



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR

ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITÉ M'HAMED BOUGARA - BOUMERDES

FACULTÉ DES SCIENCES DE L'INGENIEUR

DÉPARTEMENT MAINTENANCE INDUSTRIELLE

MEMOIRE DE MAGISTER

SPECIALITE : GENIE MECANIQUE.

OPTION : MAINTENANCE INDUSTRIELLE.

SOUTENU PAR : Mr AMRANI Mohamed.

-THÈME-

Surveillance et diagnostic d'une ligne de production par les réseaux de neurones artificiels.

Soutenu devant le jury : le 06 avril 2010

BENFDILA Arezki	Professeur	UMMTO	Président
ADJERID Smail	Maitre de conférences (MC)	UMBB	Examineur
MOHAMMEDI Kamel	Maitre de conférences (MC)	UMBB	Examineur
BENAZZOUZ Djamel	Professeur	UMBB	Rapporteur

Année 2010

Abstract

Résumé

Ce travail de recherche présente une modélisation et une simulation de diagnostic et de surveillance en temps réel des équipements stratégiques d'une ligne de production. Le modèle est basé sur les réseaux de neurones artificiels (RNA). L'objectif est de détecter et localiser toute anomalie qui peut survenir dans une machine. L'équipement considéré dans cette étude est une ligne de production pharmaceutique BEKER laboratoire (Dar El Beida-Algérie). La machine qui nous intéresse est un équipement stratégique dans la production. Nous avons défini les zones de bon et de mauvais fonctionnement. A partir de là, la simulation des pannes est possible.

Mots clés : *Intelligence artificielle - réseaux de neurones artificiels - diagnostic industriel - surveillance industrielle - algorithme de rétro-propagation du gradient.*

Abstract

This research work presents a model and a simulation of diagnosis and supervision in real time of strategic equipment in a production line. The model is based on artificial neuronal network.

The objective is to detect and localize any faulty in the machine. The considered equipment is a pharmaceutical industrial line BEKER laboratory factory) (Dar El Beida-Algeria). The considered machine is strategic equipment in the production. We have defined zones of good and bad functioning, from this fact the breakdowns simulation is possible.

Key words: *Artificial intelligence - artificial neuronal network - industrial diagnosis - industrial supervision - back-propagation algorithm.*

ملخص:

نقدم في هذا البحث احدا طرق فحص و مراقبة التجهيزات الأساسية في احد خطوط التصنيع.

حيث تعتمد هذه الكيفية على شبكة من الأعصاب الاصطناعية.

الهدف من الدراسة هو اكتشاف أي خلل و تحديده في أي آلة من آلات خط التصنيع.

التجهيزات التي قامه عليها هذه الدراسة هي تجهيزات خط تصنيع لمؤسسة صيدلانية بيكر- ليوراتوار(دار البيضاء – الجزائر).

و بقصد التمكن من محاكاة تشغيل الخط قمنا بتحديد التجهيزات الأساسية و تحديد المناطق التي تعمل فيها هذه التجهيزات بشكل جيد و المناطق التي تكون فيها أعطال.

الكلمات المفتاحية:

الذكاء الاصطناعي, الشبكة العصبية الاصطناعية, المراقبة الصناعية, خوارزمية الانتشار الخلفي.

Remerciements

Le travail de ce mémoire de magister a été réalisé au sein du Laboratoire de Mécanique des Solides et Systèmes (LMSS) à la faculté des sciences de Boumerdes dirigé par le Pr. A. SERIDI.

J'adresse mes remerciements les plus sincères au Pr. BENAZZOUZ pour avoir accepté de m'encadrer. Ses appréciables conseils m'ont guidé de manière forte tout au long de mon travail.

Je remercie vivement et sincèrement N.SALHI qui n'a ménagé aucun effort pour m'apporter son aide.

Je tiens à témoigner ma reconnaissance envers les cadres de la société pharmaceutique BEKER Laboratoires Der El Beida Alger-Algérie, et en particulier le Directeur Général R.KERRAR qui m'a ouvert les portes de sa direction, et toute l'équipe de maintenance en particulier W.BENRAHMOUN et S.LAFFED pour les considérables efforts qu'ils ont fait à mon égard.

Je remercie toute l'équipe du Laboratoire BEKER pour leur gentillesse et soutien, ce dont je leur suis reconnaissant.

SOMMAIRE

Introduction générale	1
Chapitre I: Généralités sur la surveillance et le diagnostic industriel	
Introduction :	4
1 Concept et terminologie:	4
1.1 Dégradation :	4
1.2 Définition des défauts et pannes.....	4
1.3 Définition de la défaillance :	5
1.4 Classification des défaillances.....	5
1.4.A Classification des défaillances par rapport aux conséquences	5
1.4.B Classification des défaillances en fonction de la vitesse d'apparition	5
1.5 Mode de fonctionnement :	5
2 Notions de bases de la maintenance :	6
2.1 Définition de la maintenance :	6
2.2 Types de maintenance :	6
2.2.1 La maintenance corrective :	6
2.2.2 Maintenance préventive.....	7
2.3 Disponibilité:	8
2.4 Fiabilité :	8
2.5 Maintenabilité :	8
2.6 Sûreté :	8
3 Surveillance :	9
a- La détection.....	9
b- Diagnostic industriel.....	9
4 Causalité :	9
5 Les différentes étapes techniques du diagnostic :	11
5.1 Validation des mesures.....	11
5.2 Méthodes pour la détection et la validation de mesures invalides	12
5.3 Les principales signatures	12
a- Signature vibratoire	12
b- Signature acoustique	13
c- Signature par émission acoustique	13
d- Signature ultrasonore	13

e- Signature par analyse des lubrifiants	13
6 Méthodes du diagnostic	14
6.1 Introduction	14
6.2 Méthodes internes de diagnostic	14
6.2.1 Les méthodes de diagnostic de défaillances par modélisation fonctionnelle	15
6.2.2 Méthode de diagnostic par modélisation physique	15
6.3 Les méthodes externes de diagnosti.....	16
6.3.1 La reconnaissance des formes (RDF).....	17
6.3.2 Diagnostic par logique floue.....	18
6.3.3 Diagnostic par réseaux de neurones.....	19
7 Analyse critique des méthodes de diagnostic existant	19
7 Conclusion	20
Chapitre II : Notions de base des réseaux de neurones artificiels	
Introduction	22
1 Histoire	22
2 Le neurone biologique	24
3 Le neurone artificiel	26
4 Fonction d'activation	26
5 Les réseaux de neurones artificiels :.....	28
5.1 Introduction :.....	28
5.2 Différentes architectures de réseaux de neurones.....	28
a. Réseau multicouche (feed-forward).....	28
b. Réseau à connexion locale	29
c. Réseau à connexion récurrente	29
d. Réseau à connexion complète	30
5.3 Apprentissage	30
a. Définition	30
b. Apprentissage supervisé	31
c. Apprentissage non supervisé	31
d. Choix du taux d'apprentissage	31
e. Valeurs initiales des poids	31
f. Test d'arrêt	32
g. Choix de réseau	32

5.4 Apprentissage des réseaux multicouches	32
5.5 Principe de descente de gradient (propagation de gradient)	32
a. Algorithme de descente de gradient	33
b. Caractéristiques de la rétro-propagation.....	36
5.6 Utilisation d'un terme de moment	37
5.7 Les applications des réseaux de neurones	38
Conclusion	39
Chapitre III : Diagnostic et surveillance d'une ligne de production par les réseaux de neurones artificiels	
Introduction	41
1 Présentation de laboratoire BEKER	41
2 Description des ateliers des laboratoires BEKER	41
3 Le choix de l'équipement à étudier	42
4 Principe de fonctionnement du compresseur d'air	43
5 Légende du schéma d'écoulement/système de régulation du compresseur	45
6 Les paramètres du compresseur d'air	46
7 Argumentation du choix des paramètres	48
7.1 Choix des paramètres du circuit de lubrification	48
7.2 Choix des paramètres du circuit d'air.....	49
8 Modélisation du compresseur d'air :.....	49
9 L'approche neuronale.....	51
10 Type de réseau choisi.....	53
11 Apprentissage du réseau	54
a. Type d'apprentissage	54
b. Principe de l'apprentissage	54
12 Les paramètres d'apprentissage	54
a. L'erreur (goal)	54
b. Le nombre d'itération	54
c. La fonction d'activation	54
d. Le taux d'apprentissage	54
e. Le moment (mc)	55
13 Algorithme de rétro-propagation du gradient	55
14 Simulation de l'apprentissage	56

15 Evaluation des performances des réseaux de neurones	57
Conclusion	58
Chapitre IV : Simulation et résultats	
Introduction	59
1. Partie A : circuit d'huile	59
2. Partie B : circuit d'air	67
2.1. Première phase : <i>détection de défaut</i>	67
2.2. Deuxième phase : <i>localisation de défaut</i>	72
Conclusion	73
Conclusion générale	74
Bibliographie	
Annexes	

Introduction générale

Les systèmes de production ont connu un important développement technologique tout au long de cette décennie. Cette complexité technologique ajoutée à d'autres contraintes économiques incite les industriels à une plus grande attention à la maintenance de leur système de production. Dans l'objectif d'augmenter la disponibilité des installations et d'améliorer la fiabilité des équipements afin de réduire les coûts directs et indirects de la maintenance. Pour se faire, la mise en place de la maintenance préventive est l'une des stratégies actuelles utilisées dans l'industrie. Cette dernière est devenue un vrai métier avec ses propres méthodologies et concepts. Parmi les facteurs qui ont favorisé ce type de la maintenance, la surveillance industrielle et l'automatisation du diagnostic qui sont des tâches les plus importantes qui répondent à cette évolution technologique.

Vu l'importance des enjeux en termes de productivité (arrêt inutile des installations), de sécurité (anomalie non détectée) et de qualité de production (mesure incorrecte d'une grandeur à contrôler), de nombreuses approches ont été utilisées pour apporter une contribution à la solution de ce problème. On distingue cependant, parmi les différentes méthodes, deux familles principales suivantes :

- ❖ Méthodes de surveillance avec modèle,
- ❖ Méthodes de surveillance sans modèle.

Les méthodes qui se basent sur la modélisation de l'équipement sont naturellement tributaires de l'existence ainsi que de la qualité de la modélisation physique de l'équipement. Ce modèle servira de référence pour un fonctionnement nominal et tout écart par rapport au point de fonctionnement nominal sera synonyme de défaillance. L'inconvénient de ces techniques est l'existence d'incertitudes de modélisation qui sont dues au fait que la modélisation physique ne prend pas en considération tous les paramètres et les aléas qui peuvent influencer sur une information d'un paramètre de surveillance. Et plus, la modélisation d'une machine complexe ou d'un procédé entier est le problème le plus délicat à modéliser.

Les méthodes de surveillance sans modèle sont divisées en deux parties. La première partie correspond aux outils statiques et de traitement du signal qui sont généralement qualifiés d'outils de traitement de bas niveau, parce qu'ils sont en contact direct avec le signal capteur, et ne servent généralement que pour la génération d'alarmes brutes, sans aucune information concernant leurs signification. La deuxième partie est celles des techniques dites de haut niveau et qui sont plutôt orientées vers la communication avec l'expert. Celles-ci représentent les techniques de *l'intelligence artificielle (IA)*.

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'IA utilisées 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 la :

- *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,
- *Tolérance aux fautes* ou la sortie du réseau est graduellement dégradée proportionnellement au nombre de neurones manquants.

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 grâce à :

- Leur capacité d'apprentissage,
- Leur parallélisme dans le traitement,
- Leur capacité de faire face à des problèmes inhérents au non linéarité des systèmes.

Suite à notre recherche bibliographique, nous avons rencontré de nombreux travaux réalisés par les réseaux de neurones artificiels dans la surveillance et le diagnostic industriel. Et parmi ces travaux, nous citons les plus récents, tel que les travaux de KHODJA sur le diagnostic automatique des défaillances d'un système électromécanique par application des réseaux de neurones artificiels [1], ZEMOURI sur la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance [2], Marc Parizeau sur le perceptron multicouche et son algorithme de rétro-propagation des erreurs [3], NICOLAS, DANIEL et ZERHOUNI sur les réseaux de neurones temporels, ces travaux consistent à faire une comparaison de trois réseaux de neurones récurrents les plus représentatifs pour des applications de surveillance dynamique et pronostic [4], SOUABI, HACHMAOUI et CHITOUR sur l'utilisation des réseaux de neurones dans le domaine de la chimie afin de caractériser les fractions pétrolières qui sont des mélanges complexes [5], BOUAMAR et LADJAL sur l'utilisation des réseaux de neurones artificiels pour la surveillance des eaux potables [6], MAHDAOUI et MOUSS [7], François Denis Rémi Gilleron, Boris PIERRE-JUSTIN sur la définition et expressivité des réseaux multicouches et l'algorithme de rétro-propagation du gradient [8] et SALHI sur la surveillance et le diagnostic d'une chaîne de production pharmaceutique par les réseaux de neurones [9].

