

République Algérienne Démocratique et Populaire  
الجمهورية الجزائرية الديمقراطية الشعبية  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
وزارة التعليم العالي و البحث العلمي



UNIVERSITE MOHAMED SEDDIK BEN YAHIA -JIJEL  
Faculté des Sciences et de Technologie  
Département de Génie Mécanique

جامعة جيجل  
مكتبة كلية العلوم والتكنولوجيا  
أرقام الجرد: 2000

# Projet de Fin d'Études

*Pour l'Obtention du Diplôme  
De Master 2 en Génie Mécanique  
Option Mécanique des structures et des matériaux*

## Thème

**Etude de l'automatisation du diagnostic des  
défauts d'engrenage basé sur l'analyse vibratoire**

Les membres du jury :

*Dr. H. Bounib*

*Président*

*Dr. W. Boukharouba*

*Examineur*

*Mr. H. Feninech*

*Encadreur*

Présenté par :

*Benmicia Boudjemaa*

*Benmazid Hemza*

**Promotion 2016**

*Université de Jijel*

## Remerciements

*Tous d'abord, nous tenons à remercier Dieu clément et miséricordieux de nous avoir donné la force et le courage de mener à terme ce modeste travail. Comme, c'est un plaisir de remercier tous ce qui ont contribué à la Réalisation de ce mémoire.*

*En premier lieu, nous voudrions exprimer notre remerciement les plus sincères à notre encadreur Mrfenineche Hocine, pour notre avoir guidé pour la réalisation de cette étude et le soutien scientifique et moral. Nos vifs remerciements iront aux membres de jury qui nous ferons l'honneur de juger notre travail.*

*Nous voudrions aussi remercier tous les enseignants qui ont contribués par leur savoir et leurs encouragements le long de nos parcours.*

*Nous tenons également à remercier toutes les personnes qui ont participées de près ou de loin à la réalisation de ce projet.*

**B. Benmicia et H. Benmazid**

## DEDICACES

*Avec la plus grande joie et cœur aimant que je dédie ce*

*Travail :*

*À mon père et ma mère pour leur apport affectif et leurs sacrifices.*

*À mes sœurs et mes frères, et à toute ma famille...*

*À tous les enseignants qui ont contribués par leur savoir et leurs encouragements le long de mon parcours.*

*À tous mes chers amis, et mes collègues pour leurs soutiens et leurs encouragements.*

*À tous les hommes pieux.*

**B.Benmíciá**

## *Dédicaces*

*Je Dédie ce modeste travail*

*A Mes chers parents*

*A Mes chers Frères*

*A toute la famille : Benmazid*

*A Tous mes collègues et mes amis partout*

*Enfin*

*À Tous qui m'ont aidé et merci a tous*

*« Hemza »*

## Table des matières

Introduction générale

### CHAPITRE I principaux défauts d'engrenage et leurs méthodes de diagnostic

I.1 Introduction .....	1
I.2 Principaux défauts d'engrenage .....	1
I.2.1 Défauts généralisés .....	2
I.2.1.1 Usure abrasive .....	2
I.2.1.2 Pitting ou piqûres .....	2
I.2.2 Défauts localisés .....	3
I.2.2.1 Écaillage .....	3
I.2.2.2 Fissuration .....	3
I.2.2.3 Grippage .....	4
I.3 Les signaux vibratoires délivrés par un engrenage .....	4
I.3.1 Engrenage sans défauts .....	5
I.3.2 Engrenage avec défauts .....	6
I.4 Les méthodes de diagnostic .....	6
I.4.1 Les méthodes classiques .....	6
I.4.1.1 L'analyse vibratoire .....	6
I.4.1.1.1 Analyse dans le domaine temporel .....	8
I.4.1.1.2 Les modes de détections .....	8
I.4.1.1.3 Domaine d'analyse de fréquence .....	11
I.4.1.1.4 Techniques de temps-fréquence .....	11
I.4.1.1.5 Ondelettes .....	12
I.4.1.1.6 Analyse d'enveloppe .....	13
I.4.2 Les Méthode intelligentes .....	14
I.4.2.1 Introduction .....	14
I.4.2.2 La Logique floue .....	14
I.4.2.3 Les Réseaux de neurones artificiels (RNA) .....	15
I.4.2.4 Les Algorithmes génétiques .....	16
I.4.2.5 Les séparateurs à vaste marge (SVM) .....	18
I.4.2.5.1 Principe de fonctionnement général .....	18
I.5 Conclusion .....	19

### CHAPITRE II Automatisation du diagnostic basé sur les réseaux de neurones

II.1 Introduction .....	20
II.2 Automatisation du diagnostic par réseaux de neurones .....	20
II.3 Propriétés des réseaux de neurones .....	22
II.3.1 La propriété d'approximation universelle .....	22
II.3.2 La propriété de parcimonie .....	22
II.4 Neurone biologique .....	23

II.5 Neurone artificielle (formel) .....	23
II.6 Fonction d'activation .....	25
II.7 Architectures des réseaux de neurones .....	26
II.7.1 Réseaux de neurones non boucle (ou statique) "FEED-FORWARD" .....	26
II.7.1.1 Les Perceptrons .....	26
II.7.1.1.1 Définition .....	26
II.7.1.1.2 Réseaux monocouche .....	27
II.7.1.1.3 Réseaux multicouches (ou Perceptron Multi Couche PMC) .....	27
II.7.2 Réseaux bouclé (ou dynamique) "FEED-BACK" .....	28
II.8 L'apprentissage des réseaux de neurones .....	29
II.8.1 Principe de l'algorithme d'apprentissage .....	29
II.8.2 Différents types d'apprentissage .....	30
II.8.2.1 Apprentissage supervisé .....	30
II.8.2.2 Apprentissage non supervisé .....	32
II.9 Étapes de la conception d'un réseau de neurone .....	32
II.9.1 Choix et préparation des échantillons .....	33
II.9.2 Élaboration de la structure du réseau .....	33
II.9.3 Apprentissage .....	33
II.10 Application des Réseaux de Neurones .....	35
II.11 Conclusion .....	35

## **CHAPITRE III Partie Expérimentale**

III.1 Introduction .....	36
III.2 Déroulement de la classification par les RNAs .....	36
III.2.1 Extraction d'indicateurs .....	37
III.2.2 Construction de la base de données (BD) .....	37
III.2.3 Apprentissage .....	38
III.2.4 Validation et Tests .....	38
III.2.5 Exploitation du réseau .....	38
III.3 Implémentation des RNAs sous MATLAB .....	39
III.3.1 Création du réseau .....	39
III.3.2 Apprentissage du réseau .....	39
III.4 Description du Banc d'essai d'engrenage .....	39
III.5 Présentation des Signatures vibratoires .....	41
III.5.1 La méthode temporelle .....	41
III.5.1.1 Présentation les signaux temporels .....	41
III.5.1.2 Les indicateurs temporels .....	43
III.5.1.3 Préparation des données .....	43

III.5.2 La méthode fréquentielle .....	46
III.6 Automatisation par RNA .....	49
III.7 Effet du nombre des neurones cachés dans la couche cachée .....	51
III.8 Choix des valeurs des critères d'arrêt .....	56
III.8.1 Erreur Minimale .....	56
III.8.2 Nombre d'itération maximale .....	58
III.9 Conclusion .....	62
Conclusion générale	

## Liste des figures

<b>Figure I. 1</b> Origine et Localisation des défauts dans les engrenages .....	1
<b>Figure I. 2</b> Usure abrasive .....	2
<b>Figure I. 3</b> Pitting ou piquûres.....	3
<b>Figure I. 4</b> Écaillage ou Spalling .....	3
<b>Figure I. 5</b> Fissuration ou cracks .....	4
<b>Figure I. 6</b> Le grippage .....	4
<b>Figure I. 7</b> Spectre théorique d'un engrenage sain .....	5
<b>Figure I. 8</b> Spectre de même engrenage avec un défaut.....	6
<b>Figure I. 9</b> Spectre du signal vibratoire d'un engrenage .....	8
<b>Figure I. 10</b> La représentation de différentes amplitudes (vibration sinusoïdale). .....	9
<b>Figure I. 11</b> La relation entre les domaines temporel et fréquentiel. a) domaine temporel, b) domaine fréquentiel. ....	11
<b>Figure I. 12</b> c) coordonnées tridimensionnelles montrant le temps, la fréquence et l'amplitude.....	12
<b>Figure I. 13</b> Spectre de (a) carré de l'enveloppe des signaux de vibration pour le dernier jour (b) carré de l'enveloppe du signal d'EA (c) log du carré de l'enveloppe. 13	
<b>Figure I. 14</b> Aperçu synoptique d'un système flou.....	14
<b>Figure I. 15</b> Structure d'un diagnostic par RNA. ....	16
<b>Figure I. 16</b> Principe général des algorithmes génétiques.....	17
<b>Figure I. 17</b> hyperplan optimal, vecteurs de support et marge maximale. ....	18
<b>Figure I. 18</b> meilleur hyperplan séparateur. ....	19
<b>Figure II. 1</b> Variation du nombre de paramètres en fonction de variable Pour un modèle polynomial et pour un réseau de neurones. ....	22
<b>Figure II. 2</b> le neurone biologique.....	23
<b>Figure II. 3</b> Structure générale de réseau de neurone formel .....	24
<b>Figure II. 4</b> Exemple d'un réseau de neurones non bouclé.....	26
<b>Figure II. 5</b> perceptron monocouche. ....	27
<b>Figure II. 6</b> Perceptron Multi Couche PMC.....	28
<b>Figure II. 7</b> Réseaux de neurone bouclé.....	29
<b>Figure II. 8</b> Réseau à apprentissage supervisé .....	31
<b>Figure II. 9</b> réseau a apprentissage non supervisé.....	32
<b>Figure II. 10</b> Étapes de conception du réseau de neurones .....	33
<b>Figure III. 1</b> Déroulement de la classification par les RNAs.....	37
<b>Figure III. 2</b> Lancement de la boîte d'outils Neural Pattern Recognition Tools. ....	39
<b>Figure III. 3</b> (A) Banc d'essai, (B) position de l'accéléromètre triaxial (direction : xx radiale verticale, yy radiale horizontale, zz axiale), (C) dent cassée (D) dent sévèrement usée.....	40
<b>Figure III. 4</b> Schéma cinématique.....	41



<b>Figure III. 5</b> les signaux temporels pour quatre cas de fonctionnements ((A) SD, (B) UL, (C) US, et (D) DA) suivant la direction xx. ....	42
<b>Figure III. 6</b> la position des harmoniques. ....	43
<b>Figure III. 7</b> L'évolution de la valeur efficace pour différents défauts .....	44
<b>Figure III. 8</b> L'évolution du facteur de crête pour différents défauts. ....	45
<b>Figure III. 9</b> L'évolution du Kurtosis pour différents défauts. ....	45
<b>Figure III. 10</b> Représentation spectrale du signal SD, direction xx. ....	46
<b>Figure III. 11</b> Représentation spectrale du signal UL, direction xx. ....	47
<b>Figure III. 12</b> Représentation spectrale du signal US, direction xx. ....	48
<b>Figure III. 13</b> Représentation spectrale du signal DA, direction xx. ....	49
<b>Figure III. 14</b> Variation des valeurs de performance en fonction du chaque nombre des neurones cachés dans la couche cachée. ....	55
<b>Figure III. 15</b> Variation des valeurs de performance en fonction de l'erreur minimale. ....	57
<b>Figure III. 16</b> Variation des valeurs de performance en fonction de chaque nombre d'itération maximal. ....	60

## Liste des tableaux

<b>Tableau I. 1</b> Critère de sévérité du kurtosis. ....	10
<b>Tableau II. 1</b> Analogie entre le neurone biologique et le neurone Formel. ....	24
<b>Tableau II. 2</b> Modèles de fonctions d'activation. ....	25
<b>Tableau III. 1</b> les indicateurs temporels suivant la direction xx. ....	43
<b>Tableau III. 2</b> Fréquence d'engrènement et ses harmoniques. ....	44
<b>Tableau III. 3</b> Paramètres du vecteur forme. ....	50
<b>Tableau III. 4</b> Etiquetage des classes. ....	50
<b>Tableau III. 5</b> Les paramètres et configuration du PMC. ....	51
<b>Tableau III. 6</b> Performance du nombre des neurones cachés dans la couche cachée. ....	51
<b>Tableau III. 7</b> Performance de l'erreur minimale. ....	56
<b>Tableau III. 8</b> Performance du nombre max d'itération. ....	58

## Liste des symboles

$e(t)$	Bruit blanc
$\varphi_i$	La phase initiale du mouvement
$f_R$	La fréquence de rotation de l'arbre
$Z$	Nombre de dents d'une roue dentée
$i$	Nombre des harmoniques
$\tau_e$	Période d'engrènement
$N1$	Nombre de dents du pignon
$N2$	Nombre de dents de la roue
$\tau_{p1}$	Période de rotation du pignon
$\tau_{r1}$	Période de rotation de la roue
$T$	période en secondes
$f$	La Fréquence en Hz.
$X_{eff}$	La valeur efficace
$X_c$	La valeur crête
$X_{cc}$	La valeur crête à crête
$k$	Le kurtosis
$S_K$	Skewness
$\mu$	Le moyen de x
$\sigma$	L'écart type de x
$E(t)$	La valeur prévue des calculs de kurtosis de la quantité t
$B_i$	Largeur de bande
$f_i$	La Fréquence centrale
$P1, P2$	couples de parents
$F, g$	les fonctions de transfert
$Y$	sortie du réseau
$X$	Vecteurs des entrées
$W$	matrice des poids de connexions
$W0$	vecteur des biais des cellules de la couche cachée
$Z$	matrice des poids des connexions liant la couche cachée à la couche de sortie
$Z0$	vecteur des biais des cellules de la couche de sortie
$W_{kj}, W_{ij}$	les poids

$\theta_k, \theta_j$	Les biais
$n$	Le taux d'apprentissage
$\alpha$	Le moment
$M$	Le nombre d'indicateurs
$N$	Le nombre d'observations
$f_s$	La fréquence d'échantillonnage
$f_e$	La fréquence d'engrènement en (Hz)
$f_{r_1}$	La fréquence de la rotation de la roue 1
$f_{r_2}$	La fréquence de la rotation de la roue 2
$Z_1$	Le nombre des dents de la roue 1
$Z_2$	Le nombre des dents de la roue 2
$\delta_k$	L'erreur généralisée
$K_t$	Le nombre de tranche
$N_M$	Le nombre de points

# **Introduction Générale**

## Introduction générale

---

Les machines tournantes occupent actuellement une place prépondérante dans les applications faisant intervenir des systèmes de transmission de puissance. La mesure des vibrations sur ces machines revêt une importance toute particulière puisqu'elle joue un rôle capital dans les programmes de maintenance. Lorsque ces vibrations sont trop élevées, elles causent souvent un sentiment d'inquiétude, puisqu'elles annoncent possiblement un arrêt ou un bris imprévu et par conséquent une perte non négligeable de productivité ou une atteinte à la sécurité du personnel.

Les vibrations des machines tournantes sont dues à plusieurs forces dynamiques, y compris celles dues aux conditions anormales de fonctionnement ou à divers défauts. Des modèles de génération du signal de vibration ont été développés afin de rendre possible l'identification des défauts à partir des signaux mesurés et par conséquent la connaissance de l'état défectueux de la machine. Ces modèles permettent la détermination des caractéristiques spécifiques qui peuvent être extraites à l'aide du traitement des signaux, permettant ainsi de fournir des diagnostics sur l'état de la machine.

Par suite, les recherches par l'analyse du signal vibratoire ont pris une place les dégradations importantes dans la surveillance et le diagnostic des machines.

Les techniques de l'intelligence artificielle servent comme outil de base pour l'aide à la décision. Leur réponse est donc plus élaborée que celle des techniques de bas niveau. Cette réponse peut être obtenue soit à partir des données brutes venant directement des variables de surveillance, soit à partir des données traitées venant des sorties des traitements de bas niveau.

Parmi les techniques de l'intelligence artificielle utilisée pour la surveillance et le diagnostic industriel, on trouve la technique des réseaux de neurones artificiels (RNA). Les réseaux de neurones artificiels sont inspirés des neurones biologiques pour répondre aux besoins techniques grâce à ses propriétés essentielles qui sont là :

- Non linéarité qui est la capacité naturelle à réaliser l'approximation d'une fonction d'entrée/sortie non linéaire,
- Adaptabilité : le réseau s'adapte aux variations du phénomène modélisé,

## **Introduction générale**

---

En pratique, les réseaux de neurones artificiels (RNA) constituent une méthode d'approximation de systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l'aide des méthodes statistiques classiques. Les RNA donnent des résultats intéressants.

Le chapitre I : présente les principaux défauts des engrenages et leurs méthodes de diagnostic tel que les méthodes classiques et les méthodes intelligentes.

Le chapitre II : Ce chapitre nous a permis d'avoir un aperçu général sur les réseaux de neurones artificiels ; leurs types, leurs caractéristiques et leurs méthodes d'apprentissage. Dans notre étude on s'est intéressée principalement aux réseaux de neurones de type perceptron multicouches.

Le chapitre III : présente la partie expérimentale qui est basée sur l'application des méthodes de l'analyse vibratoire sur des signaux vibratoires réels recueillis sur un banc d'essais des défauts d'engrenages à quatre modes de fonctionnement, délivrés par le laboratoire de l'université de Tabriz, IRAN.

Nous terminons notre mémoire par une conclusion générale, où nous rappellerons les principaux résultats obtenus dans cette étude

**CHAPITRE I**  
**Principaux Défauts D'engrenage Et**  
**Leurs Méthodes De Diagnostic**



### I.1 Introduction :

L'engrenage est un des mécanismes élémentaires les plus utilisés pour transmettre du mouvement, et adapter les vitesses de rotation entre organes moteurs et récepteurs. Il est constitué de deux roues dentées mobiles autour d'axes de rotation, et dont l'une entraîne l'autre par l'action de dents successivement en contact.