Le travail de recherche de M^{me} SALHI est réalisé au sein de la société pharmaceutique « Laboratoire Pharmaceutique Algérien » (LPA) Boudouaou, en coordination avec laboratoire de maintenance des systèmes mécaniques et solides de l'université de

Boumerdes. Dans l'objectif de surveiller et de diagnostiquer la chaîne de production pharmaceutique.

A la lumière de l'analyse bibliographique effectuée, le travail de recherche de M^{me} SALHI et les avantages de la méthode RNA, nous sommes venus avec une grande motivation et objectivité à appliquer cette méthode pour surveiller et à diagnostiquer notre ligne de production pharmaceutique BEKER Laboratoire (Der El Beida Alger-Algérie). Cet atelier se compose de compresseur d'air qu'est l'équipement le plus stratégique. Pour se faire, nous avons choisi le réseau *feed-forward* multicouches [10], comportant une couche d'entrée, une couche cachée et une couche de sortie. Le choix de ce type d'architecture (3 couches) est arbitraire, la couche cachée est utilisée afin d'extraire plus d'informations à partir des données d'entrée du réseau. Et outre, ce type de réseau de neurones MLP (*Multi Layer Perceptron*) avec retro-propagation de gradient [9], [10] a été choisi pour sa simplicité, son emploi est très vaste dans les systèmes de surveillance et diagnostic.

Le compresseur d'air se compose de deux circuits (circuit de lubrification et circuit d'air) que nous avons surveillé en temps réel avec des valeurs et paramètres réels. Ici les paramètres surveillés sont les pressions et les températures qui sont les indicateurs des pannes du compresseur les plus primordiaux.

Pour mettre en place cette étude, nous avons procédé de la manière suivante :

- Dans le premier chapitre nous présenterons les concepts généraux relatifs à la surveillance et au diagnostic, ainsi que les différentes méthodes utilisées pour la surveillance industrielle et le diagnostic.
- Dans le deuxième chapitre nous décrirons tous les concepts de base relatifs aux réseaux de neurones. Afin de clarifier aux lecteurs cette approche. Nous parlerons des différents types de réseaux, de l'apprentissage et l'algorithme de la rétro-propagation de gradient.
- Le troisième chapitre est une description et une illustration détaillée sur l'approche employée et sur l'atelier que nous avons choisi. Cet atelier est une ligne de production pharmaceutique (compresseur d'air).
- Le quatrième chapitre contient tous les résultats de simulations relatives à la surveillance et au diagnostic de la machine. Nous simulerons l'apprentissage du réseau multicouche et les zones de bon et de mauvais fonctionnement de chaque circuit. Et enfin nous validerons notre travail par des tests pour évaluer le pourcentage de reconnaissance de chaque réseau de neurone que nous synthétiserons au fur et à mesure dans des tableaux.
- Enfin, une conclusion générale est donnée dans laquelle nous discutons les résultats obtenus ainsi que les perspectives qui pourront constituer la suite de notre travail.

Chapitre I : Généralité sur la surveillance et le diagnostic industriel

Introduction

Quand un défaut apparaît dans un processus, il doit être détecté le plus tôt possible. Dans ce cas le système de détection du défaut doit indiquer l'existence d'une anomalie dans les équipements de réalisation du processus. Après la détection, le diagnostic du défaut est exécuté, le défaut est éliminé et sa cause est localisée.

Dans ce contexte et, d'après une étude bibliographique [14, 21, 23, 26, 27], on constate que les techniques utilisées pour la détection et le diagnostic de défaillances sont divisées en deux catégories [26], [27] :

- A partir de modèles physiques ou de comportements validés par les techniques d'identification des paramètres, le diagnostic de défaillance devient possible en suivant en temps réel l'évolution des paramètres physiques ou bien en utilisant l'inversion du modèle de type « boîte noire ».
- Il n'est pas nécessaire de disposer d'un modèle mathématique du processus ; par contre les méthodes retenues reposent sur l'expertise humaine confortée par un solide retour d'expérience ; dans cette catégorie, on retrouve les méthodes basées sur l'intelligence artificielle, parmi lesquelles, nous pouvons citer la reconnaissance des formes, la logique floue et les réseaux de neurones artificiels.

Une autre classification consiste à séparer le diagnostic externe du diagnostic interne [13], [27]. Le diagnostic externe (ou boîte noire), repose sur la connaissance des grandeurs d'entrées/sorties du processus, à savoir : analyse de données, analyse statistique, réseaux de neurones, logique floue, etc.

Le diagnostic interne (dit boîte blanche ou transparente), quant à lui, repose sur des analyses topologiques ou fonctionnelles détaillées des matériels. Citons par exemple : l'analyse des systèmes, l'estimation des paramètres, etc.

1 Concept et terminologie

1.1 Dégradation

Une dégradation représente une perte de performance d'une des fonctions assurée par un équipement. Si les performances sont au-dessous du seuil défini dans les spécifications fonctionnelles de cet équipement, il n'y a plus dégradation mais défaillance.

1.2 Définition des défauts et pannes

Le concept de défaut est important dans les opérations de surveillance et la maintenance des processus industriels.

Un *défaut* est tout écart entre la caractéristique observée sur le dispositif et la caractéristique de référence lorsque celui-ci est en dehors des spécifications.

La *panne* est l'inaptitude d'un dispositif à accomplir une fonction requise.

1.3 Définition de la défaillance

« C'est la cessation de l'aptitude d'un dispositif à accomplir une fonction requise, cette fonction doit être déterminée avec les tolérances associées ». (AFNOR X06-501).

➤ Les causes de défaillance

La norme définit la cause de défaillance par les circonstances liées à la conception, la fabrication ou l'usage qui entraînent la défaillance.

➤ Mode de défaillance

Effet par lequel une défaillance est observée.

➤ Mécanisme de défaillance

Processus physique, chimique ou autre entraîne une défaillance.

1.4 Classification des défaillances

1.4. A Classification des défaillances par rapport aux conséquences

- a) Défaillances mineures : défaillance qui ne réduit pas l'aptitude d'un dispositif à accomplir sa fonction requise.
- b) Défaillances majeures : défaillance qui risque de réduire l'aptitude d'un dispositif à accomplir sa fonction requise.
- c) Défaillances critiques : défaillance qui risque de causer blessures à des personnes ou des dégâts important de matériel.
- d) Défaillances catastrophiques : défaillance qui entraîne des dégâts causant des dommages importants au matériel et à l'environnement.

1.4. B Classification des défaillances en fonction de la vitesse d'apparition

- a) Défaillance soudaine : défaillance qui n'aurait pas pu être prévue par examen ou une surveillance antérieure.
- b) Défaillance progressive : défaillance qui aurait pu être prévue par un examen ou une surveillance antérieure.

1.5 Mode de fonctionnement

Un système présente généralement plusieurs modes de fonctionnement. On peut observer des modes de plusieurs types parmi lesquels :

- **Mode de fonctionnement nominal** : c'est le mode où l'équipement ou le système industriel remplit sa mission dans les conditions de fonctionnement requises par le constructeur et avec les exigences attendues de l'exploitant.
- **Mode de fonctionnement dégradé** : qui correspond soit à l'accomplissement partiel de la mission, soit à l'accomplissement de celle-ci avec des performances moindre. En

d'autres termes, il y a eu dégradation dans l'équipement ou le système mais pas de défaillance.

- **Mode de défaillance** : qui correspond à des mauvais fonctionnements du système, c'est-à-dire qu'il y a eu défaillance soit après dégradation soit défaillance brusque. Un mode de défaillance est caractérisé par les effets causés par cette défaillance. Ces effets peuvent être mesurables ou qualifiables. En faisant une analyse de cause à effet de la défaillance, on peut associer le mode de défaillance à toute cette analyse faite par un expert. En d'autres termes, à chaque mode de défaillance, on associe une décision et une interprétation possible. Chaque équipement ou système peut posséder qu'un seul mode nominal; par contre, il possède plusieurs modes de défaillance.

2 Notions de bases de la maintenance

2.1 Définition de la maintenance

Le terme "maintenance" dans son histoire, forgé sur les racines latines *manus* et *tenere*, est apparu dans la langue française au XII^e siècle. Le terme est réapparu à l'époque moderne dans le vocabulaire des militaires "maintien dans les unités de combat, de l'effectif et du matériel à un niveau constant". Définition intéressante car l'industrie l'a reprise à son compte en l'adaptant aux unités de production affectée à un combat économique.

Selon la norme AFNOR la maintenance est défini comme suit :

«L'ensemble des actions permettant de maintenir ou de rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé ». (NF X60-010).

2.2 Types de maintenance

2.2.1 La maintenance corrective

D'après la norme AFNOR X 60-010 :

C'est une opération de maintenance effectuée après défaillance.

La maintenance corrective est liée à l'ignorance, éventuellement à un défi, son évanescence est contiguë au savoir imprégné des logiques marchandes, donc incertaine. La maintenance corrective s'inscrit aux limites du savoir bousculées par les développements et les créations qui impatientes, ne s'accordant pas toujours à la rigueur d'une recherche et pouvant subir des influences aléatoires.

Elle se décompose en deux types :

a. La maintenance palliative

Est un ensemble d'activités de maintenance corrective destinées à permettre à un bien d'accomplir provisoirement une fonction ou partie d'une fonction, elle est appelée couramment dépannage.

b. La maintenance curative

Est un ensemble d'activités de maintenance corrective ayant pour objet de rétablir un bien dans un état spécifié ou de lui permettre d'accomplir une fonction requise. Le résultat des activités réalisées doit présenter un caractère permanent. Les activités pouvant être des

réparations, des modifications ou aménagement ayant pour objet de supprimer la ou les défaillances.

2.2.2 Maintenance préventive

Dans la définition de la maintenance préventive, sont inclus les inspections, les contrôles, les visites ou rondes systématiques et les interventions de maintenance effectuées.

La maintenance préventive s'oppose en cela à la maintenance corrective déclenchée par des perturbations ou par les événements, et donc subie par la maintenance

La maintenance préventive consiste à suivre l'évolution de l'état d'un organe, de manière à prévoir une intervention dans un délai raisonnable (1 mois, par exemple).

La maintenance préventive se divise à son tour de deux types de maintenance: la maintenance préventive systématique et la maintenance préventive conditionnelle.

a. Maintenance préventive systématique

D'après la norme (AFNOR X 60-10), la maintenance systématique se définit comme "une maintenance effectuée selon des critères prédéterminés dans l'intention de réduire la probabilité de défaillance d'un bien".

b. Maintenance préventive conditionnelle

D'après la norme (AFNOR X 60-10), la maintenance conditionnelle se définit comme "une maintenance préventive subordonnée à un type d'événement prédéterminé (Autodiagnostic, information d'un capteur, mesure d'une usure) révélateur de l'état de dégradation du bien".

Les actions d'exécution consacrées à la réalisation des travaux de maintenance sont regroupées de la manière suivante :

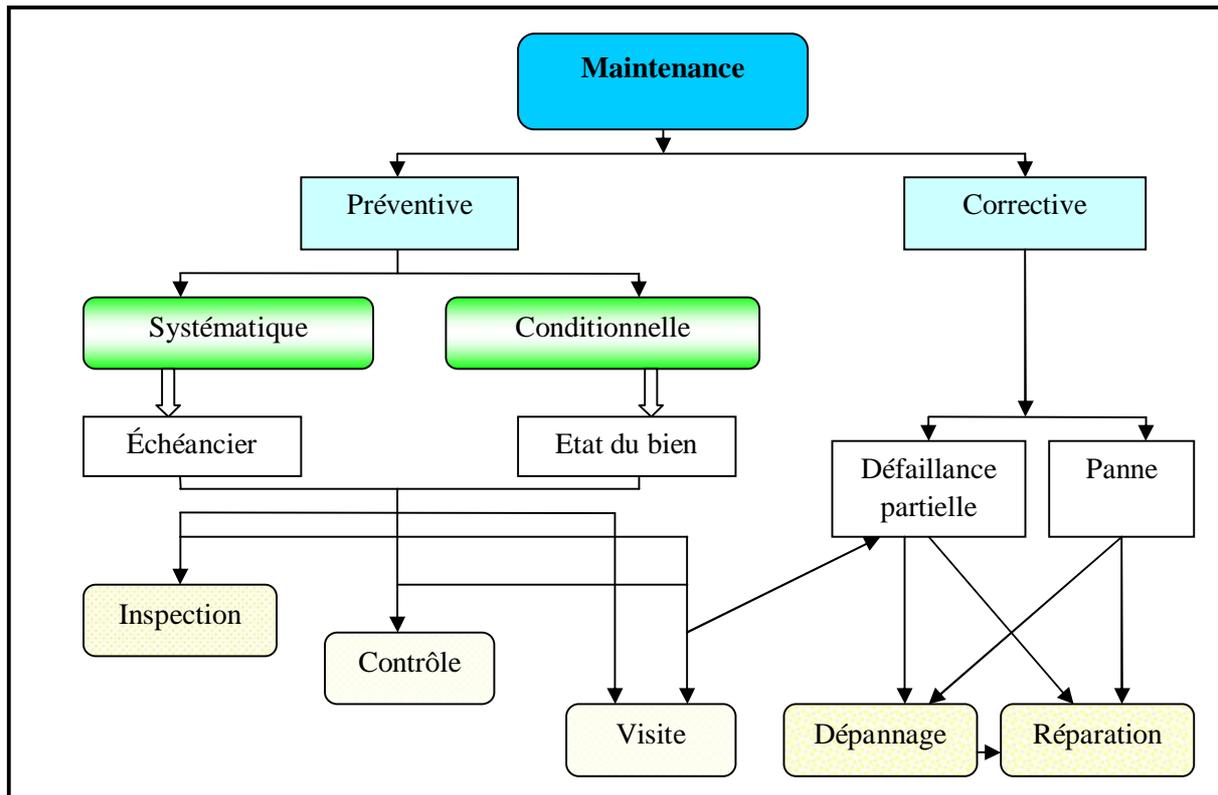


Figure 1.1 : Actions de maintenance.

2.3 Disponibilité

La disponibilité est « l'aptitude d'un bien, sous les aspects combinés de sa fiabilité, maintenabilité et de l'organisation de la maintenance, à être en état d'accomplir une fonction requise dans des conditions de temps déterminées ».

2.4 Fiabilité

C'est l'aptitude d'un système à accomplir sa mission dans des conditions données d'utilisation.

2.5 Maintenabilité

La maintenabilité est l'ensemble des actions destinées à maintenir ou rétablir une entité dans un état dans lequel elle peut accomplir une action requise définie suivant la norme (AFNOR X 60-500).

2.6 Sûreté

C'est l'aptitude d'un système à respecter l'utilisateur et son environnement.

3 Surveillance

La surveillance est un processus passif, informationnel qui analyse l'état du système et fournit des indications. La surveillance consiste notamment à détecter et classer les défaillances en observant l'évolution du système puis à les diagnostiquer en localisant les éléments défaillants et en identifiant les causes premières.

La surveillance se compose donc de deux fonctions principales qui sont la détection et le diagnostic.

a. La détection

Pour détecter les défaillances du système. Il faut être capable de classer les situations observables comme étant normales ou anormales.

b. Diagnostic industriel

« Le diagnostic est l'identification de (s) la cause (s) probable (s) de la défaillance à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test ».

Deux tâches essentielles en diagnostic

- Observer les symptômes de défaillance,
- Identifier la cause de la défaillance à l'aide d'un raisonnement logique fondé sur des observations.

4 Causalité

Le problème du diagnostic :

Ce problème consiste avant tout à résoudre le problème inverse de la relation "cause à effet" connaissant principalement l'effet par ses symptômes observables.

Nous considérons dans ce qui suit, que cette relation est de nature déterministe.

La relation déterministe définie par le modèle suivant la fig.1.2 :

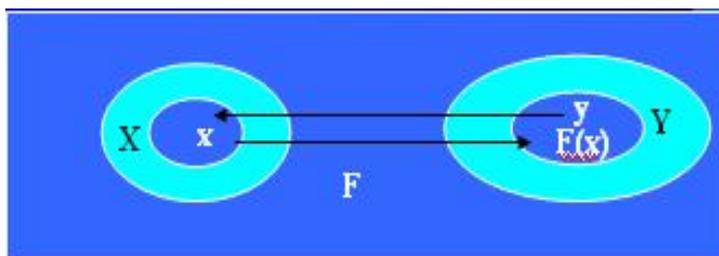


Figure 1.2 : Relation entre l'espace X des causes et l'espace Y des symptômes.

Soit

X : espace de paramètres inconnus (toutes les causes)

Y : espace des grandeurs observables (tous les symptômes)

Le problème à étudier est la détermination de x solution de y connaissant la fonction F :

$$F(x)=y \quad (1-1)$$

Solution triviale

$$x =F^{-1}(y) \quad (1-2)$$

Cette solution est très difficile à cause de la réalité physique des matériels. Pour l'effectuer, il faut satisfaire certaines conditions.

Conditions utilisées pour résoudre la formule (1-2), (problème bien posé et problème mal posé):

Un problème bien posé remplit trois conditions suivantes :

- **existence** de solution pour tout $y \in Y$,
- **unicité** de solution de x dans X,
- **continuité** de la solution $x(y)$.

Un problème mal posé ne remplit pas les trois conditions précédentes pour les raisons suivantes :

- données aberrantes ou fausses $y \notin Y$,
- données incompatibles, $y \notin F(X)$ mais $y \in Y$,
- données expérimentales bruitées,
- erreurs de modélisation, approximation grossière de F,
- choix inadéquat des topologies dans X et Y.

La sélection de la méthode de diagnostic la plus appropriée à un système industriel donné ne peut se faire qu'après un recensement des besoins et des connaissances disponibles.

L'objectif de la classification est de structurer la démarche nécessaire pour retenir la méthode techniquement et économiquement la plus efficace.

Les éléments indispensables à étudier :

- nature des causes de défaillance à localiser,
- connaissance des symptômes associés aux défaillances induites par les causes,
- maîtrise des moyens de mesure des symptômes,
- maîtrise des moyens de traitement des symptômes,
- connaissance des mécanismes physiques entre les causes et les effets,
- inventaire du retour d'expérience,
- recensement des expertises disponibles,
- définition du niveau de confiance dans le diagnostic,
- identification des utilisateurs finals du diagnostic.

5 Les différentes étapes techniques du diagnostic

Les étapes techniques, du diagnostic industriel nécessaires à la conception, au développement et à l'exploitation de systèmes d'aide au diagnostic. Sont définies dans la figure 1.3.

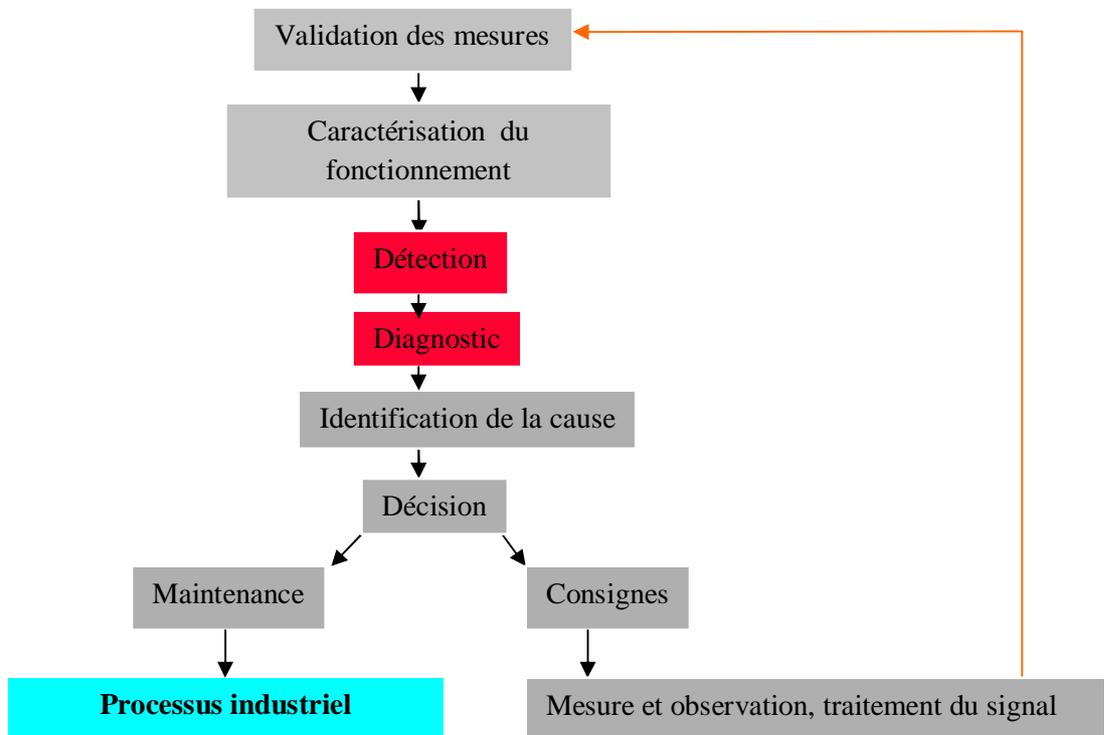


Figure 1.3: Les différentes étapes du diagnostic industriel

L'extraction des informations nécessaires à la mise en forme des caractéristiques associées aux fonctionnements normaux et anormaux, à partir des moyens de mesures appropriées ou d'observations réalisées hors des rondes par les personnels de surveillance.

Deux façons pour estimer la grandeur physique :

- **mesure directe** : utilisation de capteurs,
- **mesure indirecte** : Estimateur d'état.

L'élaboration des caractéristiques et signatures associées à des symptômes révélateurs de défaillances et de dégradations en vue de la détection d'un dysfonctionnement.

5.1 Validation des mesures

C'est l'opération qui consiste à engendrer une information représentant une grandeur physique, qui sera considérée crédible et fiable par les utilisateurs : les opérateurs et les systèmes de diagnostic.

5.2 Méthodes pour la détection et la validation de mesures invalides

Méthodes classiques :

- La redondance directe,
- La comparaison avec un seuil statique,
- Le vote majoritaire,
- Le test de certaines caractéristiques,
- La comparaison avec des seuils dynamiques,
- Le test de certaines caractéristiques,
- L'étalonnage systématique des capteurs.

La détection d'un dysfonctionnement par comparaison avec des signatures associées à des états de fonctionnements normaux et la définition d'indicateurs de confiance dans la détection. Le bruit associé aux signatures est pris en compte par l'utilisation des tests de décision statistique.

5.3 Les principales signatures

Dans les industries, souvent les paramètres à surveiller sont les effets induits par le fonctionnement même de la machine : effets dont l'amplification traduit sinon une défaillance, au moins une dégradation de la machine. Les types de signatures les plus utilisées sont :

a. Signature vibratoire

Les signatures vibratoires sont adaptées à la détection d'anomalies affectant des ensembles mécaniques dont les éléments structuraux sont soumis à des efforts dynamiques se traduisant par des vibrations mécaniques. L'analyse vibratoire détecte des mouvements répétitifs d'une surface appartenant à un matériel mécanique dynamique (machines tournantes, machines alternatives...) ou à un matériel statique (structure, tuyauterie...). Pour la majorité des défauts rencontrés sur les machines tournantes les vibrations sont de nature périodiques. Pour les défauts qui se traduisent par des chocs sur les structures, les vibrations sont caractérisées par des signaux transitoires de faibles durées, répétitives ou aléatoires. Il existe également des signaux aléatoires au cours du temps (exemple : cavitation dans les machines hydrauliques).

L'interprétation des signaux vibratoires fait appel le plus souvent à l'analyse fréquentielle, en traitement des signaux, cela revient à considérer les signaux comme une somme de fonctions sinusoïdales dont les valeurs des fréquences sont des multiples entiers d'une fréquence dite fréquence fondamentale. En l'absence de défauts les différentes fréquences contenues dans le signal sont directement reliées à la géométrie et à la vitesse de rotation de l'élément en cause. La présence d'un ou plusieurs défauts se traduit par l'apparition de nouvelles fréquences que l'on peut, souvent interpréter si la mesure de la vibration est faite au voisinage direct du défaut. Par contre, si le point de mesure est éloigné de la source du défaut, de nombreuses sources vibratoires (parasites) peuvent rendre l'interprétation extrêmement compliquée.

Suivant la nature des problèmes recherchés, les points de mesures accessibles et les technologies utilisées la mesure de la vibration peut s'exprimer par une mesure de déplacement, une mesure de déplacement, une mesure de vitesse ou une mesure d'accélération. La grande variété des problèmes vibratoires rencontrés sur les matériels mécaniques a conduit à développer des signatures spécifiques à l'aide de techniques très variées de traitement des signaux. Le plus souvent les signatures sont mises sous forme de courbes après une analyse spécifique répondant au problème recherché. Les types de traitement les plus utilisés sont : l'analyse spectrale, l'analyse synchrone, le calcul de la fonction de corrélation, le calcul de la fonction de transfert etc.

b. Signature acoustique

Les signatures acoustiques ont pour origine les bruits induits par certains phénomènes tels que la fuite de fluides à travers des petites ouvertures (problème d'étanchéité), la cavitation dans les machines hydrauliques, la vaporisation due à la surchauffe dans les machines à vapeur. La surveillance par signature acoustique permet d'isoler les composants fréquentiels dus à ces types de phénomènes.

c. Signature par émission acoustique

Elle a pour base l'écoute des bruits (en général, ultrasonores) émis par les matériaux lorsqu'ils sont mis sous contrainte.

d. Signature ultrasonore

Il s'agit d'envoyer dans les matériaux, grâce auxquels on réalise les équipements industriels, un train d'ondes ultrasonores et d'en analyser les échos. La présence d'un défaut peut être détectée grâce à l'apparition d'un écho entre le signal de base et celui réfléchi par le fond du matériau. Pour un matériau ne présentant pas de défaut, il n'apparaît que les ondes incidentes et celles réfléchies par les bords du matériau. L'apparition d'un défaut peut donc être détectée directement par simple superposition des trains d'ondes initiaux et en service.

e. Signature par analyse des lubrifiants

C'est la représentation de certaines propriétés physico-chimiques des lubrifiants ; en vue de la suivie de leur évolution au cours du service. En effet, l'état physico-chimique d'un lubrifiant peut être très modifié en présence de particules dues à l'usure des matériaux.