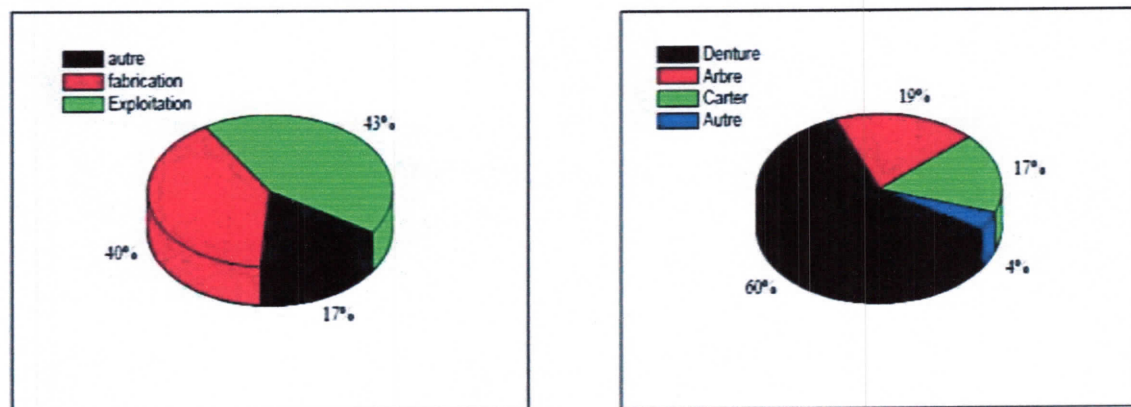
Les engrenages sont parmi les organes les plus sensibles de la chaîne cinématique et peuvent être soumis à un grand nombre d'avaries apparaissant lors du fonctionnement, et dont les causes sont multiples.

Mis-à-part les défauts de fabrication et de montage, on distingue principalement deux catégories de défauts pouvant atteindre un jeu d'engrenage, les défauts généralisés et localisés.

### I.2 Principaux défauts d'engrenage : [1]

Les enquêtes réalisées par la société des assurances ALLIANZ sur les détériorations des systèmes à engrenages tels que les réducteurs ont permis de conclure à leurs origines et à leurs localisations .

En effet, ces enquêtes ont révélé que la denture concentre la majorité des sources de défauts et ce à raison de 60% de l'ensemble des défauts ; les erreurs de conception et de fabrication sont à l'origine de 40% des avaries surgissant au niveau des engrenages.



**Figure I. 1** Origine et Localisation des défauts dans les engrenages


Au vu de ces statistiques, nous pouvons conclure que d'une part, la denture est la partie la plus fréquemment touchée par les avaries, d'autre part, les erreurs de conception et de fabrication peuvent donner lieu à l'occurrence prématurée de défauts. En outre, les problèmes d'exploitation et de maintenance sont à l'origine de 43% des défaillances. Ceci mène à conclure que l'établissement d'un plan de maintenance

préventive permettra de réduire les nuisances occasionnées au cours de l'exploitation des engrenages et particulièrement de leurs dentures. [2]

### **I.2.1 Défauts généralisés :**

#### **I.2.1.1 Usure abrasive :**

Phénomène présent sur une grande partie de la denture se caractérisant par un enlèvement de matière dû au glissement des deux surfaces en contact. Le développement de cette usure est lié à la charge mécanique à transmettre et à la vitesse de glissement, ainsi qu'à la présence d'éléments abrasifs dans le lubrifiant. Elle peut être normale, inversement proportionnelle à la dureté superficielle de la denture et progressant lentement, ou anormale lorsque le lubrifiant est pollué de particules abrasives ou corrosives. Elle conduit à un mauvais fonctionnement voir à une mise hors service.



**Figure I. 2 Usure abrasive**

#### **I.2.1.2 Pitting ou piqûres :**

Il s'agit de trous plus ou moins profonds qui affectent toutes les dents. Se produisant surtout sur des engrenages en acier de construction relativement dur. Cette avarie peut apparaître à la suite de légers désalignements d'axes par exemple, à cause de surpressions locales.




**Figure I. 3 Pitting ou piqûres**

## **I.2.2 Défauts localisés :**

### **I.2.2.1 Écaillage :**

Se manifestant par des trous moins nombreux que ceux du pitting, mais plus profonds et plus étendus. Les dégradations sont produites par fatigue en sous-couche, au point de cisaillement maximal. Ce phénomène rencontré le Plus souvent dans les engrenages cémentés, évolue très rapidement vers la rupture, sans passer par une phase d'usure.



**Figure I. 4 Écaillage ou Spalling**

**I.2.2.2 Fissuration :**


Généralement au pied de la dent, elle progresse à chaque mise en charge. Son apparition est due à un dépassement de la limite élastique en Contrainte au pied de dent, du côté de la dent en traction.



**Figure I. 5 Fissuration ou cracks**

**I.2.2.3 Grippage :**

Conséquence directe d'une destruction brutale du film d'huile, ou d'un frottement sous charge provoquant des hausses de températures. Le grippage est favorisé essentiellement par des vitesses élevées, de gros modules, un faible nombre de dents en contact.



**Figure I. 6 Le grippage**

**I.3 Les signaux vibratoires délivrés par un engrenage : [3]**

**I.3.1 Engrenage sans défauts :**

Considérons un engrenage avec des dents parfaitement identiques sans défauts. Des excitations se produiront à chaque engrènement d'une paire de dents. Le signal vibratoire engendré par cet effort est recueilli au niveau du palier.

Le signal vibratoire d'un engrenage idéal est de type :

$$x(t) = \sum_{i=1}^N a_i \sin(2\pi Z f_R t + \varphi_i) + e(t) \dots\dots\dots (I.1)$$

Où :

$e(t)$  : Bruit blanc

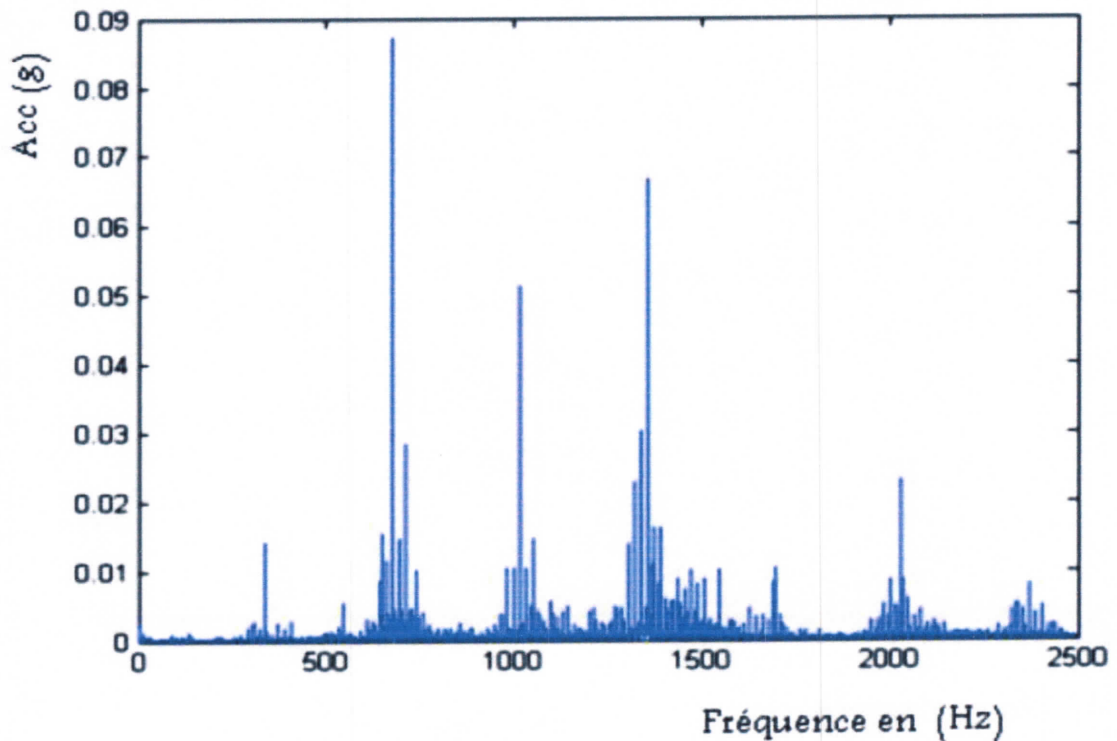
$\varphi_i$  : La phase initiale du mouvement.

$f_R$  : La fréquence de rotation de l'arbre.

$Z$  : Nombre de dents d'une roue dentée.

$i$  : Nombre des harmoniques.

Le spectre vibratoire est constitué de composantes dont les fréquences correspondent à la fréquence d'engrènement  $F_e$  et ses harmoniques (Figure I.8).




**Figure I. 7** Spectre théorique d'un engrenage sain

**I.3.2 Engrenage avec défauts :**

Pour tenir compte de l'effet de certains défauts (Figure I.9) ou de vibration de torsion, le modèle (I.1) va s'écrire en supposant l'existence de modulations d'amplitude et de phase :

$$x(t) = \sum_{i=1}^N a_i \sin(2\pi Z f_R t + \varphi_i(t)) + e(t) \dots \dots \dots (I.2)$$



**Figure I. 8** Spectre de même engrenage avec un défaut

**I.4 Les méthodes de diagnostic :**

Généralement, on peut classer les méthodes de diagnostic des défauts en deux catégories, les méthodes classiques basées sur les différentes techniques du traitement de signal et les méthodes intelligentes (RNA, Logique floue) :

**I.4.1 Les méthodes classiques : [4]**

**I.4.1.1 L'analyse vibratoire :**

L'analyse vibratoire est la plus connue et la plus largement utilisée, car adaptée aux des composants mécaniques et aux machines industrielles en fonctionnement, elle permet de détecter la majorité des défauts susceptibles d'apparaître dans les machines tournantes. [5]

### **a) L'objectif**

L'analyse vibratoire poursuit deux objectifs :

- 1) – la détection des défauts.
- 2) – l'analyse détaillée des défauts.

On utilise à cet effet des paramètres calculés :

- 1) – soit dans le domaine temporel.
- 2) – soit dans le domaine fréquentiel.
- 3) – soit sans les deux à la fois.

### **b) Spectre du signal [6]**

La caractéristique la plus marquante du signal, est la modulation d'amplitude due à la rotation des roues.

Le spectre sera composé par une famille de raies de fréquence  $kv_e = \frac{k}{\tau_e}$

due au fondamental et aux harmoniques du signal d'engrènement (Figure I.10). Cette famille de raies est étalée sur une grande partie du spectre, car la nature du signal d'engrènement est de type large bande. De plus, la modulation d'amplitude se traduit par la présence de bandes latérales  $\frac{1}{\tau_{p1}}$  pour la modulation

due au pignon, et  $\frac{1}{\tau_{r1}}$  pour la modulation due à la roue (Figure I.10).

Avec :  $\tau_e$  : période d'engrènement.

$\tau_{p1} = \tau_e N_1$  Période de rotation du pignon et  $N_1$  est le nombre de dents du pignon

$\tau_{r1} = \tau_e N_2$  Période de rotation de la roue et  $N_2$  est le nombre de dents de la roue

### **c) Manifestation d'un défaut de denture localisé**


Considérons un engrenage, si la denture est correcte, le spectre vibratoire aura la même allure que celui défini sur la Figure (I.10), avec des bandes latérales d'amplitudes données.

Si l'une des deux roues possède une dent détériorée, il se produit alors, un choc Périodique à la fréquence de rotation de cette roue. Ce choc modulera en amplitude le signal d'engrènement, il y aura donc une augmentation du facteur de modulation de la roue considérée, et donc une augmentation d'amplitude de ses raies latérales.

### **d) Détermination du spectre**

Pour obtenir le spectre en fréquence, il existe plusieurs méthodes. On distingue Principalement deux approches :

- Les méthodes non-paramétriques
- Les méthodes paramétriques



**Figure I. 9** Spectre du signal vibratoire d'un engrenage

En réalité, l'amplitude de toutes les raies est pondérée par la réponse impulsionnelle de la structure mécanique reliant la source excitatrice au capteur.

**I.4.1.1.1 Analyse dans le domaine temporel :**

Dans l'analyse des vibrations, il est possible de visualiser le signal en forme d'onde dans le temps sur des oscilloscopes et par conséquent les composantes de fréquence. La formule suivante donne la relation entre le temps et la fréquence

$$T = 1/f \dots\dots\dots (I.3)$$

Où : *T* est la période en secondes et *f* est la fréquence en Hz.

Cette formule permet de déterminer les composantes de fréquence à partir du signal de temps (données en forme d'onde).

**I.4.1.1.2 Les modes de détections :**

En mesure vibratoire, on utilise couramment trois modes de détection :

- Valeur efficace.
- Valeur crête.
- Valeur crête à crête.

**1) La Valeur efficace *X<sub>eff</sub>* :**

Pour une vibration périodique, la valeur efficace est la moyenne quadratique des valeurs efficaces de chacune des vibrations sinusoïdales qui la composent :



$$X_{eff} = \sqrt{(X_{1eff}^2 + X_{2eff}^2 + \dots + X_{neff}^2)} \quad \text{ou} \quad X_{eff} = \sqrt{[1/T \int_0^T X^2(t) dt]} \quad \dots\dots(I.4)$$

Il existe une autre désignation de la valeur efficace qui est Xrms (rms : root mean square).

Pour une vibration sinusoïdale :

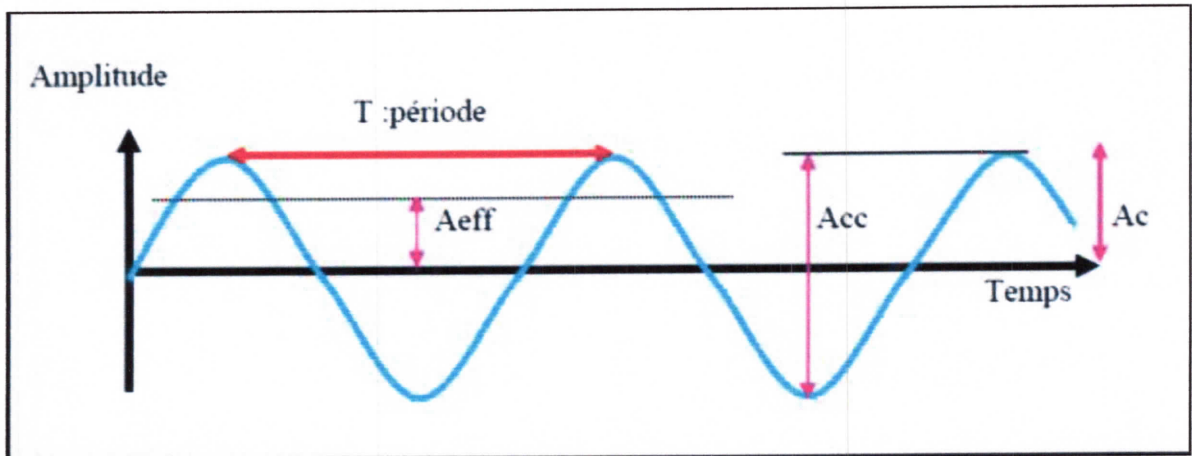
$$X_{eff} = \frac{X_c}{\sqrt{2}} = \frac{X_{cc}}{2\sqrt{2}} \quad \dots\dots\dots(I.5)$$

**2) La Valeur crête Xc :**

La valeur crête d'une vibration est la valeur maximale prise par la vibration x(t) dans l'un des sens positif et négatif.

**3) La Valeur crête à crête Xcc :**

La valeur crête à crête d'une vibration est la somme des deux valeurs crête pour les sens positif et négatif.



**Figure I. 10** La représentation de différentes amplitudes (vibration sinusoïdale).

**4) Le Kurtosis :**

Mathématiquement est le moment d'ordre 4, est couramment nommé en traitement de signal par « Kurtosis ». Il représente le taux d'aplatissement de la distribution, il donne une évaluation de l'importance du pic du sommet de la courbe, il est défini par : [7].

$$M_4 = K = \frac{1}{\sigma^4} \int_{-\infty}^{+\infty} (x - \mu)^4 p(x) dx \quad \dots\dots\dots(I.6)$$

Ou par :

$$K_U = \frac{1}{N} \sum_{i=1}^N \left[ \frac{(x_i - \mu)}{\sigma} \right]^4 \quad \dots\dots\dots(I.7)$$

Ce moment est utilisé pour détecter la présence de chocs dans le signal vibratoire. En

Effet, pour un signal de distribution gaussienne, le kurtosis est égal à 3.

Kurtosis	Sévérité
1.5	Bon : signal harmonique
2.8 à 3.2	Passable : signal aléatoire
3.2 à 4	Elevé
>4	Critique

**Tableau I. 1** Critère de sévérité du kurtosis.

Le  $\mu$  est le moyen de  $x$ , le  $\sigma$  est l'écart type de  $x$ , et  $p(x)$  représente la valeur prévue des calculs de kurtosis de la quantité  $t$ . une version d'échantillon de cette valeur de population.

**5) Skewness :**

C'est un **Moment d'ordre 3** couramment appelé « Skewness », représente le taux de dissymétrie de la distribution d'amplitudes du signal par rapport à la valeur moyenne :

$$M_4 = S_k = \frac{1}{\sigma^3} \int_{-\infty}^{+\infty} (x - \mu)^3 p(x) dx \dots \dots \dots (I.8)$$

C'est une quantité sans dimension, Elle sera positive ou négative selon l'étalement de la courbe à droite ou à gauche, respectivement, de la valeur moyenne.

Le  $\mu$  est le moyen de  $x$ , le  $\sigma$  est l'écart type de  $x$ , et  $p(x)$  représente la valeur prévue des calculs d'obliquité de la quantité  $t$ . une version d'échantillon de cette valeur de population.