Outre les signatures précitées, il existe d'autres types tels que les signatures thermiques, les signatures par radiographie etc.

6 Méthodes du diagnostic

6.1 Introduction

Le diagnostic industriel est basé principalement sur les analyses des signatures (symptômes) exploités par des experts ; afin de détecter le comportement défaillant, d'en déduire la fonction ou l'élément en dysfonctionnement (localisation) ; puis d'en déterminer la cause et enfin, si possible d'y remédier.

Dans la majorité des cas les experts ne disposent pas de modèles liant les causes et leurs effets ; ces raisons expliquent la grande diversité des méthodes de diagnostic industriel qui sont basées soit sur la modélisation complète des défaillances ou au contraire sur les connaissances des experts sans modélisation des défaillances [27].

D'un autre côté, la grande diversité des technologies des systèmes industriels (mécanique, thermique, électrique, etc.) ne permet pas d'utiliser une méthode universelle qui posséderait tous les avantages et aucun inconvénient. Une méthode universelle de diagnostic industriel n'existe pas ; c'est pour cette raison que les méthodes existantes sont partagées en deux grandes familles : les méthodes internes et les méthodes externes [13], [27].

Sur la figure ci-dessous sont présentées les différentes méthodes de diagnostic :

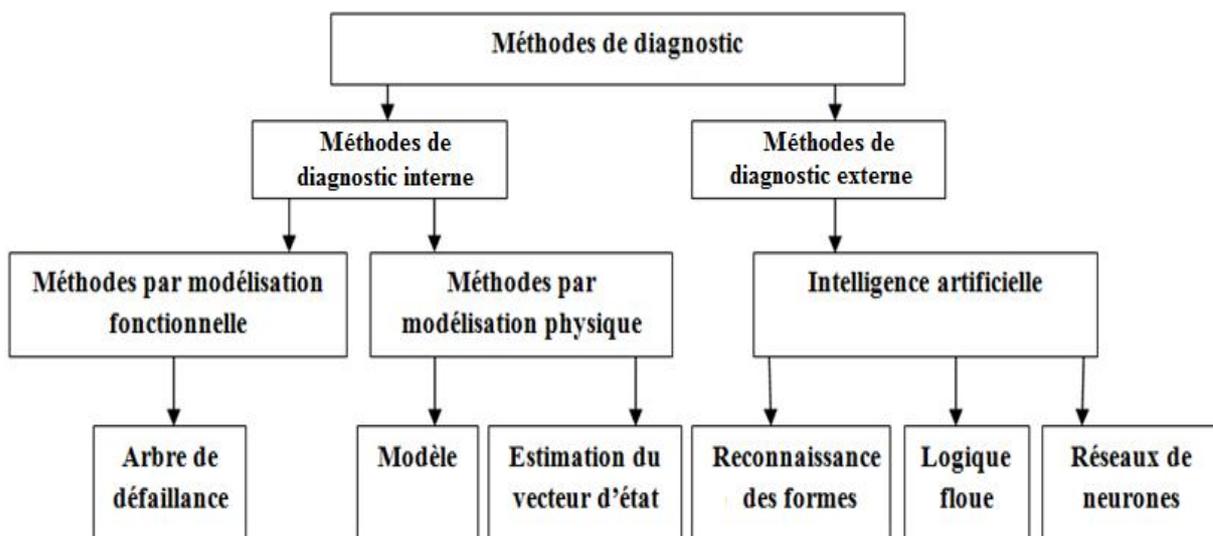


Figure 1.4: Schéma synoptique de classement des méthodes de diagnostic.

6.2 Méthodes de diagnostic interne

Ces types de méthodes sont basés sur les techniques de modélisation [22], [24], [27]; à savoir :

- Les méthodes du diagnostic par modélisation fonctionnelle ;
- Les méthodes de diagnostic de défaillance par modélisation physique.

6.2.1 Les méthodes de diagnostic de défaillances par modélisation fonctionnelle

Un système est un ensemble déterminé d'éléments interconnectés ; ces éléments sont regroupés fonctionnellement en vue de remplir une ou plusieurs fonctions. Une défaillance fonctionnelle est caractérisée par la perte d'une des fonctions d'un élément donné. Le principe des méthodes de modélisation des défaillances fonctionnelles est d'établir à priori les liens entre les causes initiales des défaillances et de leurs effets mesurables par les systèmes de traitement de l'information.

a. La méthode de l'arbre de défaillance

C'est une méthode inductive [20], avec laquelle on introduit toutes les combinaisons d'événements possibles qui entraînent la réalisation d'un événement unique indésirable. Les conditions et les événements sont organisés sous forme d'un arbre utilisant des symboles logiques « et » et « ou ». Les défaillances des matériels, à erreurs humaines ou à tout autre élément significatif.

L'arbre de défaillances est constitué de niveaux successifs d'événements tels que chaque événement à un niveau donné est généré à partir de combinaisons logiques d'événements de niveau inférieur. Cette procédure est répétée jusqu'à atteindre les événements appelés événements de base.

6.2.2 Méthodes de diagnostic par modélisation physique

Cette famille de méthodes repose principalement sur les modèles mathématiques qui représentent d'une manière satisfaisante le processus réel et qui devront aussi être validés expérimentalement avant toute utilisation industrielle. Ces méthodes sont regroupées en deux grandes familles : les méthodes du modèle, les méthodes d'identification des paramètres et les méthodes d'estimation du vecteur d'état.

a. La méthode du modèle

La méthode du diagnostic basée sur le modèle [22] consiste à comparer les grandeurs déduites d'un modèle représentatif du fonctionnement des différentes entités du processus avec les mesures directement observées sur le processus industriel.

b. La méthode de diagnostic par identification des paramètres

La méthode de diagnostic par identification des paramètres [14], [27] s'applique au cas très particulier où l'on souhaite suivre l'évolution de certains paramètres physiques critiques pour le fonctionnement d'un processus et qui ne sont pas mesurables directement. Par exemple l'encrassement des tubes dans un échangeur de chaleur modifie directement les températures, des débits des pressions d'évaluer de façon indirecte le coefficient d'échange thermique. Le principe général des méthodes d'identification est d'estimer les paramètres internes physiques représentés par un vecteur paramètre θ du modèle à partir de la connaissance des signaux d'entrées 'u' et 'y' mesurées sur le processus industriel par des méthodes appropriées.

Dans cette approche, il peut arriver quelquefois que les paramètres du processus aient des relations compliquées avec les coefficients physiques du processus ; souvent le mauvais fonctionnement affecte ces derniers. Alors les relations entre les paramètres et les coefficients doivent être uniques et de préférence connus avec précision. Néanmoins ce dernier cas est rare.

c. La méthode de diagnostic par estimation du vecteur d'état

Ces méthodes sont basées sur la prise en compte des observations u , y pour remonter aux paramètres ou à son vecteur d'état interne x . Les éléments et x ayant par définition un sens physique ou quasi-physique, la cause exacte de la défaillance devient aisée à localiser.

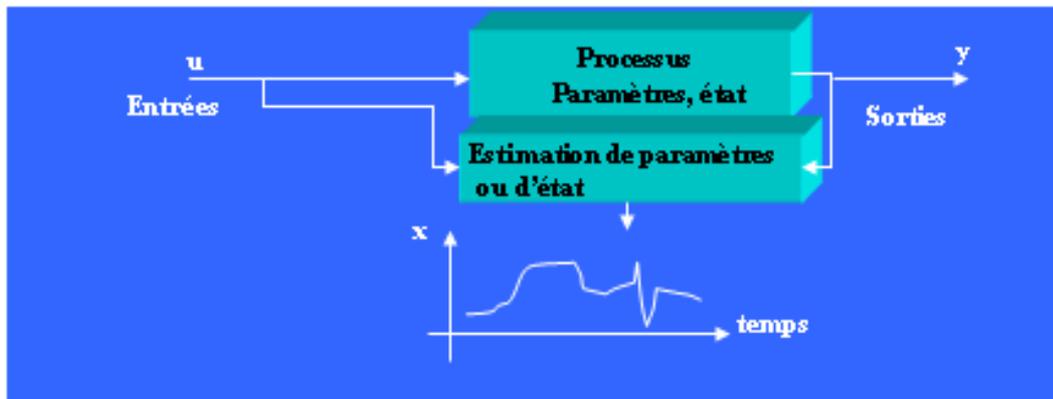


Figure 1.5 : Principe du diagnostic interne.

6.3 Méthodes de diagnostic externe

Ces méthodes ne nécessitent pas un modèle mathématique pour décrire les relations de cause à effet, la seule connaissance repose sur l'expertise humaine confrontée à un solide retour d'expérience [13], [27].

Le principe de fonctionnement de ces méthodes est divisé en trois phases :

- Les mesures.
- L'extraction du caractère.
- La classification.

Au début, les données appropriées sont mesurées, puis un vecteur de caractère est calculé. Ensuite, ce dernier réparti en une ou plusieurs classes. Quand la détection et le diagnostic sont combinés, les classes seront les suivantes : le fonctionnement normal, le défaut n°1, le défaut n°2, etc.

Donc, dans cette catégorie, on retrouve toutes les méthodes basées sur l'intelligence artificielle qui inclut la reconnaissance des formes, les réseaux de neurones et la logique floue.

6.3.1 La reconnaissance des formes (RdF)

Le diagnostic par RdF peut être présenté comme une solution alternative à l'approche par modèle puisque les modes de fonctionnement sont modélisés, pas de manière analytique, mais en utilisant uniquement un ensemble des mesures de ces modes [11, 15, 19, 27].

Pour la RdF, une forme est un ensemble de a paramètres ou caractères. Quand les paramètres sont des nombres réels, une forme peut être définie par un point ou un vecteur $x = (x_1, x_2, \dots, x_a)$ dans un espace de dimension a défini par ces paramètres. Cet espace est appelé l'espace de représentation.

Les prototypes sont des points représentatifs des formes types dans l'espace de représentation dans certains cas les formes types sont des modes de fonctionnement. Puisque dans un cas réel, les points sont bruités, une nouvelle observation sera rarement et rigoureusement confondue avec l'un des prototypes. Les nouvelles observations forment donc des zones autour de chaque prototype, ces zones sont appelées classes. La méthode de RdF a plusieurs étapes [23] qui sont :

Détermination de l'espace de représentation

Il s'agit de construire le vecteur forme E . Elle consiste à déterminer les paramètres et les techniques de prétraitement nécessaires pour permettre une meilleure reconnaissance ou classification. Elle est le fruit de l'expérience acquise sur le processus et conditionne le succès du système de diagnostic par RdF. Un ensemble de N observations :

1 E , 2 E , ..., N E , recueillies sur le processus à l'aide des capteurs, constitue l'ensemble d'apprentissage. La procédure consiste à mesurer et relever sur le réseau de l'ensemble d'apprentissage E .

Pour lesquels l'état de bon fonctionnement ou de panne est connu, Il peut être constant en réalisant un maillage suffisamment fin. Le plan (A, B) , puis en reportant sur ce maillage les points de bon fonctionnement « O » et les points de panne « X » voir la figure 1.6.