**6) Les moments d'ordre supérieurs :**

De nombreux moments d'ordre supérieur sont employés dans le domaine du traitement du signal afin d'estimer les caractéristiques du signal. La particularité des signaux rencontrés (données temporelles ou non, stationnaires ou non) et les applications nécessitant souvent une réponse en temps réel ont poussées au développement de nouveaux estimateurs (moments). Elles donnent une description plus complète des données et de leurs propriétés. [8]

**I.4.1.1.3 Domaine d'analyse de fréquence :**

Le second type de représentation est la représentation du domaine de fréquence (fréquence, amplitude) appelé spectre ou représentation spectrale. Le signal complexe  $F(t)$  qui est difficile à interpréter, est décomposé en une série de composants élémentaires définis par leurs fréquences et leurs amplitudes.

L'outil mathématique utilisé dans ce cas est la décomposition du signal à l'aide de la transformée de Fourier. Si cette décomposition est possible, sa représentation dans le domaine temporel est encore inutilisable. Il consiste à représenter dans un diagramme appelé spectre la fréquence et l'amplitude. avec ce type de représentation, chaque composante sinusoïdale est définie par son amplitude et sa fréquence. La représentation spectrale devient plus nette et réalisable. Le spectre final contient toutes les fréquences sinusoïdales (lignes discrètes) formant le signal de vibration d'origine.

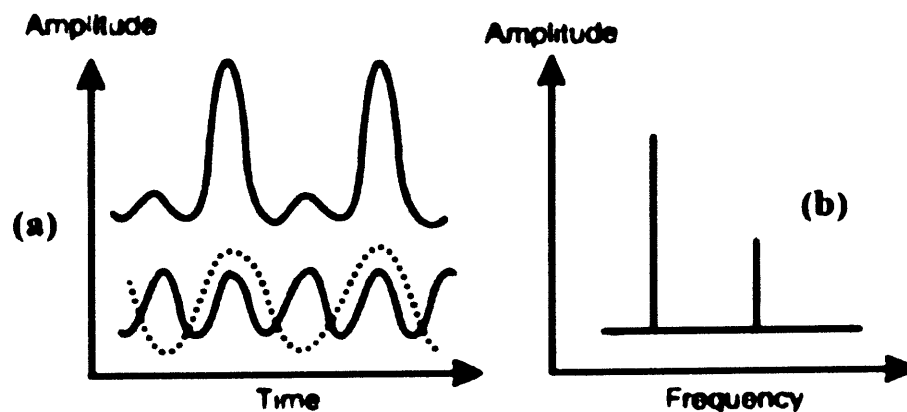


Figure I. 11 La relation entre les domaines temporel et fréquentiel. a) domaine temporel, b) domaine fréquentiel.

**I.4.1.1.4 Techniques de temps-fréquence :**

Comme mentionné précédemment, dans toutes les méthodes classiques, il est supposé que les signaux sont stationnaires mais ce n'est pas toujours le cas d'autre part, dans certaines machines lorsque les défauts commencent à apparaître, les signaux vibratoires deviennent non-stationnaires et dans ce cas, les méthodes conventionnelles ne sont pas applicables. Il existe actuellement plusieurs types de variables telles que la vitesse des machines tournantes dont les signaux de vibration stationnaires ou pseudo-stationnaire ne peuvent pas être supposés.

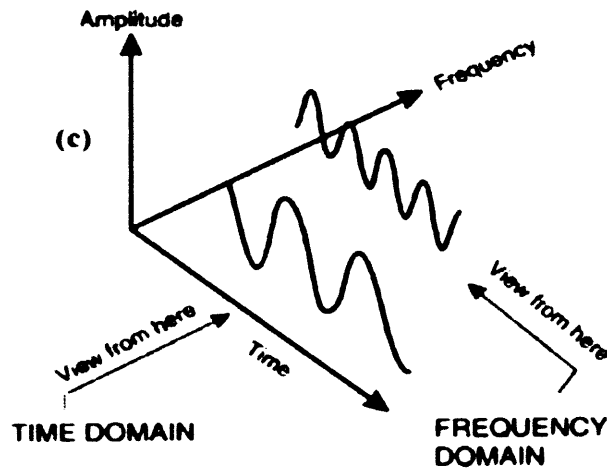


Figure I. 12 c) coordonnées tridimensionnelles montrant le temps, la fréquence et l'amplitude.

**Potentiels des méthodes temps-fréquence :**

Les méthodes temps-fréquence permettent (voir la figure I.12) :

- 1- de fournir une représentation du signal en trois dimensions (amplitude-temps-fréquence).
- 2- de détecter et de suivre le développement des défauts qui génèrent une faible puissance vibratoire.
- 3- de superviser des machines dans lesquelles le processus de fonctionnement normal produit une amplitude élevée des chocs périodiques.

**I.4.1.1.5 Ondelettes :**

L'analyse en ondelettes consiste à décomposer le signal sur une base de fonctions à support borné. Les fonctions de base se déduisent d'une ondelette mère par dilatation et ou contraction. On parle ainsi de décomposition temps-échelle On distingue :

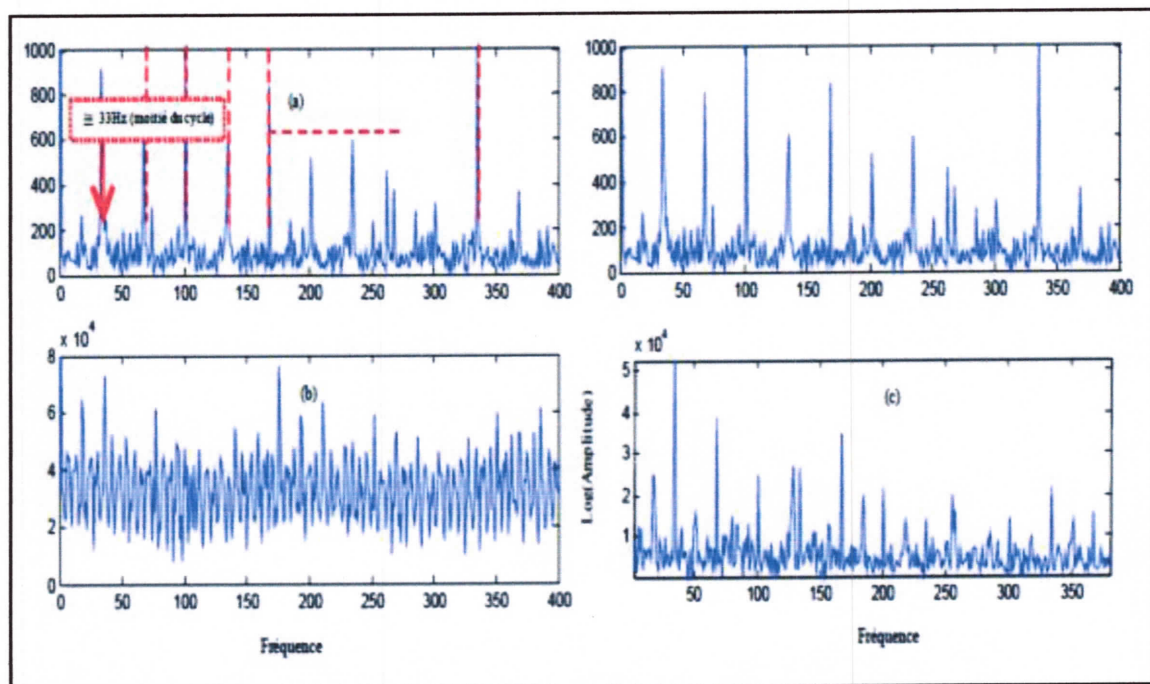
- L'ondelette continue de Morlet (qui correspond en fait à un filtrage du signal par un banc de filtres à  $B_i/f_i = cte$  ..... (I.9)  
( $B_i$  largeur de bande,  $f_i$  fréquence centrale) en quadratures.
- et les ondelettes discrètes orthogonales qui garantissent l'unicité de la décomposition d'un signal. Le choix de la meilleure 'ondelette' en fonction du problème considéré est important dans un souci d'interprétation physique de la décomposition.

Pour les signaux d'engrenages, la transformée en ondelettes permet de mettre en évidence les non-stationnarités et par conséquent, elle a été appliquée dans plusieurs études.

### **I.4.1.1.6 Analyse d'enveloppe : [9]**

La comparaison concerne aussi l'analyse d'enveloppe des signaux d'émission acoustique et des signaux de vibration afin de faire la démodulation pour en extraire les pics correspondant aux chocs. L'enveloppe est calculée en utilisant la transformation d'Hilbert.

La Figure I.13(a) et (b) montre le carré du spectre de l'enveloppe des signaux de vibration et d'émission acoustique correspondant au dernier jour de l'acquisition. Le spectre d'enveloppe des signaux de vibration montre des pics relatifs à 32 Hz, c'est-à-dire à la moitié du cycle. Ce résultat est confirmé parce que les défauts détectés dans cette campagne d'essais correspondent à deux défauts qui se situent au début et à la moitié du cycle. Néanmoins, la détection de ces pics n'est pas possible lorsqu'on prend en compte le spectre d'enveloppe du signal d'émission acoustique (Figure I.13) (b) parce que l'enveloppe a une dynamique trop élevée. Par conséquent, nous avons fait une étude logarithmique du carré du spectre de l'enveloppe (Voir Figure I.13) (c). Dans ce cas, les pics observés dans le spectre de vibration apparaissent aussi dans cette figure. Toutefois, nous observons une plus grande quantité de faux pics.



**Figure I. 13** Spectre de (a) carré de l'enveloppe des signaux de vibration pour le dernier jour (b) carré de l'enveloppe du signal d'EA (c) log du carré de l'enveloppe.

**I.4.2 Les Méthode intelligentes :**

**I.4.2.1 Introduction :**

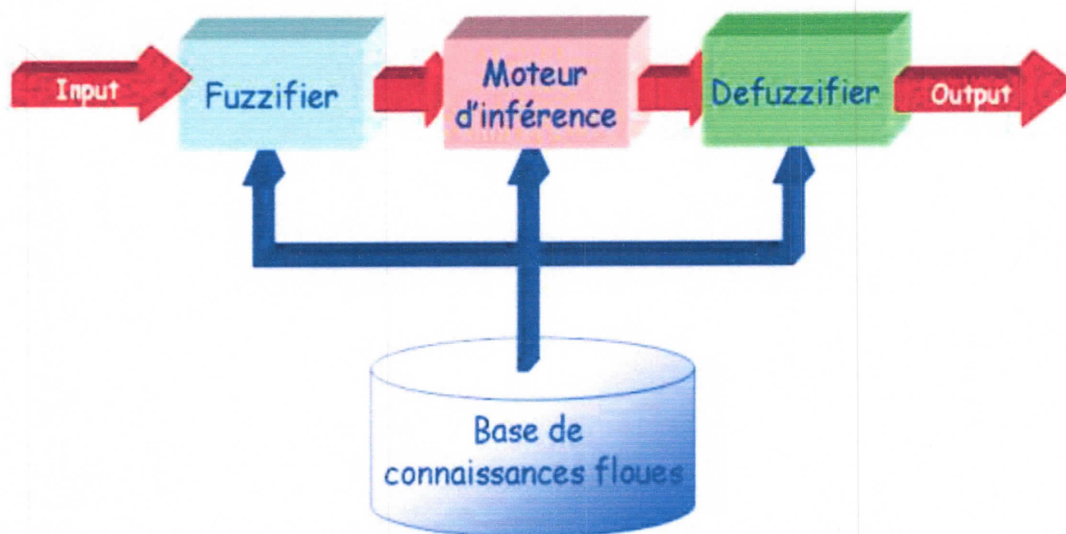
Les méthodes basées sur l'intelligence artificielle, il n'est pas nécessaire de disposer d'un modèle mathématique du processus, par contre ces méthodes retenues reposent sur l'expertise humaine confortée par un solide retour d'expérience, parmi lesquelles, nous pouvons citer, la logique floue, les réseaux de neurones artificiels, les algorithmes génétiques, SVM...etc.

**I.4.2.2 La Logique floue : [10]**

Les ensembles flous permettent de représenter et manipuler des données imprécises et incertaines. Leurs applications s'adressent avant tout à une aide à la décision.

Pour réaliser un système flou, on doit suivre trois étapes indispensables :

- **Fuzzification** : On associe à chaque variable d'entrée un degré d'appartenance à un état déterminé à l'aide des fonctions d'appartenances définies dans le système.
- **Inférence** : les degrés d'appartenance de chaque variable à chaque état étant déterminés, on applique alors les règles d'inférence préalablement définies pour obtenir le degré d'appartenance des variables de sortie à chaque état.
- **Défuzzification** : à partir des règles d'appartenance des sorties, on applique un critère de décision pour calculer la sortie du système.



**Figure I. 14** Aperçu synoptique d'un système flou

**I.4.2.3 Les Réseaux de neurones artificiels (RNA) :**

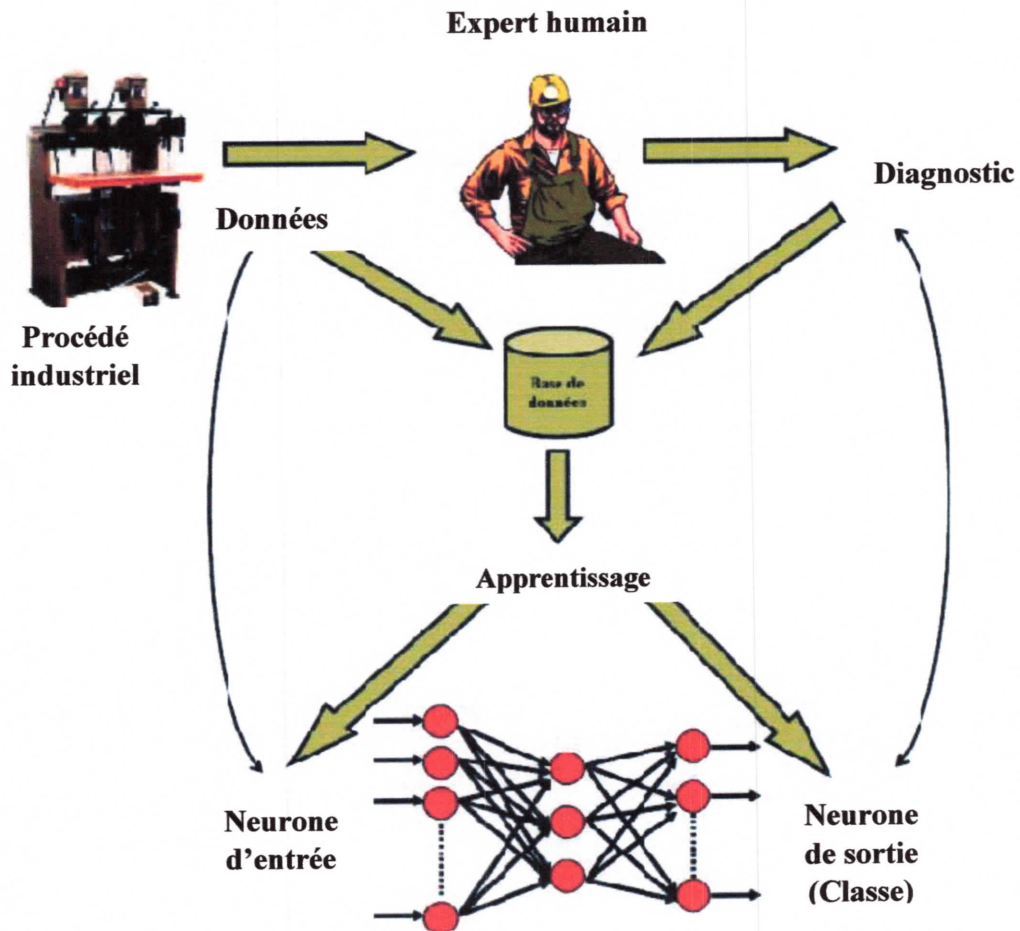
Les RNA ont été développés sous forme de modèles parallèles de réseau distribué basés sur l'apprentissage biologique du cerveau humain. Il y a de nombreuses applications d'RNA dans l'analyse de données, l'identification de modèle et la commande [11].

Les réseaux de neurones formels ont été développés dans les années 50 pour résoudre des problèmes d'ingénierie : estimation, approximation des fonctions,

Prédiction... etc. ce sont des modèles mathématiques et informatiques, des assemblages d'unités de calcul appelés neurones formels, et dont l'inspiration originelle était le fonctionnement cérébral de l'être humain.

Leur apprentissage permet de réaliser des tâches complexes dans différents types d'application (classification, identification, reconnaissance de forme, de la voix, vision, système de contrôle), il est effectué de sorte que pour une entrée particulière présentée au réseau corresponde une cible spécifique. L'ajustement des poids se fait par comparaison entre la réponse du réseau (ou sortie) et la cible, jusqu'à ce que la sortie corresponde (au mieux) à la cible (Figure I.15).

Pour un diagnostic réalisé par RNA pour identifier des défauts dans un système, on doit disposer d'un nombre suffisant d'exemples de bon fonctionnement et de défauts pour pouvoir les apprendre. Pendant la phase d'apprentissage, les exemples sont présentés au réseau en entrée avec les étiquettes correspondantes à la sortie.



**Figure I. 15** Structure d'un diagnostic par RNA.

#### **I.4.2.4 Les Algorithmes génétiques : [12]**

Les algorithmes génétiques sont des algorithmes d'optimisation s'appuyant sur des techniques dérivées de la génétique et de l'évolution naturelle croisements, mutations, sélection,... etc. Les algorithmes génétiques ont déjà une histoire relativement ancienne, puisque les premiers travaux de John Holland sur les systèmes adaptatifs remontent à 1962, L'ouvrage de David Goldberg a largement contribué à les vulgariser.