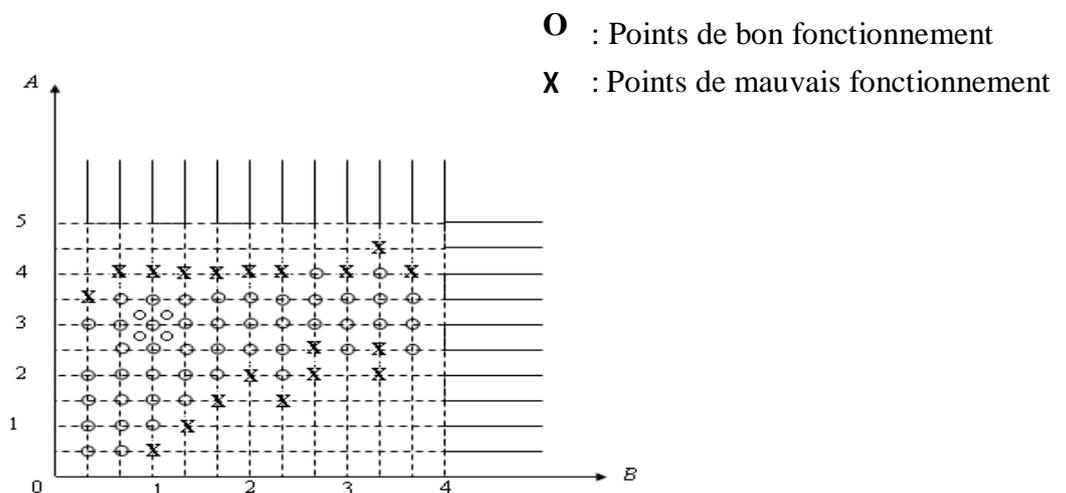


Figure 1.6 : Représentation de l'ensemble d'apprentissage E

Réduction de l'espace de représentation

Il s'agit de réduire la dimension de l'espace de représentation afin d'une part de diminuer le temps de classification d'une nouvelle observation, et d'autre part d'éviter la dégradation des performances à cause d'une dimension trop élevée de l'espace de représentation.

Détermination de l'espace de décision

Il s'agit de l'ensemble de toutes les classes possibles. Si on connaît la classe d'origine de chaque observation de l'ensemble d'apprentissage, l'espace de décision est parfaitement connu et l'apprentissage des classes peut être fait en mode dit supervisé. Dans le cas contraire, l'apprentissage des classes est fait en mode non supervisé et il passe par deux étapes : une phase de partitionnement automatique de l'ensemble des formes en classes et une phase de validation de ces classes soit par un expert, soit par des critères de validité de la partition.

6.3.2 Diagnostic par logique floue

Cette approche, contrairement à la logique du tout ou rien de G.Boode, a pour but la prise en compte de la logique de la pensée humaine qui est approximative.

Le concept de sous ensemble flou a été introduit pour prendre en compte l'imprécision. La fonction d'appartenance à un ensemble flou prend des valeurs sur l'intervalle $[0,1]$. Celle-ci exprime le degré d'appartenance d'un élément à cet ensemble : 0 pour la non appartenance stricte et 1 pour l'appartenance stricte [12], [13].

Le principe de fonctionnement du diagnostic basé sur la logique floue consiste à extraire et à calculer les signaux d'entrées, en utilisant les règles linguistiques représentées sous forme de fonctions d'appartenance, ces règles peuvent contenir tous les modèles possibles qui correspondent au mode de défaut considéré [17], [18].

En général, la procédure de fonctionnement d'un système flou est accomplie en trois étapes :

- La fuzzification ;
- L'inférence ;
- La défuzzification.

Le bloc fuzzification contient en général un traitement de données préliminaires ; ces données sont alors traitées par des règles linguistiques, ce qui nécessite leur définition par des fonctions d'appartenance. La fuzzification fournit une série de variables floues, réunies par un vecteur, qui va être introduit au bloc d'inférence.

Dans le bloc inférence, les valeurs des variables linguistiques sont liées par plusieurs règles qui doivent tenir compte du comportement statique et dynamique du système (des effets du système à diagnostiquer).

Dans la dernière étape, il faut transformer la valeur floue (linguistique) en une valeur déterminée pour déduire l'état du système, ceci se faisant dans le bloc défuzzification ; [18], [24] on rencontre les applications de cette méthode pour le diagnostic des systèmes de production.

6.3.3 Diagnostic par réseaux de neurones

« L'étude » objective et précise des RNA converge pour souligner l'importance de la diriger sous le soin et le contrôle de la neurophysiologie qui s'intéresse d'avantage aux problèmes de défaillances, il est toujours possible d'entreprendre le raisonnement humain, en communiquant à l'entrée du réseau artificiel des données de simulation à la place des mesures effectuées par les capteurs, ce qui permet une description approximative de son état, la reproduction comportementale résultat de ce test est une étape nécessaire, car elle permet de décrire, en cas de trouble fonctionnel, le scénario relatif au diagnostic depuis la détection de l'incident et jusqu'à la localisation de sa source. L'absence d'information concernant certaines situations qui ne sont pas connues par l'intermédiaire de capteurs ou celles dont la mesure est soumise à des imprécisions, pourront être palliées dans le cadre formel de l'intelligence artificielle.

7 Analyse critique des méthodes de diagnostic existantes

Les performances des méthodes de diagnostic basées sur la modélisation dépendent très fortement de l'utilisation du modèle, dont l'obtention exige un grand effort. En plus, le changement d'une équation conduit en général au changement d'autres équations ou d'autres paramètres. De ce fait, le modèle obtenu ne peut pas être considéré comme étant exact ou performant et par conséquent le système de diagnostic ne sera pas fiable.

Les méthodes basées sur l'estimation d'état ou l'estimation des paramètres ont des relations compliquées entre les coefficients physiques et les paramètres. Ces relations, doivent être uniques et de préférence connues exactement alors que ce dernier cas est rarement réalisable. Pour l'estimation du modèle dynamique d'un processus, il doit être linearisé autour d'un point de fonctionnement, donc les résidus, c'est-à-dire les différences entre les variables mesurées et les variables estimées sont généralisées et la détection du défaut est exécutée en utilisant les méthodes de test [25]. Cette approche exige relativement une connaissance exacte des paramètres d'un modèle linearisé. C'est-à-dire le processus doit fonctionner aux alentours du point où la linéarisation a été effectuée, parce que le modèle est valide seulement au voisinage de ce point de fonctionnement.

Quand aux méthodes externes de diagnostic, elles ne nécessitent pas la connaissance du modèle mathématique du processus pour la détection d'une défaillance, mais elles nécessitent les données représentatives pour les apprendre ; ces données sont obtenues à partir de l'expertise humaine basée sur le retour d'expérience (sur le système) ; ces méthodes sont simples à appliquer ou à réaliser mais la tâche de calcul dépend beaucoup des données du problème à étudier. D'un autre côté, ces méthodes sont plus flexibles dans le cas de changement de paramètres, car dans la phase de construction du système de détection, on peut prévoir les défauts en tenant compte du changement des paramètres ; en outre, on peut

considérer cette opération dans la phase d'apprentissage dans le cas d'application des réseaux de neurones et la phase fuzzification dans le cas d'application de la technique de la logique floue.

Par ailleurs, il est à remarquer que le développement d'un système de diagnostic basé sur la technique des systèmes experts, nécessite un grand effort (pour sa conception et sa réalisation). En outre, son installation coûte très cher [18]. D'un autre côté, la logique floue peut être appliquée pour remplacer les systèmes experts par des règles linguistiques, quand le problème à résoudre est trop complexe (difficile à analyser). Ces règles sont plus souhaitables pour décrire la nature exacte des machines réelles mais les formes et nombre des fonctions d'appartenance doivent être initialement choisies en utilisant une large base de données.

Partant de la considération que le caractère principal du système de diagnostic est de constituer un catalogue défauts-symptômes, les approximateurs universels (réseaux de neurones paraissent très intéressants pour la mise en place de la procédure du diagnostic [16, 18, 26, 27].

Par ailleurs les réseaux de neurones possèdent des caractéristiques permettant la résolution de problèmes complexes, à savoir :

- Leur capacité d'apprentissage,
- Leur parallélisme dans le traitement,
- Leur capacité de faire face à des problèmes inhérents au non linéarité des systèmes.

En ce qui concerne les méthodes externes, la méthode retenue dans le présent travail est la technique des réseaux de neurones artificiels. Ce choix est justifié par les avantages que possède cette technique.

Conclusion

Dans le présent chapitre on a exposé les étapes nécessaires à la mise en place d'un système d'aide au diagnostic (analyse de la problématique du diagnostic) ; une étude critique sur les différents systèmes de diagnostic existants a été exposée.

D'après l'analyse critique faite sur les méthodes du diagnostic, il a été déduit que les méthodes externes du diagnostic des défaillances sont bien adaptées au système à étudier car la modélisation physique des systèmes industriels ne peut pas être réalisée. Parmi les méthodes externes, la technique des réseaux de neurones artificiels a été retenue pour la surveillance et le diagnostic des systèmes de production. En effet, l'analyse bibliographique effectuée à démontrer que les RNA sont largement utilisés dans le domaine de surveillance et du diagnostic industriels, en raison de leurs avantages et de leur simplicité à s'adapter sur des cas réels.

Par ailleurs, le chapitre suivant sera consacré à la mise en œuvre de notre approche neuronale pour la surveillance et le diagnostic de la ligne de production pharmaceutique.

Chapitre II : Notions de base des réseaux de neurones artificiels

Introduction

Le terme « *réseaux de neurones artificiels* » regroupe un certain nombre de modèles dans l'intention d'imiter certaines fonctions du cerveau humain reproduisant quelques unes de ses structures de base.

Par ailleurs, les réseaux de neurones sont adaptés comme outil d'aide aux opérations de reconnaissance et de classification, entre autre, celles liées à la résolution des problèmes de diagnostic et de surveillance des systèmes de production.

Ce chapitre a pour but d'exposer les éléments nécessaires à la compréhension de la théorie et de la pratique des réseaux de neurones, qui seront réalisés ultérieurement (chapitre 3 et 4), en vue de surveiller et de diagnostiquer une ligne de production pharmaceutique.

Le présent chapitre comprend :

- la description des fondements biologiques des réseaux de neurones ;
- la modélisation et la présentation des modèles neuronaux les plus importants pour la surveillance et le diagnostic industriel;
- l'apprentissage des réseaux de neurones et l'algorithme de rétro-propagation du gradient.

Enfin, cette étude théorique des principales caractéristiques des RNA sera utilisée dans le chapitre qui suit pour surveiller et diagnostiquer la ligne de production pharmaceutique.

1 Histoire [28]

- 1890 : W. James, célèbre psychologue américain introduit le concept de mémoire associative, et propose ce qui deviendra une loi de fonctionnement pour l'apprentissage sur les réseaux de neurones connue plus tard sous le nom de loi de Hebb.
- 1943 : J. Mc Culloch et W. Pitts laissent leurs noms à une modélisation du neurone biologique (un neurone au comportement binaire). Ce sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique).
- 1949 : D. Hebb, physiologiste américain explique le conditionnement chez l'animal par les propriétés des neurones eux-mêmes. Ainsi, un conditionnement de type pavlovien tel que, nourrir tous les jours à la même heure un chien, entraîne chez cet animal la sécrétion de salive à cette heure précise même en l'absence de nourriture. La loi de modification des propriétés des connexions entre neurones qu'il propose explique en partie ce type de résultats expérimentaux.

Les premiers succès

- 1957 : F. Rosenblatt développe le modèle du perceptron. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance de formes. Notons qu'à cette époque les moyens à sa disposition sont limités et c'est une prouesse technologique que de réussir à faire fonctionner correctement cette machine plus de quelques minutes.

- 1960 : B. Widrow, un automaticien, développe le modèle Adaline (Adaptative Linear Element). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente. Celle-ci est à l'origine de l'algorithme de rétro-propagation de gradient très utilisé aujourd'hui avec les Perceptrons multicouches. Les réseaux de type Adaline restent utilisés de nos jours pour certaines applications particulières. B. Widrow a créé dès cette époque une des premières firmes proposant neuro-ordinateurs et neuro-composants, la "Memistor Corporation". Il est aujourd'hui le président de l'International Neural Network Society (INNS).
- 1969 : M. Minsky et S. Papert publient un ouvrage qui met en exergue les limitations théoriques du perceptron. Limitations alors connues, notamment concernant l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils étendent implicitement ces limitations à tous modèles de réseaux de neurones artificiels. Leur objectif est atteint, il y a abandon financier des recherches dans le domaine (surtout aux U.S.A.), les chercheurs se tournent principalement vers l'IA et les systèmes à bases de règles.

L'ombre

- 1967-1982 : Toutes les recherches ne sont, bien sûr, pas interrompues. Elles se poursuivent, mais déguisées, sous le couvert de divers domaines comme : le traitement adaptatif du signal, la reconnaissance de formes, la modélisation en neurobiologie, etc. De grands noms travaillent durant cette période tels : S. Grossberg, T. Kohonen, ... dont nous reparlerons.

Le renouveau

- 1982 : J. J. Hopfield est un physicien reconnu à qui l'on doit le renouveau d'intérêt pour les réseaux de neurones artificiels. A cela plusieurs raisons :
Au travers d'un article court, clair et bien écrit, il présente une théorie du fonctionnement et des possibilités des réseaux de neurones. Il faut remarquer la présentation anticonformiste de son article. Alors que les auteurs s'acharnent jusqu'alors à proposer une structure et une loi d'apprentissage, puis à étudier les propriétés émergentes ; J. J. Hopfield fixe préalablement le comportement à atteindre pour son modèle et construit à partir de là, la structure et la loi d'apprentissage correspondant au résultat escompté. Ce modèle est aujourd'hui encore très utilisé pour des problèmes d'optimisation. D'autre part, entre les mains de ce physicien distingué, la théorie des réseaux de neurones devient respectable. Elle n'est plus l'apanage d'un certain nombre de psychologues et neurobiologistes hors du coup.
Enfin, une petite phrase, placée en commentaire dans son article initial, met en avant l'isomorphisme de son modèle avec le modèle d'Ising (modèle des verres de spins). Cette idée va drainer un flot de physiciens vers les réseaux de neurones artificiels.
Notons qu'à cette date, l'IA est l'objet d'une certaine désillusion, elle n'a pas répondu à toutes les attentes et s'est même heurtée à de sérieuses limitations. Aussi, bien que les limitations du Perceptron mise en avant par M. Minsky ne soient pas levées par le modèle d'Hopfield, les recherches sont relancées.

La levée des limitations

- 1983 : La Machine de Boltzmann est le premier modèle connu apte à traiter de manière satisfaisante les limitations recensées dans le cas du perceptron. Mais

l'utilisation pratique s'avère difficile, la convergence de l'algorithme étant extrêmement longue (les temps de calcul sont considérables).

- 1985 : La rétro-propagation de gradient apparaît. C'est un algorithme d'apprentissage adapté aux réseaux de neurones multicouches (aussi appelés Perceptrons multicouches). Sa découverte réalisée par trois groupes de chercheurs indépendants indique que "la chose était dans l'air". Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables. De nos jours, les réseaux multicouches et la rétro-propagation de gradient reste le modèle le plus étudié et le plus productif au niveau des applications.

La situation actuelle

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

2 Le neurone biologique

Les cellules nerveuses, appelées neurones, sont les éléments de base du système nerveux central ; celui-ci en posséderait environ cent milliards. Par ailleurs, il existe de nombreuses variétés de neurones, les différences portant tant sur les aspects anatomiques que sur les aspects fonctionnels [29].

En général, chaque neurone biologique possède un axone qui peut atteindre plusieurs dizaines de centimètres, un corps cellulaire où se situe le mécanisme du déclenchement du neurone, des dendrites qui reçoivent des informations des autres neurones et des terminaisons axonales qui émettent des informations vers les autres neurones (fig. 2.1). Les neurones sont interconnectés entre eux par des synapses dont le nombre est d'environ 10000 milliards. Ceci signifie qu'un neurone reçoit en moyenne des excitations en provenance de 1000 neurones, et qui émet également des informations à 1000 neurones différents.

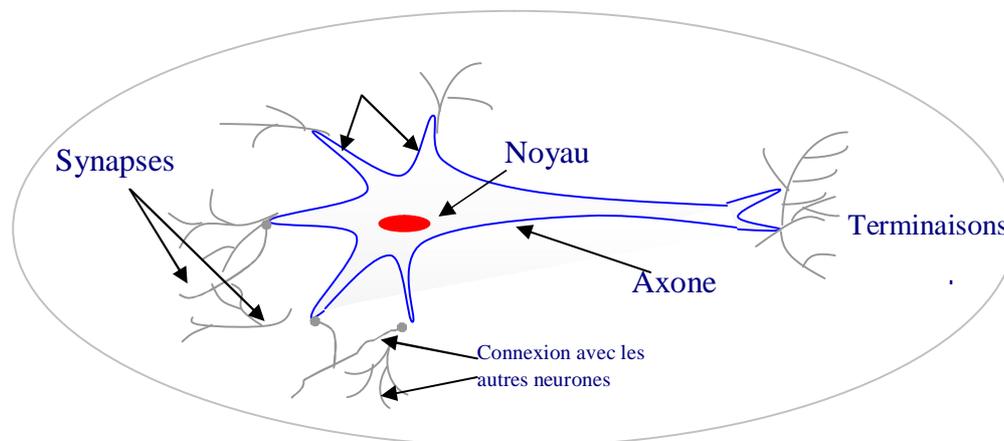


Figure 2.1 : schéma simplifié d'un neurone du cerveau humain.

Il existe quatre modes de communications entre neurones [32]:

- liaison terminaison axonale-dendritique;
- liaison terminaison axonale-corps cellulaire;
- liaison axone-axone;
- liaison dendrite-dendrite.

Le processus de communication entre les neurones se fait par voie électrochimique aux niveaux des synapses par des neurotransmetteurs ; ces fonctions spécifiques dépendent essentiellement des propriétés de la membrane externe du neurone, cette dernière remplit cinq fonctions principales:

- elle sert à propager des impulsions électriques tout au long de l'axone et des dendrites;
- elle libère des médiateurs à l'extérieur de l'axone;
- elle réagit au niveau du corps cellulaire aux impulsions électriques que lui transmettent les dendrites pour générer ou non une nouvelle impulsion;
- enfin, elle permet au neurone de reconnaître les autres neurones afin qu'il puisse se situer dans l'architecture anatomique du cerveau et de trouver les cellules auxquelles il doit être connecté.

Généralement, les réseaux de neurones artificiels sont basés sur une théorie électrique selon laquelle la jonction synaptique, est l'endroit où le neurone perçoit un stimulus par voie électrochimique. La membrane synaptique, lorsqu'elle ne reçoit pas d'excitation, est polarisée à une tension supérieure à un seuil donné, le neurone étant alors activé et cela déclenche un processus de dépolarisation ; le neurone émet sur l'axone une tension positive d'environ (+60 à +70mv) en se comportant comme un système non linéaire. C'est ce type de modèle qui est majoritairement retenu pour simuler artificiellement les neurones du cerveau humain.

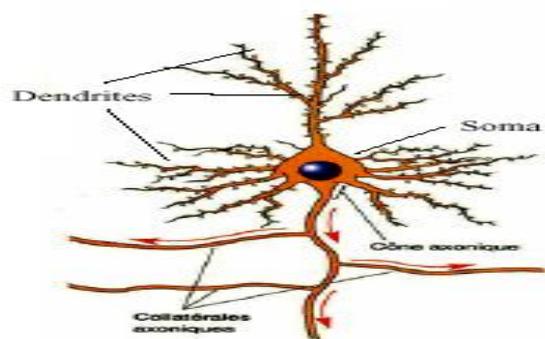


Figure 2.2 : Un neurone biologique [34].

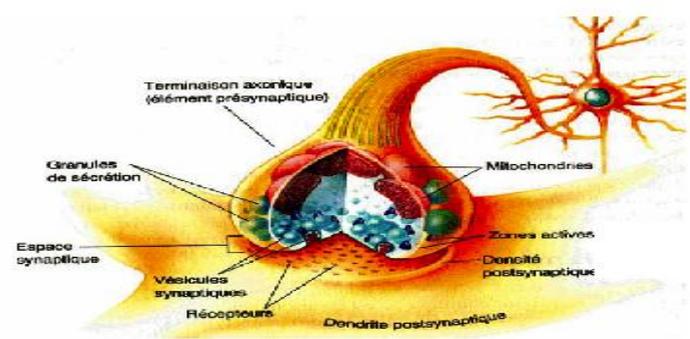


Figure 2.3 : Une synapse [34].

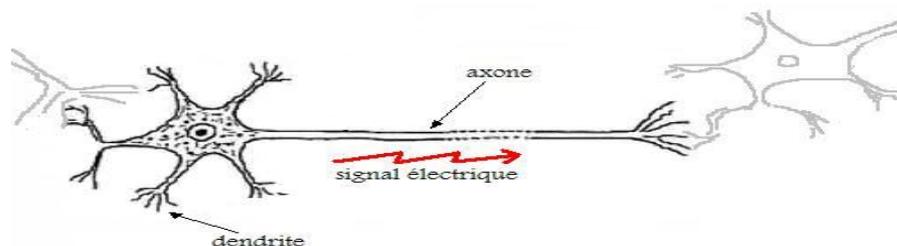


Figure 2.4 : Impulsions électriques entre les neurones.

3 Le neurone artificiel

L'élément de base d'un réseau de neurones est, bien entendu, le neurone artificiel [36] présenté par la figure 2.5. Un neurone artificiel contient deux éléments principaux:

- un ensemble de poids associés aux connexions du neurone, et
- une fonction d'activation (Tableau 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.

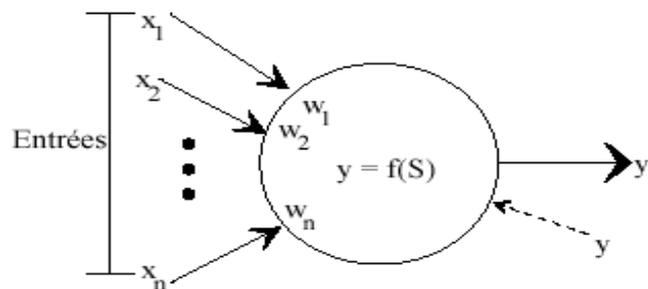
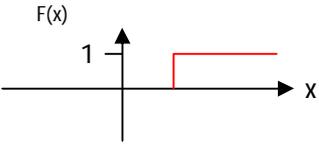
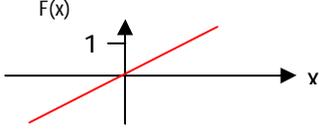
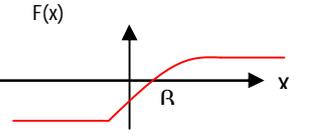
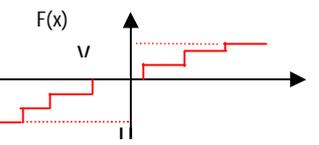
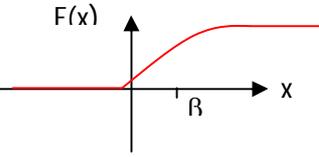
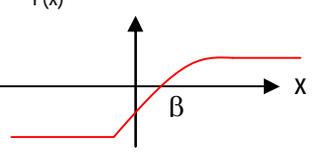
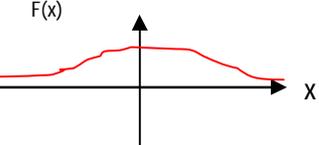


Figure 2.5 : Le neurone artificiel générique.

4 Fonction d'activation

La fonction d'activation est en générale une fonction non linéaire monotone croissante [31] [37]; par ailleurs les fonctions de transfert sont de qualités diverses : elles peuvent être déterministes, continues, discontinues ou aléatoires. Ces fonctions sont présentées dans le tableau 1 :

Tableau 1 : Fonctions d'activation.

<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 $F(x) = \frac{1}{1 + e^{-x}}$</p>	
<p>(f) fonction sigmoïde bipolaire $F(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$</p>	
<p>(g) fonction stochastique</p>	

5 Les réseaux de neurones artificiels

5.1 Introduction

Les recherches actuelles faites sur les réseaux de neurones artificiels n'ont pas permis de donner une définition exacte ou universelle à ce concept.

En effet, la définition admise, utilise la notion de réseaux d'automates ou de système connexionniste [32]. Un réseau de neurones artificiels est composé d'automates connectés en réseau et fonctionnant en parallèle et dans lequel les connexions contiennent la connaissance d'un domaine particulier.

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

- différentes architectures de réseaux de neurones ;
- mécanisme d'apprentissage ;
- apprentissage des réseaux multicouches ;
- principe de descente de gradient.

5.2 Différentes architectures de réseaux de neurones

Selon la topologie de connexion des neurones, on peut classifier plusieurs modèles de réseaux de neurones.

a. Réseau multicouche (*feed-forward*)

Dans les réseaux multicouche (*feed-forward*) les neurones sont arrangés par couche, il n'y a pas de connexion entre neurone d'une même couche et la connexion ne se fait qu'avec les neurones des couches en aval. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement, nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et de définir les concepts de neurone d'entrée et de neurone de sortie. Par extension on appelle couche d'entrée l'ensemble des neurones d'entrées et la couche de sortie l'ensemble des neurones de sorties. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées, tel que représenté sur la figure 2.6.

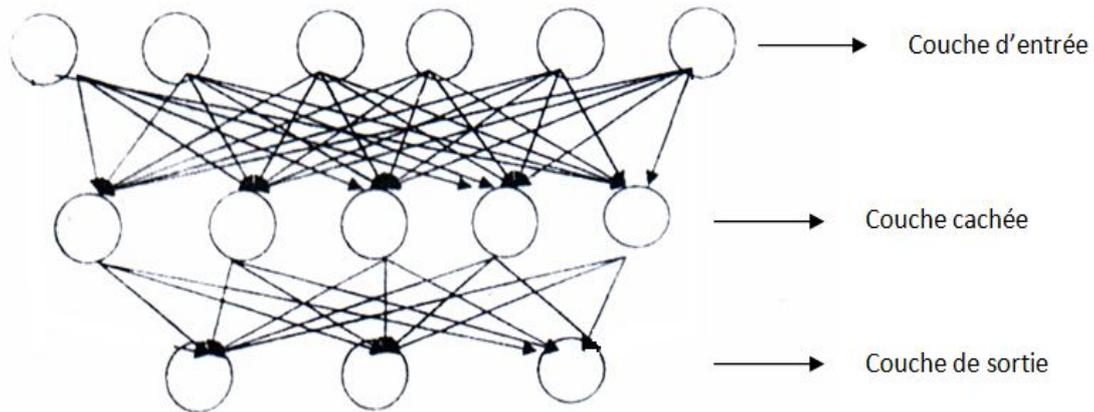


Figure 2.6 : Réseau multicouche.

b. Réseau à connexion locale

Il s'agit d'une structure multicouche, mais qui a l'image de la rétine, conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurone de couche avale. Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique. Tel que le montre la fig.2.7.