Un algorithme génétique recherche le ou les extrema d'une fonction définie sur un espace de données. Pour l'utiliser, on doit disposer des cinq éléments suivants :

1. Un principe de codage de l'élément de population. Cette étape associe à chacun des points de l'espace d'état une structure de données. Elle se place généralement après une phase de modélisation mathématique du problème traité. Le choix du codage des données conditionne le succès des algorithmes génétiques. Les codages binaires ont été très employés à l'origine. Les codages réels sont désormais largement utilisés,



## CHAPITRE I Principaux défauts d'engrenage et leurs méthodes de diagnostic

notamment dans les domaines applicatifs, pour l'optimisation de problèmes à variables continues.

2. Un mécanisme de génération de la population initiale. Ce mécanisme doit être capable de produire une population d'individus non homogène qui servira de base pour les générations futures. Le choix de la population initiale est important car il peut rendre plus ou moins rapide la convergence vers l'optimum global. Dans le cas où l'on ne connaît rien du problème à résoudre, il est essentiel que la population initiale soit répartie sur tout le domaine de recherche.

3. Une fonction à optimiser. Celle-ci prend ses valeurs dans  $R^+$  et est appelée *Fitness* ou fonction d'évaluation de l'individu. Celle-ci est utilisée pour sélectionner et reproduire les meilleurs individus de la population.

4. Des opérateurs permettant de diversifier la population au cours des générations et d'explorer l'espace d'état. L'opérateur de croisement recompose les gènes d'individus existant dans la population, l'opérateur de mutation a pour but de garantir l'exploration de l'espace d'état.

5. Des paramètres de dimensionnement : taille de la population, nombre total de générations ou critère d'arrêt, probabilités d'application des opérateurs de croisement et de mutation.




Figure I. 16 Principe général des algorithmes génétiques.

Le principe général du fonctionnement d'un algorithme génétique est représenté sur la figure (I.16) On commence par engendrer une population d'individus de façon aléatoire. Pour passer d'une génération  $k$  à la génération  $k + 1$ , les trois opérations suivantes sont répétées pour tous les éléments de la population  $k$ . Des couples de parents  $P1$  et  $P2$  sont sélectionnés en fonction de leurs adaptations.

### **I.4.2.5 Les séparateurs à vaste marge (SVM) : [13]**


Les machines à vecteurs de support sont un ensemble de techniques d'apprentissage destinées à résoudre des problèmes de discrimination, c'est-à-dire décider à quelle classe appartient un échantillon, ou de régression, c'est-à-dire prédire la valeur numérique d'une variable.

Le succès de cette méthode est justifié par les solides bases théoriques qui la soutiennent. Il existe en effet un lien direct entre la théorie de l'apprentissage statistique et l'algorithme d'apprentissage de SVM.

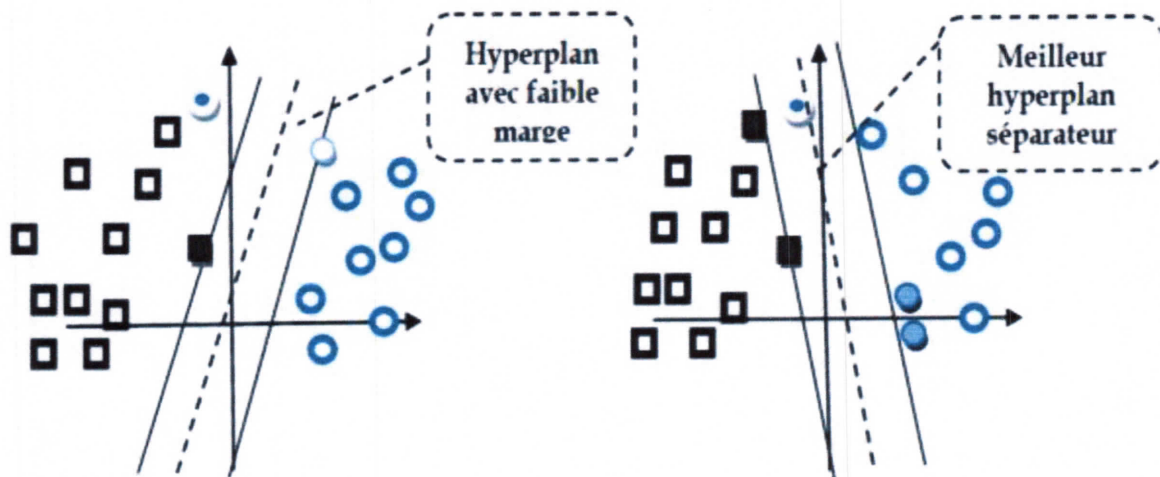
SVM est une méthode de classification particulièrement bien adaptée pour traiter des données de très hautes dimensions telles que les signaux, les images et la voix...etc.

#### **I.4.2.5.1 Principe de fonctionnement général :**

Un SVM, comme un perceptron, trouve un séparateur linéaire entre les points de données de deux classes différentes. En général, il peut y avoir plusieurs séparateurs possibles entre les classes (en supposant le problème linéairement séparable).



**Figure I. 17** hyperplan optimal, vecteurs de support et marge maximale.



**Figure I. 18** meilleur hyperplan séparateur.

### **I.5 Conclusion :**

Dans ce chapitre, nous avons présenté les principaux défauts des engrenages, ainsi que leurs méthodes de diagnostic. Mais depuis quelques années, on a fait appel à des approches basées sur l'intelligence artificielle. Et parmi ces méthodes, les réseaux de neurones artificiels (RNAs) qui ont une large utilisation dans le diagnostic des défauts dans les machines tournantes.

Dans ce sens, le chapitre suivant sera consacré à un état de l'art sur les RNAs.

**CHAPITRE II**  
**Automatisation Du Diagnostic Basé**  
**Sur Les Réseaux De Neurones**

### **II.1 Introduction :**

Dans le processus de la maintenance conditionnelle, l'interprétation des signaux vibratoires reste le domaine du spécialiste. Il ressort d'études antérieures que les méthodes classiques permettent d'envisager une aide appréciable à la décision durant l'analyse de l'état de santé des systèmes étudiés.

Dans cette étude, on utilise l'approche du diagnostic par réseaux de neurones, une branche de l'intelligence artificielle, qui permet aux opérateurs relativement non qualifiés de prendre des décisions fiables sans connaître le mécanisme du système et analyser les données.

C'est dans ce contexte que s'inscrit cette étude à savoir d'appliquer l'approche des réseaux de neurones sur un ensemble de données issues des mesures réels sur quatre pignons sans ou avec défauts (dent sans défauts, dent d'une usure légère, dent d'une usure sévère, dent arrachée).

### **II.2 Automatisation du diagnostic par réseaux de neurones :**

Les réseaux de neurones artificiels ou RNA sont des assemblages fortement connectés d'unités de calcul. Une image brute (ou prétraitée) de dimensions fixes constitue habituellement la source d'entrée des réseaux. Les dimensions doivent être établies au préalable car le nombre de neurones sur la couche d'entrée en dépend. ce là étant dit, plus les dimensions de l'image sont élevées, plus la complexité et le temps d'apprentissage augmentent. En effet, pour une image de dimensions 130×150 pixels, 19500 neurones seront requis sur la couche d'entrée, ce qui est énorme, L'apprentissage efficace d'un tel réseau est également douteux.

Grâce 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.

L'avantage de ce modèle est sa robustesse face aux variations d'inclinaison et changement d'échelle. Cependant, l'utilisation d'exemples pour apprendre, apporte le risque de ne pouvoir résoudre que des situations déjà rencontrées, c.à.d. un phénomène de sur-apprentissage qui spécialiserait le réseau uniquement sur les exemples connus sans généraliser. [14]

## **CHAPITRE II Automatisation du diagnostic basé sur les réseaux de neurones**

Le principe des réseaux de neurones s'inspire des neurones biologiques. Le modèle du neurone formel se comporte comme un opérateur effectuant une somme pondérée de ses entrées, suivie d'une non linéarité, appelée fonction d'activation, responsable du comportement du neurone.

Un réseau de neurones comprend un certain nombre de couches de neurones interconnectés : Couches d'entrées, couches cachées et couches de sortie. L'entrée représentée par les nœuds des sources fournit des poids d'accès physiques pour l'application des signaux d'entrées. Les neurones dans la couche cachée se comportent comme des détecteurs de caractéristique. Tandis que, les neurones dans la couche de sortie présentent à l'utilisateur les conclusions obtenues par le réseau, ou la réponse aux signaux d'entrées (Figure. : II.3) Une loi d'apprentissage permet d'ajuster les poids des connexions afin d'avoir les performances désirées.

L'initialisation du réseau de neurones est un processus itératif d'ajustement des poids et des biais de manière à minimiser un critère d'erreur. L'initialisation constitue aussi la phase d'apprentissage.

Les **avantages** des réseaux de neurones sont :

- + **Rapidité** : Très utile lorsque le diagnostic doit être conduit en ligne.
- + **Robustesse** : Un réseau de neurones est robuste surtout vis-à-vis du bruit.

Toutefois, un réseau de neurone présente des **inconvénients** tels que :

- + L'apprentissage peut être long et difficile.
- + L'apprentissage est gourmand en temps de calcul. Par ailleurs, il doit être réalisé sur toutes les données à la fois, avec le risque que le réseau oublie les résultats précédents.
- + Il est nécessaire de posséder des jeux de données sur toutes les conditions de fonctionnement et en particulier pour les fonctionnements défectueux.

L'intérêt des RNA dans le domaine du diagnostic se résume en deux points :

- ❖ Le premier point est la faculté du réseau de neurones d'être utilisé en tant que règle de décision dans un processus d'automatisation de l'opération du diagnostic.
- ❖ Le second point est la faculté d'apprentissage et de mémorisation d'un grand volume d'information. [15]

### II.3 Propriétés des réseaux de neurones :

Les réseaux de neurones artificiels possèdent une propriété fondamentale qui Justifient l'intérêt croissant qui leur est accordé et que sont capable d'intervenir dans des domaines très divers, et qui les distingue des techniques classiques de traitement des données.

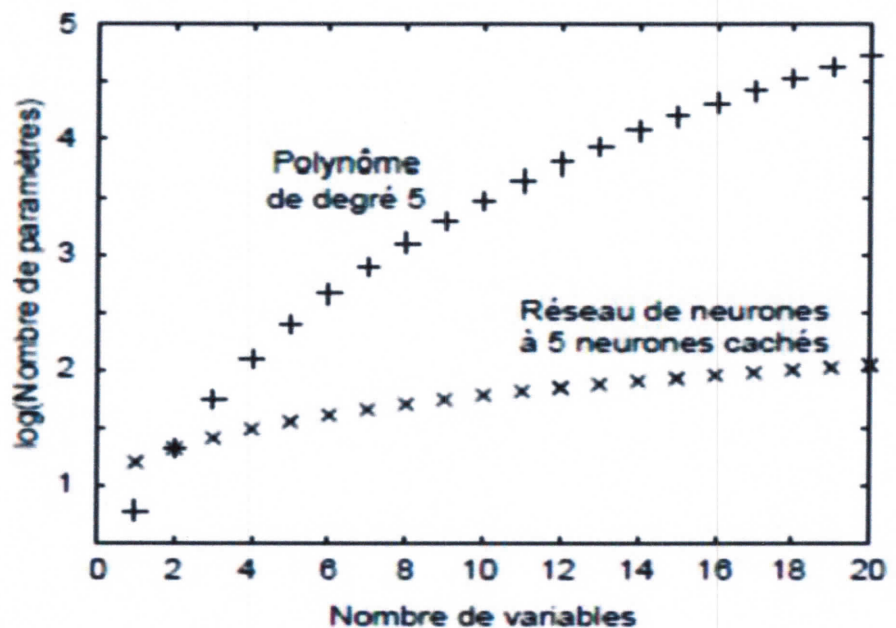
#### II.3.1 La propriété d'approximation universelle :

Cette propriété peut être énoncée comme suit: Toute fonction bornée suffisamment régulière peut être approchée uniformément, avec bonne précision, dans un domaine fini de l'espace de ses variables, par un réseau de neurones qui comporte une couche de neurones cachée en nombre fini, possédant tous la même fonction d'activation et un neurone de sortie linéaire.

#### II.3.2 La propriété de parcimonie :

Lors de la modélisation d'un processus à partir de ses données, on cherche toujours à obtenir les résultats les plus satisfaisants possibles avec un nombre minimum de paramètres. On dit que l'on cherche l'approximation la plus parcimonieuse.

Pour obtenir un modèle non linéaire de précision donnée, un RN a besoin de moins de paramètres ajustables que les méthodes de régression classiques (par exemple la régression polynomiale). Or le nombre de données nécessaires pour ajuster le modèle est directement lié au nombre de ses paramètres. (Figure II.1). [16]



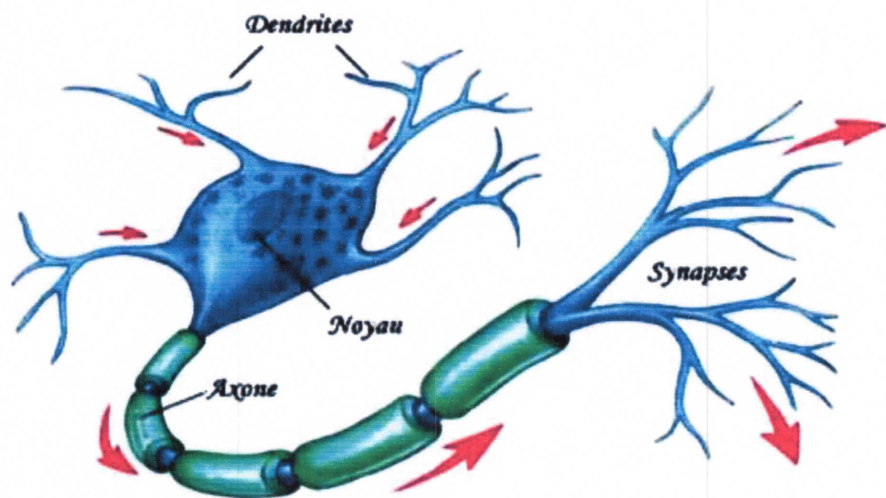
**Figure II. 1** Variation du nombre de paramètres en fonction de variable Pour un modèle polynomial et pour un réseau de neurones.

## **II.4 Neurone biologique :**

Neurone biologique est une cellule vivante spécialisée dans le traitement des signaux électriques, les neurones sont reliés entre eux par des liaisons appelées axones, Ces axones vont eux même jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux éclectiques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone.

Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu, vont fournir un courant en sortie.

La structure d'un neurone se compose en trois parties (voir la figure II.2) :



**Figure II. 2 le neurone biologique**

- **Le noyau** : ou cellule d'activation nerveuse, au centre du neurone.
- **L'axone** : attaché au noyau qui est électriquement actif, ce dernier conduit l'impulsion générée par le neurone.
- **Dendrites** : électriquement passives, elles reçoivent les impulsions d'autres neurones. [17]

## **II.5 Neurone artificielle (formel) :**

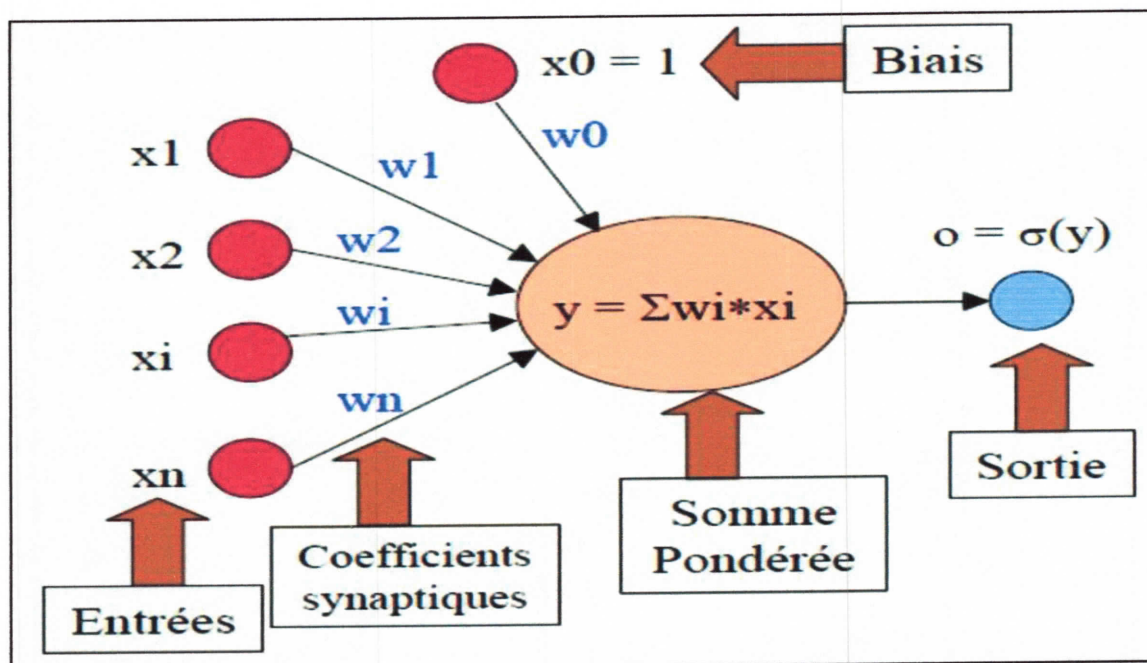
L'élément de base d'un réseau de neurones est, bien entendu, le neurone artificiel présenté par la (figure II .3) Un neurone artificiel contient deux éléments principaux :

- ❖ un ensemble de poids associés aux connexions du neurone.
- ❖ une fonction d'activation (Tableau II .1).

Les valeurs d'entrée sont multipliées par leur poids correspondant et est additionnées pour obtenir la somme S.