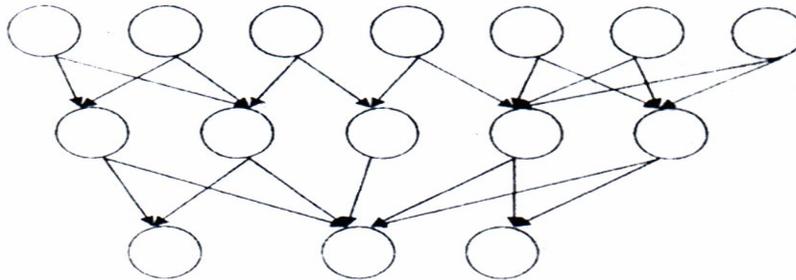


Figure 2.7 : Structure multicouche à réseau de connexion locale.

c. Réseau à connexion récurrente

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales. Ceci est représenté par la fig.2.8.

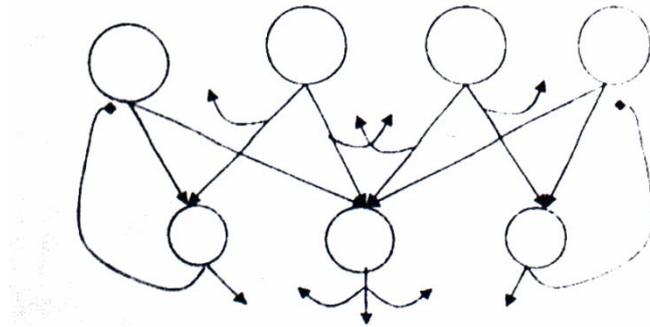


Figure 2.8 : Réseau à connexion récurrente.

d. Réseau à connexion complète

C'est la structure d'interconnexion la plus générale. Chaque neurone est connecté à tous les neurones du réseau et à lui-même. Tel que le montre la fig.2.9.

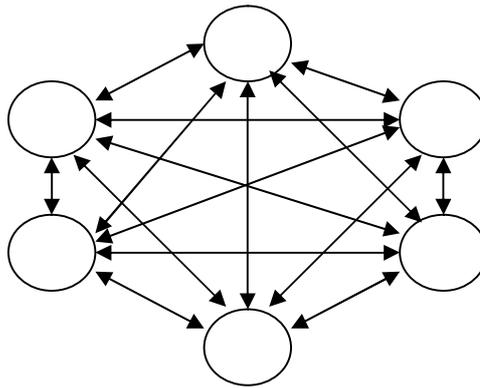


Figure 2.9 : Réseau de connexion complète.

5.3 Apprentissage

L'apprentissage [34] est vraisemblablement la caractéristique la plus intéressante des réseaux de neurones. Il ne concerne cependant pas tous les modèles, mais les plus utilisés.

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 variables modifiées pendant l'apprentissage sont les poids de connexion.

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 à 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.

Cependant 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.

Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé [30] [32]. Cette distinction repose sur la forme des exemples d'apprentissage.

b. Apprentissage supervisé

Dans ce type d'apprentissage, l'algorithme détermine les poids synaptiques à partir d'exemples étiquetés de formes auquel un professeur (teacher) a associé des réponses ou des cibles également étiquetées. Il existe plusieurs algorithmes, parmi lesquels on distingue l'algorithme de rétro-propagation qui est destiné aux réseaux multicouches.

c. Apprentissage non supervisé

Dans ce type d'algorithmes, on présente à l'entrée du réseau des exemples connus et le réseau s'organise lui-même autour d'attracteurs qui correspondent à des configurations stables du modèle dynamique non linéaire associé au réseau. L'apprentissage est accompli à l'aide de règles qui changent ou adaptent le poids des coefficients synaptiques en fonction des exemples présentés à l'entrée et dans certains cas en fonction des sorties désirées.

L'apprentissage a lieu souvent en temps réel avec des réseaux qui peuvent être éventuellement bouclés, parmi lesquels, on peut citer : le réseau de HOPFIELD, et les cartes topologiques de KOHONEN.

d. 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.

e. 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.

f. 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.

g. 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.

5.4 Apprentissage des réseaux multicouches

Les pondérations des différents réseaux utilisées sont ajustées par l'apprentissage supervisé en exploitant l'idée de minimisation itérative d'un critère de l'erreur en sortie [33] qui a pour principe de minimiser une « fonction de coût » de l'erreur calculée entre la sortie du réseau et la sortie souhaitée pour une entrée donnée. Donc le rôle de ce principe est de trouver le plus rapidement possible le minimum d'une fonction d'énergie dont la forme dépend uniquement de l'architecture du réseau.

Toutefois, les principes sous-jacents aux règles d'apprentissage les plus connus ne sont rien d'autre que des principes d'optimisation. Le plus utilisé est le principe de descente de gradient, il a été conçu pour dévier les problèmes de non séparabilité linéaire. Tel que le montre la fig.2.10.

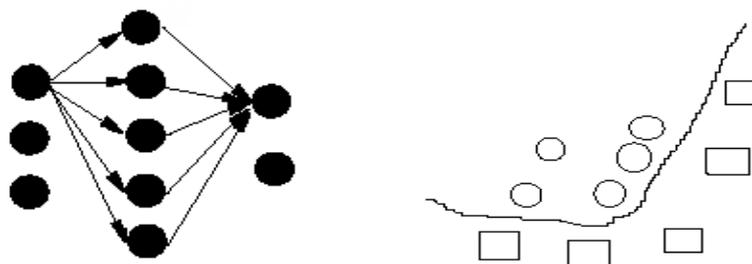


Figure 2.10: La séparation non linéaire (*rétro-propagation : cas général*).

5.5 Principe de descente de gradient (propagation de gradient) [38]

Cette méthode est utilisée couramment dans de nombreuses applications. Elle consiste à rechercher un endroit situé plus bas que tous les autres endroits (c'est-à-dire le minimum), alors le déplacement sera systématiquement vers le bas (fig.2.11) en suivant les lignes de plus grande pente, celle-ci étant mathématiquement calculée par le gradient.

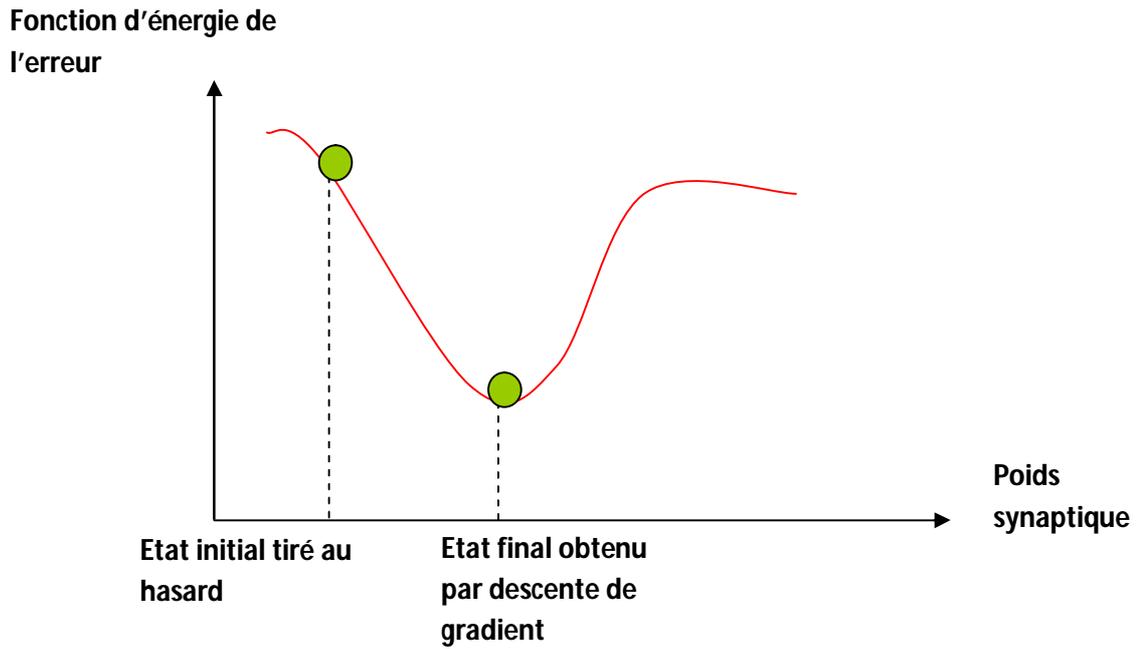


Figure 2.11 : La descente de gradient.

a. Algorithme de descente de gradient

L'algorithme utilise les conventions de notation représentées sur sa description édifée dans la fig.2.12.

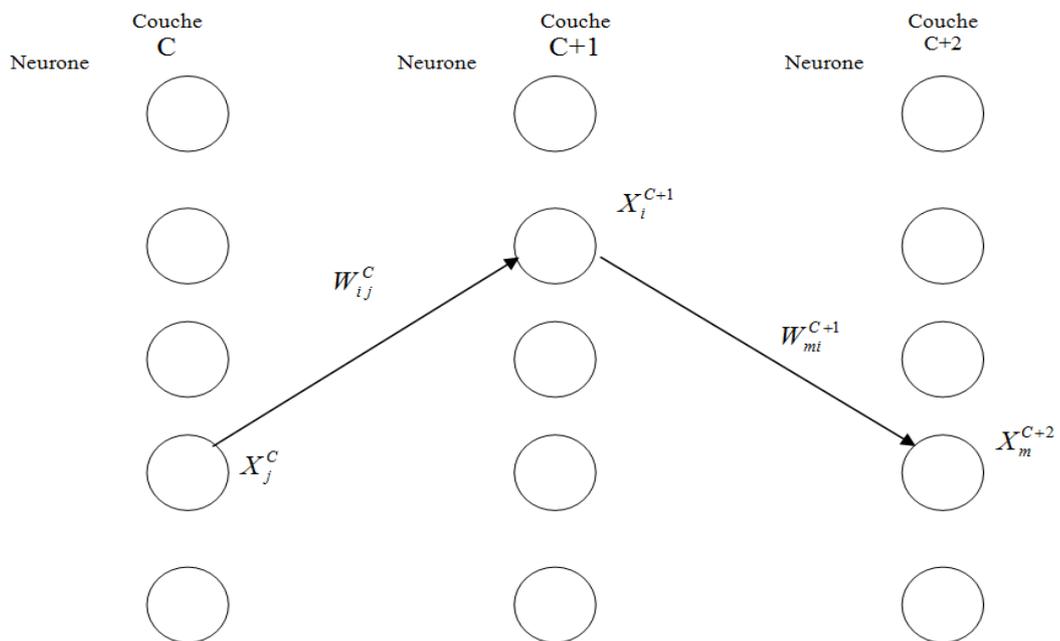


Figure 2.12 : Algorithme de retro-propagation de gradient

- soit n le nombre total des exemples d_i , $i = 1 \dots n$ de la base d'apprentissage et N_n le nombre de cellule de la dernière couche.
- La couche de rang C contient N_C cellules repérées X_i^C $i = 1, \dots, N_C$.
- Pour un réseau contenant N couches, $C = 1$ et $C = N$ correspondent à la couche d'entrée et à la couche de sortie.