Cette somme devient l'argument de la fonction d'activation, qui est le plus souvent d'une des formes présentées ci-dessous. Une fonction d'activation importante est la simple multiplication avec la valeur 1, c'est à dire que la sortie est simplement une somme pondérée. Cette propriété montre l'intérêt des réseaux de neurones par rapport à d'autres approximateurs comme les polynômes dont la sortie est une fonction linéaire des paramètres ajustables : pour un même nombre d'entrées, le nombre de paramètres ajustables à déterminer est plus faible pour un réseau de neurones que pour un polynôme. [18]



**Figure II. 3** Structure générale de réseau de neurone formel

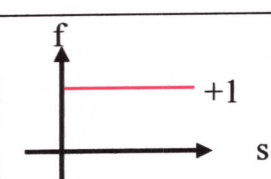
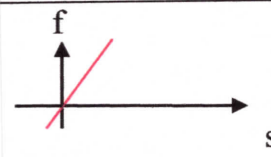
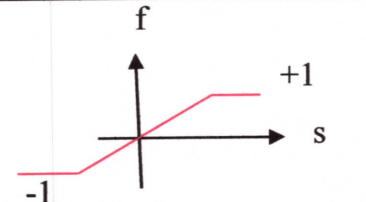
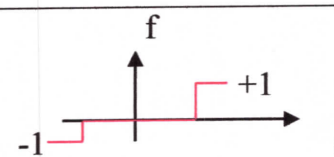
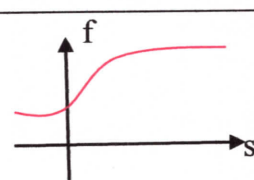
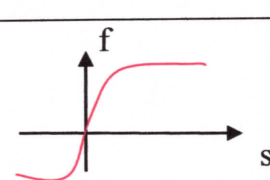
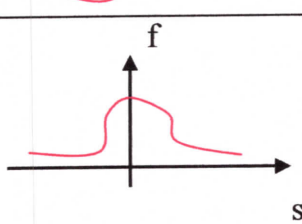
Le Tableau I.1 est représenté l'analogie entre le neurone biologique et le neurone Formel.

Neurone biologique	Neurone formel
Dendrite	Signal d'entrée
Synapse	Poids de connexion
Somma	Fonction d'activation
Axone	Signal de sortie

**Tableau II. 1** Analogie entre le neurone biologique et le neurone Formel.

**II.6 Fonction d'activation :**

La fonction de transfert est en général, une fonction non linéaire monotone croissante par ailleurs, les fonctions de transfert sont de qualités diverses : Elles peuvent être déterministes, continues, discontinues ou aléatoires. (Le tableau II.1) donne les modèles de fonctions d'activation utilisées. [19]

Désignation	Expression	Graphe
Fonction de Heaviside	$S \geq 0 \quad f = 1$ $S \leq 0 \quad f = 0$	
Fonction linéaire sans saturation	$f(s) = as$	
Fonction linéaire avec seuil	$-1 \leq S \leq 1 \quad f = as$ $S \leq -1 \quad f = -1$ $S \geq 1 \quad f = 1$	
Fonction à seuils multiples	/	
Fonction sigmoïde (1)	$f_1(s) = \frac{1}{1+e^{-s}}$	
Fonction sigmoïde (2)	$f_2(s) = \frac{1-e^{-s}}{1+e^{-s}}$	
Fonction stochastique	$f(s) = \exp(-s^2)$	

**Tableau II. 2** Modèles de fonctions d'activation.

**II.7 Architectures des réseaux de neurones :**

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

**II.7.1 Réseaux de neurones non boucle (ou statique) "FEED-FORWARD"**

Un réseau de neurones non bouclé (appelé aussi statique) est représenté comme un graphe dont les nœuds sont les neurones. L'information circule des entrées vers les sorties sans retour en arrière (Figure II.4). Ce type de réseaux est utilisé pour effectuer des tâches d'approximation de fonction non linéaire, de la classification ou de la modélisation de processus statiques non linéaires. [20]




Figure II. 4 Exemple d'un réseau de neurones non bouclé.

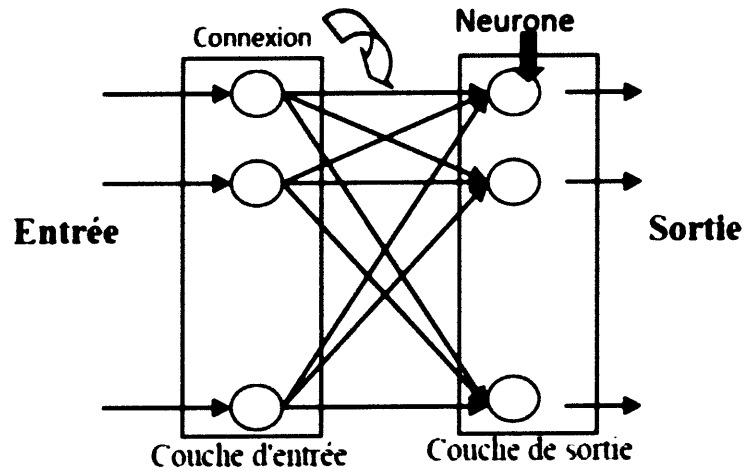
**II.7.1.1 Les Perceptrons :**

**II.7.1.1.1 Définition :**

Le mécanisme perceptron fut inventé par le psychologue FRANK Rosenblat à la fin des années 50. Il représentait sa tentative d'illustrer certaines propriétés fondamentales des systèmes intelligents en général. Le réseau dans ce modèle est formé de trois couches : Une couche d'entrée (la rétine), fournissant des données à une couche intermédiaire, chargée des calculs, cela en fournissant la somme des impulsions qui lui viennent des cellules auxquelles elle est connectée, et elle répond généralement suivant une loi définie avec un seuil, elle-même connectée à la couche de sortie (couche de décision), représentant les exemples à mémoriser. Seule cette dernière couche renvoie des signaux à la couche intermédiaire, jusqu'à ce que leurs connexions se stabilisent.

**II.7.1.1. 2 Réseaux monocouche :**

Historiquement le premier RNA, c'est le réseau monocouche. C'est un réseau simple, puisque il ne se compose que d'une couche d'entrée et d'une couche de sortie.




**Figure II. 5** perceptron monocouche.

**II.7.1.1.3 Réseaux multicouches (ou Perceptron Multi Couche PMC) :**

C'est le réseau de neurones statique le plus utilisé. Les neurones sont arrangés par couche. Les neurones de la première couche reçoivent le vecteur d'entrée, il calcule nutteurs sorties qui sont transmises aux neurones de la seconde couche qui calculent eux même leurs sorties et ainsi de suite de couche en couche jusqu'à celle de sortie. Chaque neurone dans la couche cachée est connecté à tous les neurones de la couche précédente et de la couche suivante, et il n'y a pas de connexions entre les cellules d'une même couche.

Il peut résoudre des problèmes non linéairement séparables et il suit un apprentissage

Supervisé avec la règle de correction de l'erreur.



**Figure II. 6** Perceptron Multi Couche PMC.

La sortie du réseau a pour expression :

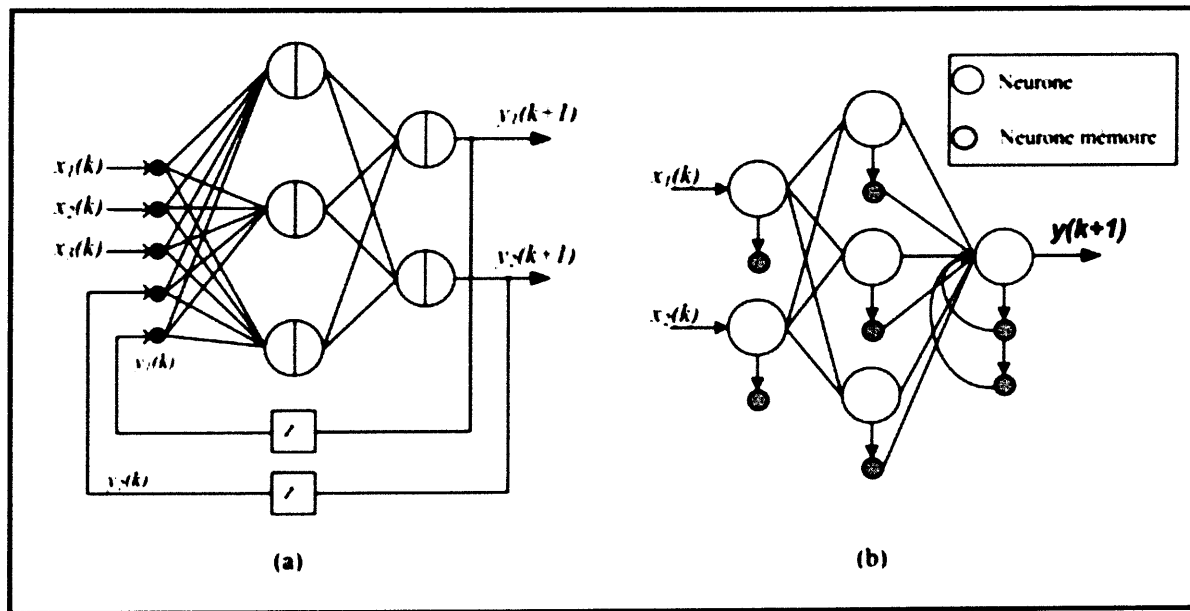
$$Y = g [Z [f (WX + w_0 )] + Z_0 ] \dots \dots \dots (II.1)$$

Avec :

$F$  et  $g$  les fonctions de transfert, des couches cachées et de sorties respectivement,  $Y$  sortie du réseau,  $X$  vecteur des entrées.  $W$  : matrice des poids de connexions liant la couche d'entrée à la couche cachée.  $W_0$  : vecteur des biais des cellules de la couche cachée.  $Z$  : matrice des poids des connexions liant la couche cachée à la couche de sortie.  $Z_0$  : vecteur des biais des cellules de la couche de sortie.

**II.7.2 Réseaux bouclé (ou dynamique) "FEED-BACK" :**

Un réseau dynamique ou récurrent possède la même structure qu'un réseau multicouche munie de rétroactions. Les connexions rétroactives peuvent exister entre tous les neurones du réseau sans distinction, ou seulement entre certains neurones (les neurones de la couche de sortie et les neurones de la couche d'entrée ou les neurones de la même couche par exemple). La (figure II.7) montre deux exemples de réseaux récurrents. Le premier est un simple multicouche qui utilise un vecteur d'entrée qui contient les copies des activations de la couche de sortie du réseau et le deuxième est un réseau à mémoire se distingue du premier par la présence des unités mémoires. [21]



**Figure II. 7 Réseaux de neurone bouclé**

## II.8 L'apprentissage des réseaux de neurones :

La recherche des algorithmes d'apprentissage statistiques amène à d'importantes découvertes au cours des deux dernières décennies, qui ont changé la manière de concevoir le problème de rendre les ordinateurs plus intelligents. Un agent est intelligent parce qu'il a des connaissances opérationnelles (pas nécessairement sous une forme verbale explicite), qui lui permettent d'effectuer certaines tâches ou de répondre à certaines questions sur un certain domaine.

L'objectif de l'apprentissage est de fournir une méthode au réseau, afin qu'il puisse ajuster ses paramètres lorsqu'on lui présente des exemples à traiter. On distingue habituellement trois types d'apprentissage : supervisé, non supervisé et hybride.

En effet les réseaux de neurones ont été appliqués avec succès à l'apprentissage de tâches de classification et d'approximation de fonctions. L'apprentissage est le processus d'adaptation des paramètres d'un système pour donner une réponse désirée à une entrée ou stimulation quelconque.

### II.8.1 Principe de l'algorithme d'apprentissage :

Il y a plusieurs algorithmes d'apprentissage pour RNA, le plus utilisé c'est l'algorithme de rétro-propagation. Le signal d'apprentissage est transmis de la couche de sortie vers la couche cachée en suite le signal se retourne à la couche sortie, le processus

est répété d'une manière itératif jusqu'à obtention l'erreur désiré. Les étapes de l'algorithme de rétro-propagation sont :

**-Etape 01** : initialisation des paramètres principales ; les poids ( $W_{kj}, W_{ij}$ ), les biais ( $\theta_k, \theta_j$ ), le taux d'apprentissage ( $\eta$ ) et le moment ( $\alpha$ )

**-Etape 02** : calcul de l'erreur généralisé  $\delta_k$

$$\delta_k = Z_k(1 - Z_k) (d_k - Z_k). \dots\dots\dots (II.2).$$

**-Etape 03** : ajustement des poids entre la couche caché et la couche de sortie

$$\Delta W_{kj}(k+1) = \eta \delta_k y_j + \alpha W_{kj}(k). \dots\dots\dots (II.3).$$

**-Etape 04** : calcule de l'erreur généralisée de la couche cachée

$$\delta_j = y_j (1 - y_j) + \sum_k \delta_k W_{kj} \dots\dots\dots (II.4)$$

**-Etape 05** : ajustement des poids entre la couche cachée et la couche de sortie

$$\Delta W(k+1) = \eta \delta_j y_i + \alpha W_{ji}(k) \dots\dots\dots (II.5)$$

**-Etape 06** : répétez les étapes de 1 à 5 jusqu'à atteindre la valeur d'erreur désirée.

## **II.8.2 Différents types d'apprentissage :**

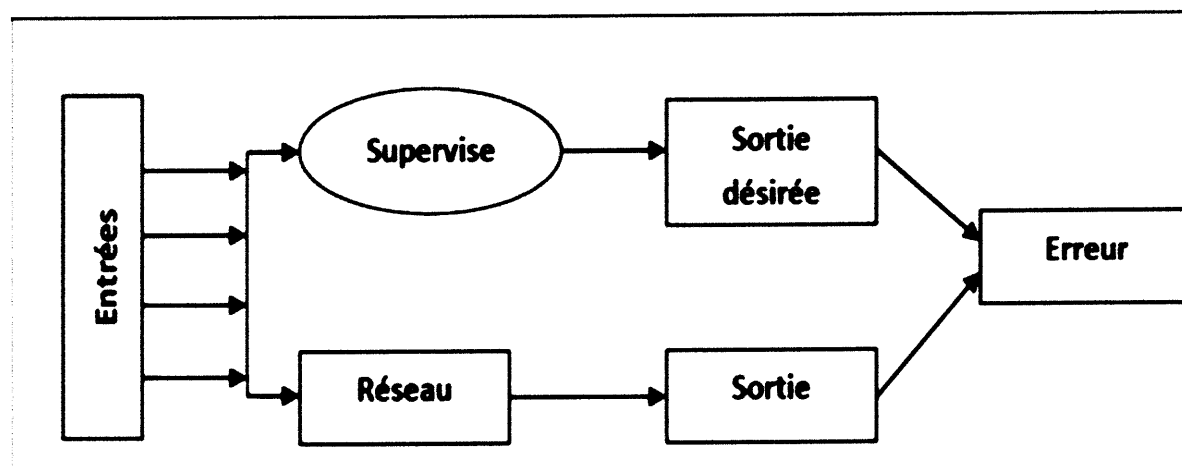
### **II.8.2.1 Apprentissage supervisé :**

Dans l'apprentissage supervise, on présente à l'ordinateur des exemples sous la forme de paires (entrée, sortie et désirée).

Dans ce type d'apprentissage, on fournit au réseau de neurones la donnée à traiter mais aussi la sortie attendue. Le réseau effectue une évaluation de la donnée, puis compare la valeur obtenue avec la valeur désirée, il va ensuite modifier ses paramètres internes afin de minimiser l'erreur constatée. L'apprentissage 'supervise' consiste donc a calculer les coefficients de telle manière que les sorties du réseau de neurones soient, pour les exemples utilises lors de l'apprentissage, aussi proches que possibles des sorties 'désirées', qui peuvent être : la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander. Il est habituel de le présenter en utilisant le paradigme du professeur et de l'élève.

De façon conceptuelle, on admet qu'il existe un professeur qui connaît la relation exacte entre toutes les entrées et leurs sorties, mais le réseau (élève) ne connaît pas cette relation. Si l'élève et le professeur sont exposes a une même entrée, le professeur est capable d'indiquer à l'élève la réponse désirée. Les paramètres (dans le cas des réseaux de neurones, le nombre de neurones et les poids) de l'élève doivent être ajustés pour

donner la même réponse que celle du professeur. Cet ajustement, l'apprentissage, est réalisé en général de façon itérative, en minimisant une mesure de l'erreur, jusqu'à ce que le réseau élève puisse émuler aussi bien que possible le professeur.



**Figure II. 8** Réseau à apprentissage supervisé

La plupart des algorithmes d'apprentissage des réseaux de neurones sont des algorithmes d'optimisation, ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût, qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées.

Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût : le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite méthode de rétro-propagation, puis il est utilisé par l'algorithme d'optimisation proprement dit. Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement, jusqu'à obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de validation, distinct du précédent. Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent : il existe des algorithmes d'optimisation non linéaire extrêmement rapides qui permettent de faire des développements industriels sur de simples PC. Le but fondamental de l'apprentissage est de bien généraliser à de nouveaux cas.

### **II.8.2.2 Apprentissage non supervisé :**

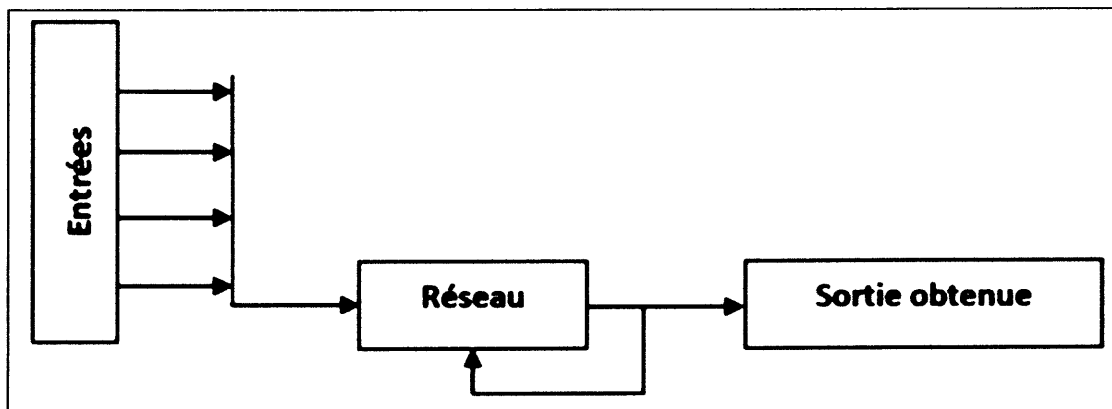
Dans ce type d'apprentissage, aucune information n'est fournie au réseau en plus des données à apprendre. Celui-ci est amené à découvrir la structure sous-jacente des



données afin de les organiser en clusters. L'apprentissage non-supervisé correspond au cas où aucune cible n'est prédéterminée.

Ainsi, l'ensemble d'entraînement ne contient que des entrées et ne définit pas explicitement la nature de la fonction (f) qui doit être retournée par l'algorithme d'apprentissage. C'est plutôt l'utilisateur qui doit spécifier le problème à résoudre. Pour ce problème, (f) doit fournir une estimation de la fonction de densité ou de probabilité de la distribution ayant généré les éléments d'entrées. Pour le problème de la classification les cartes auto-organisatrices de Kohner sont utilisées dans les réseaux de neurones artificiels.

Dans l'apprentissage non supervisé, le réseau modifie ses paramètres en tenant compte seulement des informations locales. Ces méthodes n'ont pas besoins de sorties désirées préétablies. Les réseaux utilisant cette technique sont appelés réseaux à dynamique autonome et sont considérés comme des détecteurs de régularité, car le réseau apprend en détectant les régularités dans la structure des motifs d'entrée et produit la sortie la plus satisfaisante. [22]



**Figure II. 9** réseau à apprentissage non supervisé

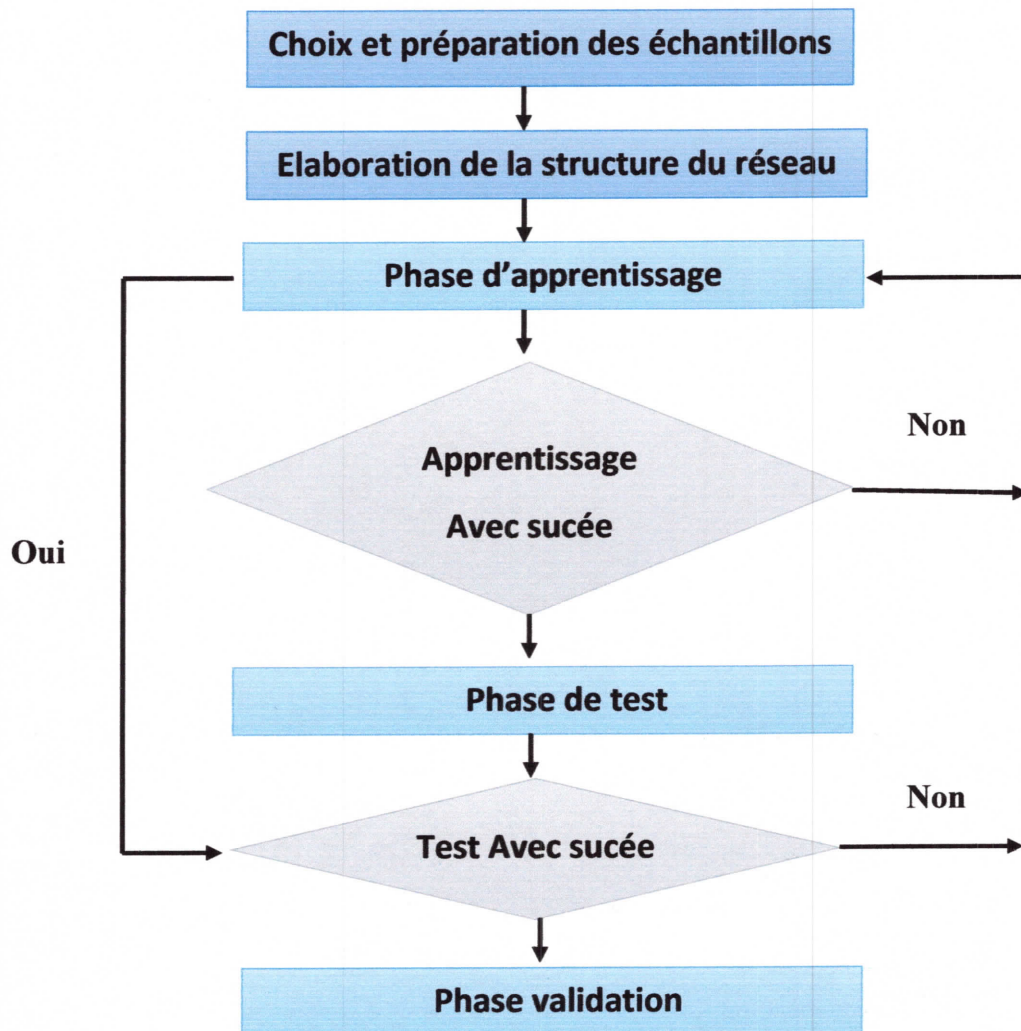
## **II.9 Étapes de la conception d'un réseau de neurone :**

Des programmes de simulation des réseaux de neurones sont disponibles dans le commerce, par exemple ; Neurone Solution, Matlab boxtool, Statistica Neural Network...etc. Pour réaliser un modèle de réseaux de neurones, quatre étapes successives sont nécessaires (voir la figure. II .10).

### **II.9.1 Choix et préparation des échantillons :**

Le processus d'élaboration d'un réseau de neurones commence toujours par le choix et la préparation des échantillons de données. Comme dans les cas d'analyse de

données, cette étape est cruciale et va aider le concepteur à déterminer le type de réseau le plus approprié pour résoudre son problème.



**Figure II. 10** Étapes de conception du réseau de neurones

### **II.9.2 Élaboration de la structure du réseau :**

La structure du réseau dépend étroitement du type des échantillons. Il faut d'abord choisir le type de réseau : perceptron multicouche, réseau de Hopfield, réseau de Kohonen, ARTMAP ...etc. Selon le problème traité ; reconnaissance de forme ou approximation d'une fonction

### **II.9.3 Apprentissage :**

#### **a. Définition**

L'apprentissage est une phase du développement d'un réseau de neurone durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré, l'apprentissage neuronal fait appel à des exemples de comportement. Dans le cas

des réseaux de neurones artificiels on ajoute souvent à la description un modèle de l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt dans la majorité des algorithmes actuels. Les variations L'apprentissage est la modification des poids de réseaux dans le but d'accorder la réponse de ce dernier, il est souvent impossible de décider a priori des valeurs des poids des connexions d'un réseau pour une application donnée. A l'issue de l'apprentissage, des poids sont fixés qui est alors la phase d'utilisation de certains modèles des réseaux, dénommés « l'apprentissage permanent ». Dans ce cas il est vrai que l'apprentissage ne s'arrête jamais.

Ce pendant on peut toujours distinguer une phase d'utilisation (en fait de remise à jour du comportement) et une phase d'utilisation, cette technique permet au réseau de conserver un comportement adapté malgré les fluctuations dans les données. [23]

### **b. Choix du taux d'apprentissage**

Plusieurs solutions ont été proposées pour le choix de taux d'apprentissage ou (le pas d'apprentissage), d'après Freeman on choisit un pas d'apprentissage entre (-0.5 ; 0.25) mais le problème qui se pose à chaque fois c'est le rapport vitesse / complexité qui n'est pas toujours convaincant. L'une des solutions est celle de Brunel qui consiste à adapter le pas afin d'avoir une décroissance régulière de l'erreur quadratique moyenne.

### **c. valeurs initiales des poids**

Les valeurs des poids doivent être différentes de zéro. Si c'était le cas les inconvénients d'adaptation des poids sont nuls. En pratique on choisit aléatoirement les valeurs initiales des poids.

### **d. Test d'arrêt**

En pratique il faut calculer un indice de convergence car on ne peut pas assurer la convergence de l'algorithme pour un nombre d'itérations alors qu'un autre cherche à arrêter l'algorithme si l'erreur est minimale.

### **e. Choix de réseau**

De nombreux travaux théoriques abordent l'approximation des fonctions continues par les réseaux de neurones ce qui a amené à l'application du choix de ne pas pouvoir savoir la taille exacte du réseau pour un problème donné.

## **II .10 Application des Réseaux de Neurones :**

Se trouvant à l'intersection de différents domaines (informatique, électronique, science cognitive, neurobiologie et même philosophie), l'étude des réseaux de neurones est une voie prometteuse de l'Intelligence Artificielle, qui a des applications dans de nombreux domaines :

- Industrie : contrôle qualité, diagnostic de panne, corrélations entre les données fournies par différents capteurs, analyse de signature ou d'écriture manuscrite...
- Finance : prévision et modélisation du marché (cours de monnaies...), sélection d'investissements, attribution de crédits...
- Télécommunications et informatique : analyse du signal, élimination du bruit, reconnaissance de formes (bruits, images, paroles), compression de données...
- Environnement : évaluation des risques. [12]

## **II .11 Conclusion :**

Pour l'implémentation d'un réseau de neurones pour une application donnée, il faut tout d'abord étudier le problème posé afin de valider son adaptabilité à une résolution par des réseaux de neurones et précisant les objectifs à atteindre. Par la suite, il faut analyser la technique des réseaux de neurones (qui englobe le choix du type de réseau et celui de son implémentation en fonction des caractéristiques du problème étudié). A cet effet, le présent chapitre a été consacré à la présentation de la théorie des réseaux de neurones, en partant du neurone biologique, jusqu'à l'étude des différents types de réseaux, le principe d'apprentissage et l'algorithme de rétro-propagation du gradient.

Dans ce contexte, il a été constaté que les réseaux multicouches (**feed forward**) correspondent bien à notre cas d'application. En effet, les réseaux de neurones multicouches entraînés par l'algorithme de rétro-propagation du gradient sont aujourd'hui les modèles les plus utilisés en diagnostic et en surveillance des lignes de production en raison de leur capacité à résoudre les problèmes de classification.

Par ailleurs, pour obtenir une surveillance efficace et un bon diagnostic d'une ligne de production en basant sur les données issues par les capteurs fait l'objet de notre travail. Pour cela il est nécessaire de déterminer un modèle neuronal permettant de représenter les diverses situations de fonctionnement (bon et mauvais fonctionnement).

**CHAPITRE III**  
**Partie Expérimentale**

**III.1 Introduction :**

Dans ce chapitre, nous avons appliqué les méthodes de l'analyse vibratoire sur des signaux vibratoires réels recueillis sur un banc d'essais des défauts d'engrenages à quatre mode de fonctionnement (le premier présente une dent sans défaut, la deuxième dent légèrement usée, la troisième dent sévèrement usée et la quatrième dent arrachée) délivrer par le laboratoire de l'université de Tabriz, IRAN.

D'après l'acquisition des signaux réels à partir des méthodes classiques (temporelle et fréquentielle), nous allons extraire les indicateurs qui seront utilisés directement dans la construction de la base de données.

Les deux ensembles (les indicateurs temporelle et fréquentielle) sont stockés sous forme matricielle qui est utilisée comme entrée au classificateur du réseau de neurones artificiels de type perceptron multicouches (PMC), une partie de cette matrice est utilisée pour l'apprentissage est l'autre partie pour le test et la validation.

En fin, nous discutons les résultats qui sont obtenus dans cette étude.

**III.2 Déroulement de la classification par les RNAs :**

Le diagnostic des différents défauts d'une machine par la méthode des réseaux de neurones artificiels se fait selon l'organigramme de la figure (III.1). [24]

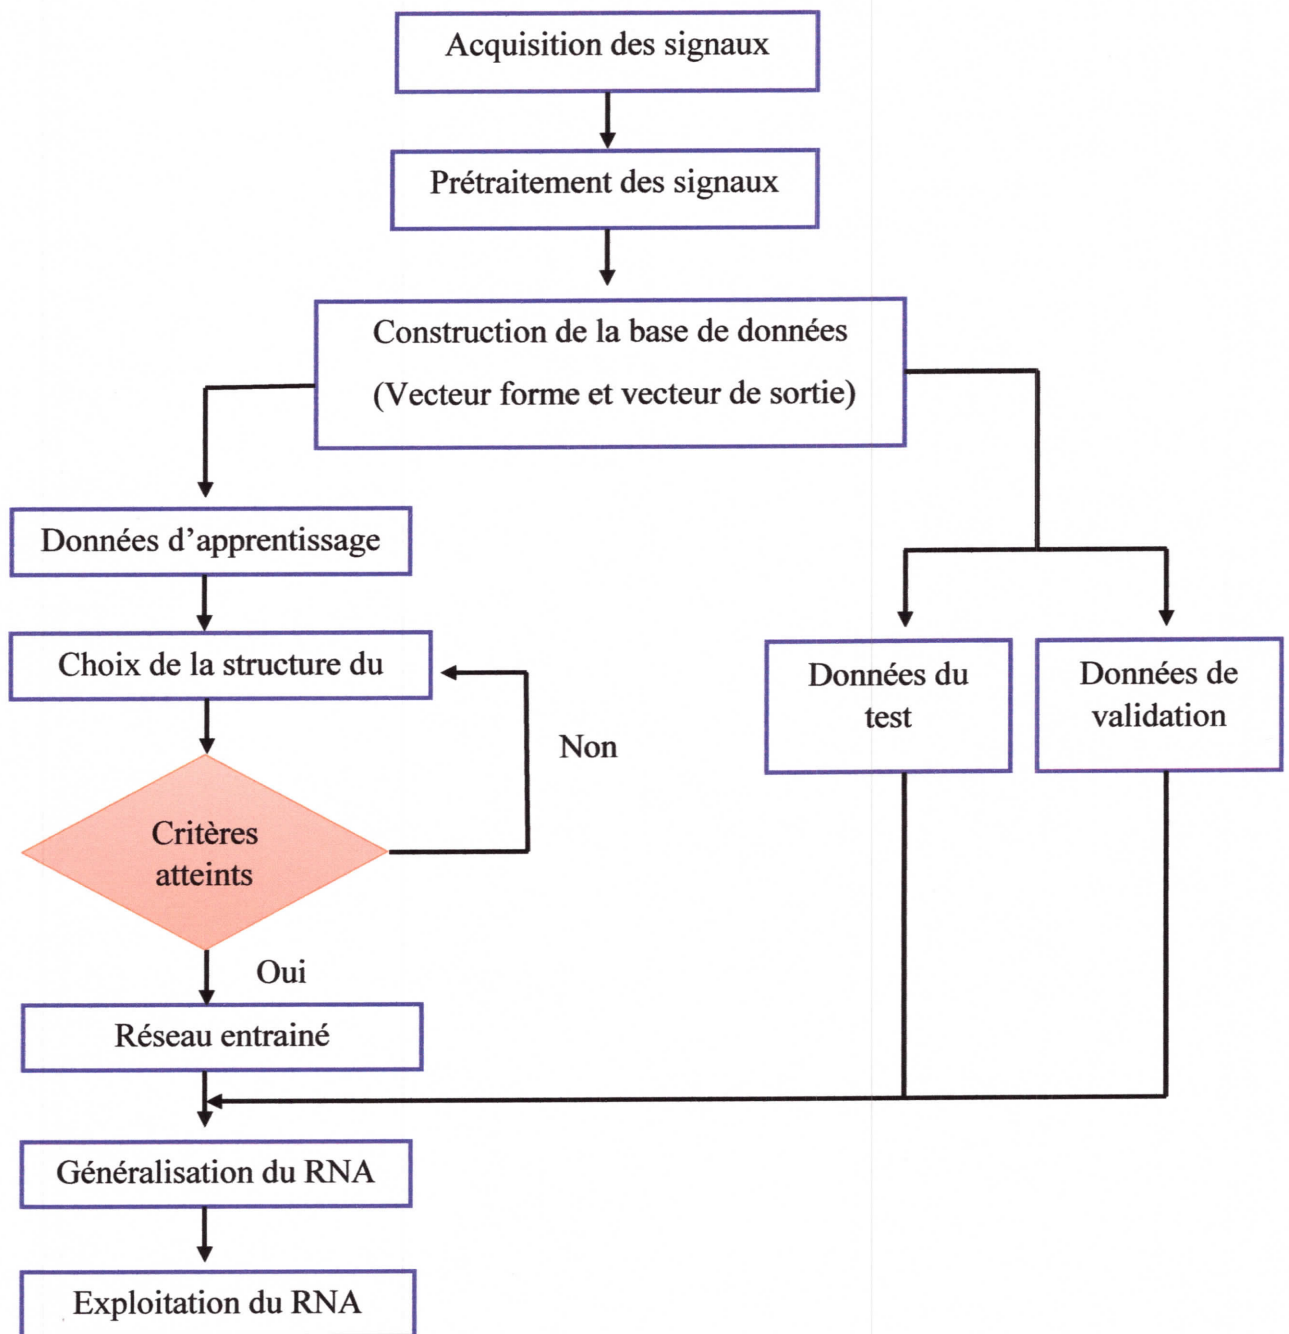


Figure III. 1 Déroulement de la classification par les RNAs.

### III.2.1 Extraction d'indicateurs :

Il s'agit principalement, dans cette étape, d'extraire et de mettre sous forme explicite l'information contenue dans le signal.

### III.2.2 Construction de la base de données (BD) :

L'étape d'extraction des indicateurs nous a permis d'avoir une matrice de données formée par les deux ensembles précédents (temporel et fréquentiels), et qui est utilisée

comme entrée au classificateur (PMC). Les deux ensembles sont stockés sous forme matricielle de type observations/indicateurs de la forme suivante :

$$BD = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1M} \\ x_{21} & x_{22} & \dots & x_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{NM} \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix}$$

Où M est le nombre d'indicateurs, N est le nombre d'observations

On a alors N observation (signaux), représentées en lignes et M indicateurs, représentés en colonnes. Ces matrices seront divisées en  $N_c$  classes ( $w_1, w_2, \dots, w_{N_c}$ ) Chaque classe  $w_i$  possède  $N_i$  observations.

### **III.2.3 Apprentissage :**

L'apprentissage est la propriété la plus intéressante des réseaux de neurones. Cette phase a pour but de déterminer les paramètres des connexions. L'apprentissage comporte l'acquisition de connaissances la préparation des exemples d'apprentissage et la détermination du nombre de couches cachées et le nombre de neurones dans chaque couche. L'apprentissage du réseau est effectué sur une partie des données (généralement 60%).

### **III.2.4 Validation et Tests :**

Une fois l'architecture du réseau de neurones est choisie, La phase test consiste à vérifier les performances du réseau déterminé lors de la phase d'apprentissage et sa capacité de généralisation. La validation est parfois utilisée hors de l'apprentissage, mais pour la phase de test, dans le cas général, une partie de l'échantillon est écartée de l'échantillon d'apprentissage et conservée pour les tests. On peut par exemple utiliser 60% de l'échantillon pour l'apprentissage, 20% pour le test et 20% pour la validation.

### **III.2.5 Exploitation du réseau :**

Après la détermination de la configuration optimale du réseau, ce dernier devient capable à classer d'autres états de la machine et décide l'existence ou non des défauts.

## **III.3 Implémentation des RNAs sous MATLAB :**

### **III.3.1 Création du réseau :**

Pour créer un réseau de neurone artificiels de type PMC, on utilise la commande **nprtool** (Neural Pattern Recognition Tool).



### III.3 Implémentation des RNAs sous MATLAB :

#### III.3.1 Création du réseau :

Pour créer un réseau de neurone artificiels de type PMC, on utilise la commande `nprtool` (Neural Pattern Recognition Tool).

La figure III.2 présente le lancement de la boîte d'outils Neural Pattern Recognition.


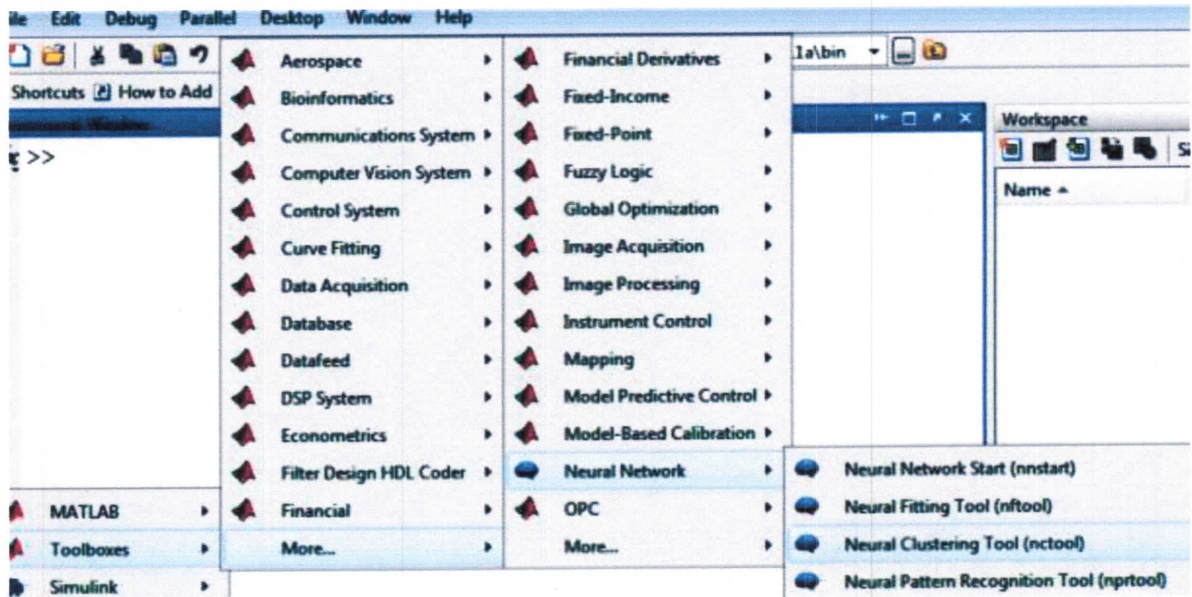


Figure III. 2 Lancement de la boîte d'outils Neural Pattern Recognition Tools.


#### III.3.2 Apprentissage du réseau :

Après la division des données en trois parties (apprentissage, test et validation). On procède à l'apprentissage du réseau qui se fait avec l'onglet train.

### III.4 Description du Banc d'essai d'engrenage :

Les essais ont été effectués sur un banc d'essais à l'université de Tabriz, (IRAN) Ce banc d'essai est composé d'une boîte de vitesses, un moteur électrique, un mécanisme de charge, un système multicanal d'analyseur d'impulsion, un accéléromètre triaxial, un tachymètre, et quatre amortisseurs sous la base du banc d'essai (Figure III.3).

le premier est considéré sans défauts (SD), le second présente une usure légère (UL) sur une dent, le troisième est affecté par une usure sévère (US) sur une dent, tandis que le quatrième présente une dent complètement arrachée (DA) (Figure (III.3).C et D). [25]



**Figure III. 3** (A) Banc d'essai, (B) position de l'accéléromètre triaxial (direction : xx radiale verticale, yy radiale horizontale, zz axiale), (C) dent cassée (D) dent sévèrement usée.

L'arbre d'entrée est entraîné par un moteur électrique à courant continu asservi en vitesse de rotation. L'arbre de sortie est relié à un frein pour générer un couple résistant. Pour enregistrer les signaux vibratoires, un accéléromètre triaxial est monté radialement, sur le palier de l'arbre d'entrée (Figure III.3.B).

La fréquence d'échantillonnage des voies accélérométriques est de  $f_s = 16384$  Hz. La vitesse de rotation nominale durant ces essais est fixée à  $N_{rot} = 1420$  tr/min, soit une fréquence de  $f_{r_1} = 23.67$  Hz, en exerçant un couple résistant constant. Les durées d'acquisition sont réalisées sur 95 tours de l'arbre d'entrée, soit un temps d'acquisition de 4s.

d'acquisition sont réalisées sur 95 tours de l'arbre d'entrée, soit un temps d'acquisition de 4s.




Figure III. 4 Schéma cinématique.


### III.5 Présentation des Signatures vibratoires :

Nous avons représenté dans cette partie les signaux dans les domaines temporels et fréquentielles pour les quatre modes de fonctionnement : sans défaut (SD), usure légère (UL), usure sévère (US) et dent arrachée (DA), et nous disposons seulement des signaux de la direction xx.


#### III 5.1 La méthode temporelle :

##### III 5.1.1 Présentation les signaux temporels :


La figure (III.5) représente les signaux temporels des quatre modes de fonctionnements (SD, UL, US, et DA) suivant la direction xx.




(A)



(B)



(C)



(D)

Figure III. 5 les signaux temporels pour quatre cas de fonctionnements ((A) SD, (B) UL, (C) US, et (D) DA) suivant la direction xx.

Cas UL	26.0357	3.8221	206.7155	2.8098	-0.02
Cas US	32.8673	4.3308	265.9600	3.0903	-0.18
Cas DA	52.00	13.00	1493.4	38.20	-0.098

Tableau III. 1 les indicateurs temporels suivant la direction xx.

III.5.1.3 Préparation des données :

Pour avoir suffisamment de données, nous avons divisé chaque signal en 7 tranches de 2048 points, le nombre d'échantillons pour chaque tranche doit être suffisamment grand, pour couvrir un nombre suffisant du plus grand cycle correspondant à la plus grand période (la plus petite vitesse de rotation).

La figure (III.6) présente la position de la des harmoniques en (Hz) pour le cas théorique dans un spectre de puissance.




Figure III. 6 la position des harmoniques.

Le tableau III.2 présente les valeurs de la fréquence d'engrènement et ses harmoniques

Fréquence d'engrènement [Hz]	1ère har	2ème har	3ème har	4ème har	5ème har	6ème har	7ème har	8ème har
698.5	1397	2095.5	2794	3492.5	4191	4889.5	5588	6286.5
La fréquence d'engrènement : $f_e = fr_1 \cdot Z1 = fr_2 \cdot Z2$								

Le tableau III.2 présente les valeurs de la fréquence d’engrènement et ses harmoniques

Fréquence d’engrènement [Hz]	1ère har	2ème har	3ème har	4ème har	5ème har	6ème har	7ème har	8ème har
698.5	1397	2095.5	2794	3492.5	4191	4889.5	5588	6286.5
La fréquence d’engrènement : $f_e = fr_1 \cdot Z1 = fr_2 \cdot Z2$								

Tableau III. 2 Fréquence d’engrènement et ses harmoniques.

**III.5.1.4 Représentation la variation des indicateurs temporels pour différent états des défauts 1 (SD), 2 (UL), 3 (US), et 4 (DA) :**

La figure III.7 représente le RMS en fonction de différents défauts d’engrenages, RMS = 52 de défaut 4 (DA) est supérieure que les RMS d’autres défauts. Il est sensible à la forme du signal.




Figure III. 7 L’évolution de la valeur efficace pour différents défauts

La figure III.8 représente le facteur crête en fonction de différents défauts d’engrenage, Fc = 13 de défaut 4 (DA) est supérieure que les autres défauts. Alors le Fc est sensible au défaut DA.




Figure III. 8 L'évolution du facteur de crête pour différents défauts.

La figure III.9 représente le kurtosis en fonction de différents défauts. En remarque que le kurtosis (38.20) de défaut 4 (DA) est supérieure que le kurtosis des autres défauts, alors le kurtosis sensible au défaut (DA).




Figure III. 9 L'évolution du Kurtosis pour différents défauts.

Le kurtosis apparaît comme étant l'indicateur le plus approprié à la détection des défauts des engrenages. Il voit sa sensibilité limitée en particulier si le nombre de défauts augmente.

Par ailleurs il reste sensible à la bande de fréquence du signal et la taille du défaut. Le facteur de crête est moins sensible que le kurtosis, pas autant que le RMS qui se montrent d'autant plus sensibles aux amplitudes du signal et pas à sa forme, ce qui ne les place pas comme des indicateurs privilégiés.

### III.5.2 La méthode fréquentielle :

Les figures ci-dessous représentées les spectres des signaux dans les quatre cas de fonctionnements, dent sans défauts SD (FigIII.10), dent avec usure légère UL (FigIII.11), dent avec usure sévère US (FigIII.12), et dent arrachée DA (FigIII.13) suivant la direction xx.

Théoriquement, si la denture est correcte et si aucun phénomène parasite ne vient perturber l'engrènement, le spectre vibratoire est constitué de raies dont les fréquences correspondent à la fréquence d'engrènement  $f_{eng}$  et à ses harmoniques. L'amplitude de la composante fondamentale d'engrènement dépend de la portée et croît avec le couple à transmettre.

Les efforts générés par l'engrènement sont :

- uniquement radiaux pour les engrenages parallèles, à denture droite ou à chevrons.
- mixtes (radiaux et axiaux) pour engrenages à denture hélicoïdale, les engrenages coniques et les engrenages à roue et vis sans fin.

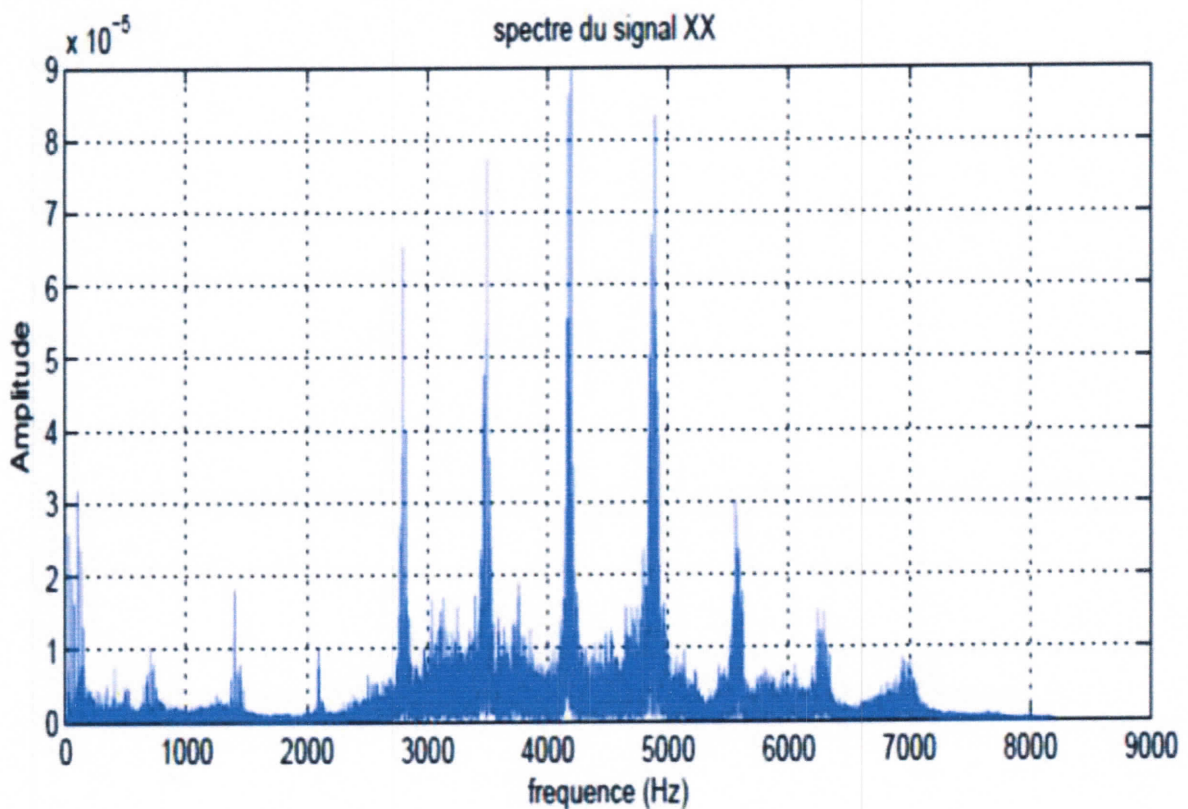



Figure III. 10 Représentation spectrale du signal SD, direction xx.




Lorsque l'ensemble de la denture est usé ou détérioré, les chocs se produisent à l'engrènement de chaque dent. Le spectre est constitué d'un peigne de raies de faible étendue spectrale (choc « mou ») dont le pas correspond à la fréquence d'engrènement, mais cette fois avec une amplitude beaucoup plus élevée que le cas sans défaut (SD).



**Figure III. 11** Représentation spectrale du signal UL, direction xx.

L'évolution de l'amplitude des fréquences d'engrènement par rapport au cas précédent UL est beaucoup plus significative de la dégradation que la seule présence (normale) de ces fréquences dans le spectre. Le défaut sera beaucoup plus facile à identifier dans le cadre d'une surveillance que dans le cadre d'un diagnostic isolé. Le suivi pondéral des particules métalliques contenues dans le lubrifiant permettra souvent de confirmer le diagnostic.



**Figure III. 12** Représentation spectrale du signal US, direction xx.

Si l'engrenage présente une dent arrachée, il se produit un choc périodique dont la cadence de répétition correspond à la fréquence de rotation de la roue possédant la denture altérée.

Le spectre correspondant est donc constitué, non seulement des composantes d'engrènement comme précédemment LU et US, mais aussi et surtout, d'un peigne de raies dont le pas correspond à la fréquence de rotation de l'élément altéré, souvent plus facile à mettre en évidence à l'aide d'une analyse cepstrale.




Figure III. 13 Représentation spectrale du signal DA, direction xx.

**III.6 Automatisation par RNA :**

Nous avons choisi de calculer les indicateurs suivants : la valeur efficace, le facteur de crête, la valeur crête à crête et le kurtosis, le skewness, et les moments d'ordre supérieur. Ces indicateurs peuvent être des bons indicateurs de surveillance dans le cas des engrenages.

Le tableau III.3, nous donne tous les paramètres du vecteur forme :

Indicateurs	Domaine	Dénomination
1	Temporel	Valeur efficace (RMS)
2		Facteur crête
3		Valeur crête à crête
4		Kurtosis
5		Skewness
6		Moment D'ordre 5
7		Moment D'ordre 6
8		Moment D'ordre 7

9	Fréquentiel	Valeur Max
10		Valeur Min

Tableau III. 3 Paramètres du vecteur forme.

### a) Choix des classes (Sortie du RNA)

Le vecteur de sortie du réseau contient les différentes classes correspondant aux différents états de fonctionnement du dispositif expérimental. Nous avons choisi quatre Classes, chacune d'elles correspond à un cas du défaut. Le Tableau III.4 représente l'étiquetage des différentes classes étudiées :

Classes	Cas du défaut	Etiquette
1	Sans défaut (SD)	1000
2	L'usure légère (UL)	0100
3	L'usure sévère (US)	0010
4	Dent arrachée (DA)	0001

Tableau III. 4 Etiquetage des classes.

### b) Configuration du RNA

Nous avons créé un code sous l'environnement MATLAB qui nous permet de créer, tester et de valider le réseau PMC, en utilisant différents paramètres et configurations décrit dans le tableau III.5.

Paramètre	Configuration	Commentaires
Nombre de couche cachée	1	—
Nombre de neurone dans la couche de sortie	4	Correspondant aux différentes classes
Fonction de transfert pour la couche cachée	<i>tansig</i>	Tangente sigmoïde
Fonction de transfert pour la couche de sortie	<i>Purelin</i>	Linéaire

Type d'apprentissage	Rétropropagation du gradient	Basé sur l'Algorithme de Levenberg Marquardt, avec pour fonction <i>Trainlm</i>
Fonction de performance	<i>mse</i>	Erreur moyenne quadratique

Tableau III. 5 Les paramètres et configuration du PMC.


### III.7 Effet du nombre des neurones cachés dans la couche cachée :

Pour étudier l'effet du nombre des neurones cachés dans la couche cachée sur la performance du réseau, on a effectué 12 essais, en variant ce nombre dans suivant le tableau III.6, qui résume les résultats obtenus :

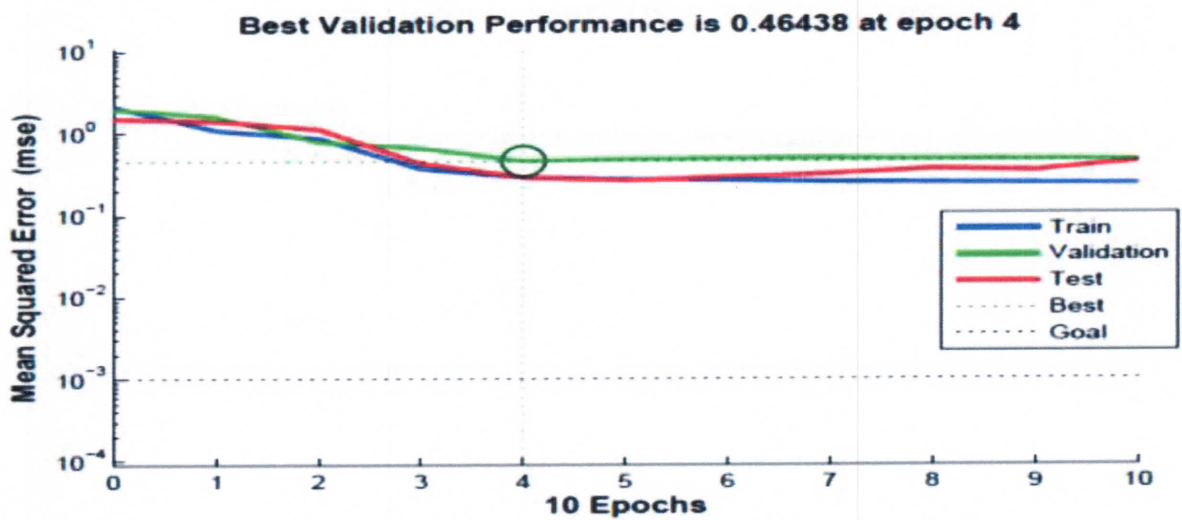
Réseau	nombre des neurones cachés dans la couche cachée	Performance
1	1	0.5337
2	2	0.3186
3	3	0.5749
4	4	0.2894
5	5	0.0793
6	6	0.2647
7	7	0.0505
8	8	0.5322
9	9	0.2289
10	10	0.2747
11	15	0.1220
12	20	0.3008

Tableau III. 6 Performance du nombre des neurones cachés dans la couche cachée.


Les figures de 1 à 12 ci-dessous correspondent à la variation des performances d'apprentissage \ test \ validation en fonction du nombre des neurones cachés dans la couche cachée.




(1)




(2)




(3)




(4)




(5)




(6)



(7)




(8)




(9)






(10)



(11)



(12)

**Figure III. 14** Variation des valeurs de performance en fonction du chaque nombre des neurones cachés dans la couche cachée.

La performance (erreur) prend la valeur minimale de 0.0505 ce qui correspond au nombre des neurones cachés dans la couche cachée 7. On peut déduire alors, que la meilleure valeur du nombre des neurones cachés dans la couche cachée pour le réseau est de 7.

**III.8 Choix des valeurs des critères d'arrêt :**

Afin de choisir les valeurs des critères d'arrêt, c'est-à-dire définir les valeurs d'itérations maximales, et les valeurs de l'erreur minimale pour lesquelles on obtient la meilleure performance de classification, nous avons testé plusieurs valeurs pour chaque critère.


**III.8.1 Erreur Minimale :**


Pour étudier l'effet de l'erreur minimale sur la performance du réseau, on a effectué 4 essais, à la différence qu'on a variée l'erreur dans l'intervalle,  $[10^{-4}, 10^{-1}]$ , Le tableau III.7 résume les résultats obtenus :

Réseau	Erreur Minimale	Performance
1	$10^{-1}$	0.0681
2	$10^{-2}$	0.0133
3	$10^{-3}$	0.3270
4	$10^{-4}$	0.2660


**Tableau III. 7** Performance de l'erreur minimale.

Les figures ci-dessous correspondent à la variation des observations d'apprentissage \ test \ validation en fonction de l'erreur minimale.






(2)



(3)



(4)

Figure III. 15 Variation des valeurs de performance en fonction de l'erreur minimale.

Pour une erreur de  $10^{-2}$  on obtient la meilleure performance soit 0,0133 alors On peut dire que la valeur de l'erreur qui donne la meilleure performance (l'erreur minimale) est  $10^{-2}$ .


**III.8.2 Nombre d'itération maximale :**

Pour étudier l'effet du nombre maximal d'itération sur la performance du réseau, on a effectué 6 essai, en variant ce nombre dans un intervalle de [10, 2000]. Le tableau III.7 résume les résultats obtenus :


Réseau	Nombre max d'itération	Performance
1	10	0.2625
2	50	0.3585
3	100	0.1356
4	500	0.0273
5	1000	0.7292
6	2000	0.2787

**Tableau III. 8** Performance du nombre max d'itération.

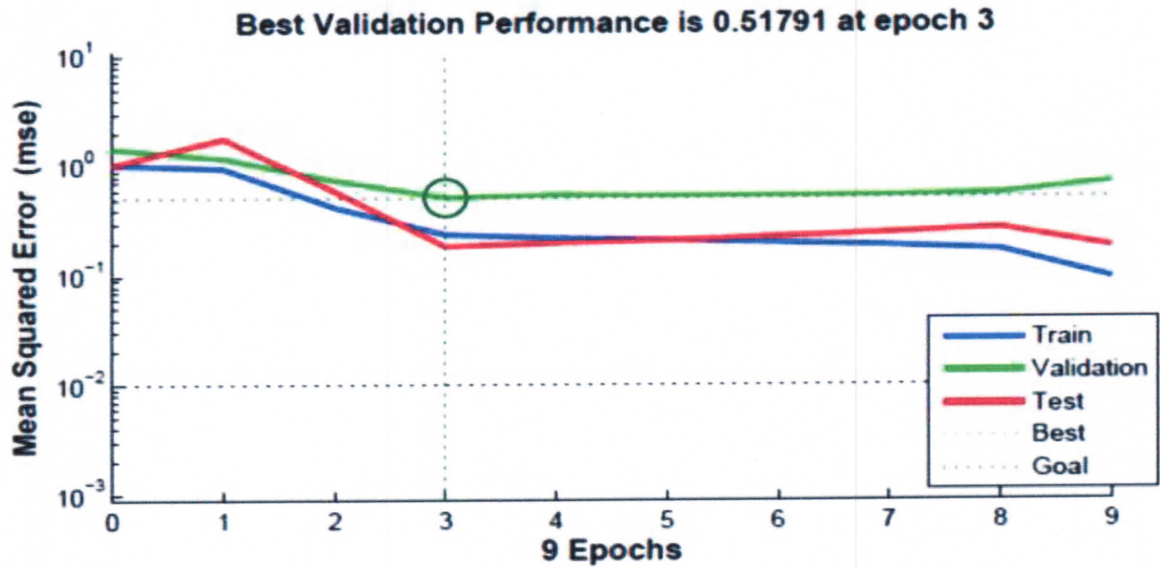
Les figures de 1 à 6 ci-dessous correspondent à la variation des performances d'apprentissage \ test \ validation en fonction du nombre maximal d'itération.




(1)




(2)




(3)



(4)



(5)



(6)

**Figure III. 16** Variation des valeurs de performance en fonction de chaque nombre d'itération maximal.

La performance (erreur) prend la valeur minimale de 0.0273 ce qui correspond à la valeur maximale 500, on peut déduire alors, que la meilleure valeur du nombre maximal d'itération pour le réseau est de 500.

### **III.9 Conclusion :**

L'analyse vibratoire consiste à utiliser des indicateurs de niveau de vibration pour détecter les cas de fonctionnement normal et anormal d'un engrenage.

Dans ce chapitre, nous avons appliqué la méthode de l'analyse vibratoire sur des signaux vibratoires réels recueillis sur un banc d'essais des défauts d'engrenages à quatre modes de fonctionnement (dent sans défaut (SD), dent légèrement usée (UL), dent sévèrement usée (US) et dent arrachée (DA)).

La capacité des réseaux de neurones à stocké l'information sous forme des poids de connexion d'une manière itérative par minimisation de l'erreur, c'est-à-dire le processus d'apprentissage, rend le comportement des réseaux de neurones similaire à l'esprit humain (les réseaux de neurones sont une intelligence artificiel).

Finalement, nous avons présenté les différents résultats obtenus lors de l'utilisation du réseau de neurones perceptron multicouches (PMC) à l'automatisation du diagnostic des défauts des engrenages.

## **Conclusion Générale**



## **Conclusion générale :**

La surveillance des engrenages par l'analyse vibratoire est parmi les préoccupations les plus primordiales et pour chercheurs ainsi que les industriels et ce pour l'apport qu'elle fournit de façon continue. Le contrôle des engrenages et leur surveillance se fait par l'acquisition d'un signal quelconque, qui par la suite, sera comparé à un seuil de la valeur d'un indicateur issue d'un traitement extrêmement simple du même signal vibratoire.

Aujourd'hui, la surveillance par l'analyse vibratoire est mieux connue, mieux appliquée, et connaît un nouvel essor et s'implante de plus en plus dans des secteurs industriels de plus, et cela grâce au développement des techniques modernes du traitement du signal.

Outre les possibilités offertes par ces techniques au niveau du diagnostic de l'état de l'engrenage permettant de définir des indicateurs de surveillance très sensibles pour la détection et le suivi d'un certain nombre de défauts. Ces indicateurs permettent la mise en évidence à un stade précoce, le suivi de l'évolution des défauts en temps réel par ordinateur tels que le jeu d'accouplement, l'écaillage, la fissure, et l'usure de dents d'engrenage...etc., qui sont inaccessibles aux indicateurs classiques de la surveillance vibratoire.

L'utilisation de ces indicateurs (temporels et fréquentiels) dans la construction de la base de données, qui est utilisée comme entrée dans le réseau de neurone artificiel de type perceptron-multi-couches (PML), est donner des bons résultats pour l'automatisation du diagnostic des défauts des engrenages, et leur classification des différents défauts de ce dernier, que durant de cette étude.

## Références Bibliographiques

- [1] Khelf Ilyes, «diagnostic des machines tournantes par les techniques de l'intelligence artificielle,» Thèse de doctorat de l'université de Annaba, 2014.
- [2] Rahmune Chemseddine, «analyse et traitement du courant statorique pour la détection des défauts dans les systèmes électromécanique,» Mémoire de Magister de l'Université de Boumerdès, Septembre 2011.
- [3] Benmohamed Hanène, «L'étude de l'usure des engrenages par analyse vibratoire,» Mémoire de Magister de l'université de Annaba, 2010.
- [4] Oulmane Abdelhak, «surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant les réseaux de neurones et la logique floue,» Thèse de Doctorat de l'université de Montréal Canada, Juillet 2014.
- [5] Djebili Omar, «contribution à la maintenance prédictive par analyse vibratoire des composants mécaniques tournants, application aux butées à billes à soumises à la fatigue de contact de roulement,» Thèse de Doctorat de l'université de Boumerdès , 2013.
- [6] Mohamed el Badaoui, «contribution au diagnostic vibratoire des réducteurs complexes à engrenages par l'analyse cepstrale,» Les sciences de technologie de l'université Jean Monnet, Saint-Etienne, la France , 1999.
- [7] Mr. Touafek Ishak, «Extraction d'indicateurs robustes pour le diagnostic des défauts,» Mémoire de Magister de l'universite de Ferhat Abbas Sétif.
- [8] Boufrioua Youcef, «Les statistiques d'ordre supérieur : théorie et application. » Mémoire de Magister, Université constantine 1. 2013
- [9] Amani Raad, «contributions aux statistiques cycliques d'ordre supérieur application au diagnostic des défauts d'engrenage,» Thèse de Doctorat de l'université de Technologie de Compiègne, Novembre 2003.
- [10] «[http:// franck-dernoncourt. developpez.com/tutoriels/algo/introduction-logique-floue](http://franck-dernoncourt.developpez.com/tutoriels/algo/introduction-logique-floue)».
- [11] Mohamed Djouada, Ridha Ziani, Ahmed Felkaoui, Rabah Zegadi, «diagnostic des défauts par un couplage réseaux de neurones artificiels-algorithmes génétiques,» Université Ferhat Abbas Sétif , Novembre 2007.
- [12] Nicolas Durant, «algorithmes génétiques et autres outils d'optimisation appliqués à la gestion de trafic aérien », Octobre 2004.
- [13] Khellat-Kihel Souad, «Les séparateurs a vaste marge Bi-classes,» Université d'Oran Usto M.B. 2011-2012.

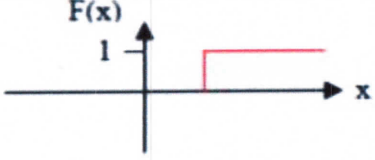
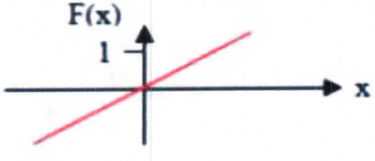
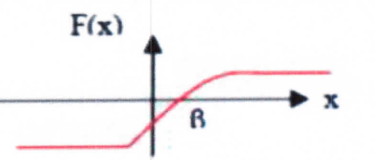
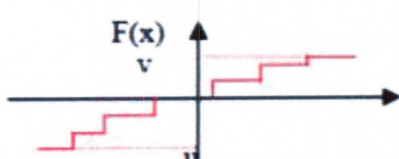
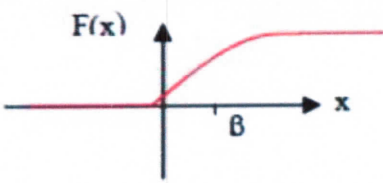
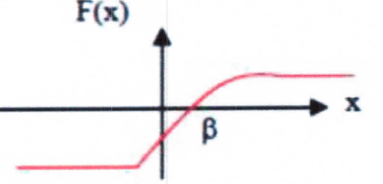
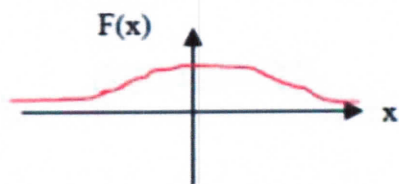
- [14] Djedi Sara, «Etude comparative de PCA et KPCA associées au SVM en biométrie,» Mémoire de fin d'études en vue de l'obtention du diplôme Master, l'université de Mohamed Khider Biskra, Juin 2012.
- [15] Medoued Ammar, «Surveillance et diagnostic des défauts des machines électriques : Applications aux moteurs asynchrones,» Thèse de doctorat en sciences en électrotechnique, Université de 20 Aout 1955, Skikda.
- [16] Merzouka Nouressadat, «Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réels : une approche dans l'espace d'état,» l'université de Setif 1, Mémoire de Magister en Electronique , Juillet 2009.
- [17] M. Hammouche Sofiane, «identification d'un modèle fractionnaire à l'aide des réseaux de neurones,» l'université de Mouloud Mammeri, Tizi-Ouzou, Mémoire de Magister en Automatique , Juillet 2012.
- [18] Amrani Mohamed, « surveillance et diagnostic d'une ligne de production par les réseaux de neurones artificiels,» l'université de M'Hamed Bougara-Boumerdes, Mémoire de Magister en Génie mécanique, Avril 2010.
- [19] Medoued Ammar, «Surveillance et diagnostic des défauts des machines électriques : Applications aux moteurs asynchrones,» Thèse de doctorat en sciences électrotechnique, Université de 20 aout 1955, Skikda.
- [20] Merzouka Nouressadat , «Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réels : une approche dans l'espace d'état,» l'université de Setif 1, Mémoire de Magister en Electronique, Avril 2009.
- [21] Ouahib Guenounou, «Méthodologie de conception de contrôleurs intelligents par l'approche génétique-application a un bioprocédé,» Thésé de doctorat , université de toulouse 3, paul Sabatier, avril 2009.
- [22] Kadous Djamila , «Utilisation des réseaux de neurones comme outil du datamining : Génération de modèle comportemental d'un processus physique à partir de données,» l'université de Abou-Bakr de Tlemcen, Mémoire de Master, Juillet 2012.
- [23] Redouane Rebouh, « formation des Bétons avec Ajout par l'Utilisation des Réseaux de Neurones,» l'université de Hassiba Ben Bouali de chalef, Mémoire de Magister en Génie Civil , Décembre 2011.
- [24] Moussa Souad, «étude de l'amélioration des performances des réseaux neurones artificiels appliqués au diagnostic des défauts des roulements,» mémoire de Master, de l'université de Jijel, Juin 2014.

- [25] J Rafiee, F. Arvani, A. Harifi, M.H. Sadeghi, «Intelligent condition monitoring of a gearbox using artificial,» *Mechanical Systems and Signal Processing* 21 (2007) 1746–1754, Department of Electrical Engineering, University of Tabriz, Tabriz, Iran, September 2006.

## ANNEXE 1

### La fonction de transfert (d'activation) :

La fonction de transfert est en général une fonction non linéaire monotone croissante par ailleurs les fonctions de transfert sont de qualités diverses : elles peuvent être déterministes, continues, discontinues ou aléatoires. es fonctions sont présentées dans le tableau suivant :

<p>(a) Fonction de Heaviside</p>	
<p>(b) Fonction linéaire sans saturation</p>	
<p>(c) Fonction linéaire avec seuil</p>	
<p>(d) fonction à seuils multiples</p>	
<p>(e) fonction sigmoïde <math display="block">F(x) = \frac{1}{1 + e^{-x}}</math></p>	
<p>(f) fonction sigmoïde <math display="block">F(x) = \frac{1 - e^{-x}}{1 + e^{-x}}</math></p>	
<p>(g) fonction stochastique</p>	

Les fonctions d'activation.