Soit X_i^{C+1} la sortie de la cellule numéro i de la couche $C+1$, son contenu vaut :

$$X_i^{C+1} = f\left(\sum_{j=0}^{N_C} W_{ij}^C X_j^C\right) = f(A_i^{C+1}) \quad (2-1)$$

f : fonction sigmoïde

$$A_i^{C+1} = W_i^{tr} X^C \quad (2-2)$$

- En désignant par $X_{i k}^N$ la sortie de la cellule de rang i de la dernière couche associée à l'exemple X_k présenté sur la couche d'entrée, par d_i^k la sortie souhaitée, ou k varie de 1 à n et N_n est le nombre de cellules de la dernière couche, la fonction quadratique de l'erreur a pour expression :

$$R = \sum_{k=1}^n \sum_{i=1}^{N_n} \left\| X_{i k}^N - d_i^k \right\|^2 \quad (2-3)$$

Cette fonction de coût fait appel de façon implicite à tous les éléments du réseau et à tous les poids synaptiques un élément de la dernière cellule est fourni par :

$$X_i^N = f\left(\sum_{j=0}^{N_n-1} W_{ij}^{N-1} X_j^{N-1}\right) \quad (2-4)$$

Une règle d'apprentissage possible consisterait à minimiser la fonction R avec la technique des moindres carrés, la règle de retro-propagation du gradient utilise la règle de Windrow-Hoff en minimisant la fonction de coût évalué lors de la présentation de l'exemple d_k .

$$R^* = \sum_{i=0}^{N_n} \left(X_{i k}^N - d_i^k\right)^2 \quad (2-5)$$

La loi d'adaptation du vecteur poids W s'écrit :

$$W_k = W_{k-1} - \alpha_k \nabla_k (W) \quad (2-6)$$

La loi de pondération des poids sera notée par :

$$W_{ij}^k = W_{ij}^{k-1} - \alpha_k \frac{\partial R^*}{\partial W_{ij}} \quad (2-7)$$

En considérant la dernière couche, on obtient pour la sortie désirée d_i^k :

$$\frac{\partial R^*}{\partial W_{ij}^{N-1}} = 2(X_{ik}^N - d_i^k) \frac{\partial X_{ik}^N}{\partial W_{ij}^{N-1}} = 2(X_{ik}^N - d_i^k) \frac{\partial X_{ik}^N}{\partial A_{ik}^{N-1}} \frac{\partial A_{ik}^{N-1}}{\partial W_{ij}^{N-1}} \quad (2-8)$$

Avec :

$$A_{ik}^N = \sum_{j=0}^{j=Nn-1} W_{ij}^{N-1} X_{jk}^{N-1} \quad \text{et} \quad \frac{\partial A_{ik}^{N-1}}{\partial W_{ij}^{N-1}} = X_{jk}^{N-1} \quad (2-9)$$

Compte tenu de (2-4)

$$\frac{\partial X_{ik}^N}{\partial A_{ik}^N} = f'(A_{ik}^N) \quad (2-10)$$

D'où :

$$\frac{\partial R^*}{\partial W_{ij}^{N-1}} = 2(X_{ik}^N - d_i^k) f'(A_{ik}^N) X_{jk}^{N-1} \quad (2-11)$$

Le calcul des poids de la dernière couche dépend des éléments des couches précédentes.

- pour la couche C on peut écrire de façon similaire :

$$\frac{\partial R^*}{\partial W_{ij}^C} = \frac{\partial R^*}{\partial A_{ik}^{C+1}} \cdot \frac{\partial A_{ik}^{C+1}}{\partial W_{ij}^C} \quad (2-12)$$

Avec :

$$\frac{\partial A_{ik}^{C+1}}{\partial W_{ij}^C} = X_{ik}^C \quad (2-13)$$

$$\frac{\partial R^*}{\partial A_{ik}^{C+1}} = \sum_m \frac{\partial R^*}{\partial A_{mk}^{C+2}} \frac{\partial A_{mk}^{C+2}}{\partial A_{ik}^{C+1}} \quad (2-14)$$

- l'indice m correspond au nombre de termes qui contribue à la fonction de coût lorsque l'on passe de la couche c+1 à la couche c+2.

$$\frac{\partial A_{mk}^{C+2}}{\partial A_{ik}^{C+1}} = \frac{\partial \left[\sum_{i=1}^{i=nc+2} W_{mi}^{C+1} f(A_{ik}^{C+1}) \right]}{\partial A_{ik}^{C+1}} = W_{mi}^{C+1} f'(A_{im}^{C+1}) \quad (2-15)$$

n_{c+2} représente le nombre de cellules de la couche (c+2) augmenté d'une unité et finalement on obtient :

$$\frac{\partial R^*}{\partial W_{ij}^C} = \sum_{m=1}^{m=nc+2} \frac{\partial R^*}{\partial A_{mk}^{C+2}} W_{mi}^{C+1} f'(A_{ik}^{C+1}) X_{jk}^C \quad (2-16)$$

L'algorithme de rétro-propagation de gradient se résume comme suite :

a°/ Pour la dernière couche, les poids sont adaptés suivant la loi :

$$W_{ij,k}^N = W_{ij,k-1}^{N-1} - \alpha_k (X_{ik}^N - d_i^k) f'(A_{ik}^N) X_{jk}^{N-1} \quad (2-17)$$

b°/ Pour les couches intermédiaires on a :

$$W_{ij,k}^N = W_{ij,k-1}^C - \alpha_k \sum_{m=1}^{m=nc+2} \frac{\partial R^*}{\partial A_{mk}^{C+2}} W_{mi,k}^{C+1} f'(A_{ik}^{C+1}) X_{jk}^C \quad (2-18)$$

b. Caractéristiques de la rétro-propagation

Les caractéristiques de la rétro-propagation [39] sont :

- Processus de descente de gradient effectué sur tout le vecteur.
- Minimum d'erreur local, pas nécessairement global.

- Minimisation de l'erreur sur l'ensemble d'apprentissage; risque de sur-apprentissage comme pour les arbres de décision.
- Apprentissage nécessite des milliers itérations très lente.
- Décider de la topologie et fixer les valeurs des paramètres (par ex: taux d'apprentissage) est plus un *art* qu'une science.

5.6 Utilisation d'un Terme de Moment

La formule d'adaptation des poids synaptiques, fournie par l'algorithme de rétro-Propagation est souvent modifiée par l'ajout d'un terme de moment. Dans ce cas, la valeur d'un poids synaptique n'est plus seulement adaptée proportionnellement à la dérivée de la fonction de coût par rapport à ce poids, mais est également modifiée en fonction de la correction appliquée à l'instant précédent. Sous forme mathématique, la formule d'adaptation des poids synaptiques.

$$W_{l,ij}(\tau+1) - W_{l,ij}(\tau) = -\eta \frac{\partial E^{(k)}}{\partial W_{l,ij}} + \beta(W_{l,ij}(\tau) - W_{l,ij}(\tau-1)) \quad (2-20)$$

Cette expression peut être réécrite:

$$W_{l,ij}(\tau+1) - W_{l,ij}(\tau) = -\eta \sum_{q=0}^{\tau} \beta^q \frac{\partial E^{(k-q)}}{\partial W_{l,ij}} \quad (2-21)$$

η : est le taux d'apprentissage, $\eta > 0$.

E : fonction de coût à minimiser.

τ : Vecteur des variances générales des caractéristiques, avec : $\tau = [\sigma_1^2 \ \sigma_2^2 \ \dots \sigma_d^2]^T$

σ_i^2 : Est le paramètre de normalisation de ce neurone (W correspond ici aux coordonnées du centre de la Gaussienne).

β : $0 \leq \beta \leq 1$, est un paramètre qui est appelé *terme de moment* [40].

Grâce à l'utilisation d'un terme de moment, la direction de recherche du minimum à un instant donné, est une somme pondérée des gradients actuel et précédent. La pondération qui intervient, est telle que l'importance relative d'un gradient décroît exponentiellement au fur et à mesure que ce dernier est éloigné dans le temps. Le fait de prendre en compte plusieurs gradients consécutifs aide les poids synaptiques à traverser les sections plates de la surface de la fonction de coût, après qu'ils en aient descendu des sections abruptes (voir figure 2.13). Ceci permet en outre de modifier les poids synaptiques, non plus à l'aide d'un même taux d'adaptation pour l'ensemble de ceux-ci, mais selon un taux qui est propre à chaque poids, et qui est dépendant de son histoire particulière.

Les valeurs des paramètres η et β doivent être déterminées empiriquement, de manière à limiter la fréquence d'apparition de deux phénomènes qui sont opposés, mais qui conduisent tous deux à un net ralentissement de l'évolution de l'apprentissage.

D'une part, lorsque les valeurs de ces paramètres sont faibles, les poids synaptiques sont peu modifiés quand une région de faible pente de la fonction de coût est rencontrée; l'ensemble du système n'évolue alors que lentement.

D'autre part, lorsque les valeurs de ces paramètres sont élevées, des corrections d'amplitude importante sont appliquées aux poids synaptiques dans les régions de forte pente de la fonction de coût, ce qui peut entraîner une augmentation de la valeur de cette dernière. Il en résulte ainsi également un ralentissement de l'évolution de l'apprentissage.

L'apprentissage du perceptron multicouche nécessite donc une phase de méta-optimisation, au cours de laquelle des valeurs des coefficients a et b , conduisant au meilleur compromis entre ces deux situations extrêmes, doivent être recherchées.

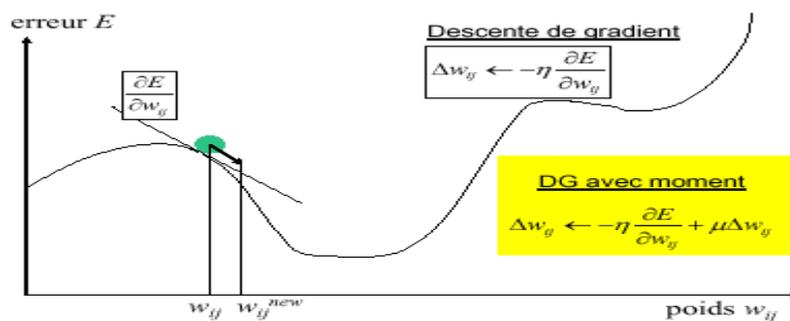


Figure 2.13 : Apprentissage avec l'utilisation du moment.

5.7 Les applications des réseaux de neurones

L'intérêt porté aujourd'hui aux réseaux de neurones tient sa justification dans les quelques propriétés intéressantes qu'ils possèdent et qui devraient permettre de dépasser les limites de l'informatique traditionnelle.

Pour cette raison les réseaux de neurones artificiels ont trouvé plusieurs applications et dans plusieurs domaines, parmi lesquels nous pouvons citer :

➤ L'application à la reconnaissance des formes

L'application des réseaux de neurones pour la reconnaissance des formes a été largement étudiée ; les réseaux de neurones multicouches sont intensivement étudiés et appliqués pour la reconnaissance des voies et des images [42, 43, 27].

➤ L'application à la planification

L'optimisation est souvent sollicitée pour la planification des actions ou des tâches.

A cet effet, l'utilisation du modèle de Hopfield et du modèle de Kohonen paraît très utile pour la résolution des problèmes d'optimisation [42].

➤ **L'application au traitement du signal**

Dans ce domaine, les applications réalisées traitent essentiellement de la reconnaissance de signatures radar ou sonar [42].

La société NESTOR a développé un réseau de neurones qui identifie une cible à coup sûr (100% de réussite) et reconnaît un bruit avec un taux de réussite de 95%.

Cette application a été construite à partir de signaux "sonar" et des traits caractéristiques de ces derniers sont déterminés par les experts comme étant utiles pour identifier une cible dans un environnement bruité. Le réseau agit dans ce cas comme un filtre pour éliminer le bruit.

➤ **L'application au contrôle**

Grâce à leurs propriétés (structures parallèles de traitement, capacité d'adaptation et de généralisation, etc.), les réseaux de neurones sont appliqués au contrôle intelligent. Les applications initiées peuvent être classifiées en plusieurs méthodes [44], tels que : le contrôle supervisé [38], le contrôle inverse et le contrôle neuronal adaptatif [42], [44]. D'un autre côté les réseaux de neurones sont ainsi appliqués à la commande vectorielle de la machine asynchrone par implémentation des régulateurs flous [41].

➤ **L'application au diagnostic**

Les réseaux de neurones sont bien adaptés à la résolution des problèmes de diagnostic et de surveillance industrielle, grâce à leur capacité de traitement non linéaire et leur simplicité à mise en œuvre. Dans ce contexte on distingue plusieurs applications des réseaux de neurones pour le diagnostic des défaillances [45, 46, 47, 48, 26] et en particulier, pour le diagnostic et la surveillance des lignes de production.

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.

A la lumière de l'étude effectuée, il a été constaté que les réseaux multicouches *feedforward* 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). Pour se faire le troisième chapitre est consacré à la modélisation neuronale proposée.

Chapitre III : Diagnostic et surveillance d'une ligne de production par les réseaux de neurones artificiels.

Introduction

L'automatisation du diagnostic et la surveillance en temps réel des lignes de production parmi les tâches les plus importantes afin d'assurer et rentabiliser la maintenance préventive de leurs équipements et leurs systèmes modernes, qui sont devenus de plus en plus complexes. En vu de cette industrie moderne, on trouve de nombreux chercheurs et industriels qui sont toujours à la recherche des nouvelles méthodes et techniques à mettre en place pour prévenir toutes défaillances pouvant être irréversibles pour leurs matériels.

Pour cette raison, nous sommes motivés à étudier un cas réel avec des données réelles, en utilisant ainsi l'une des méthodes pour diagnostiquer et surveiller l'unité de production pharmaceutique « BEKER Laboratoires Der El Beida-Alger (Algérie) ».

1 Présentation de laboratoire BEKER

Laboratoire BEKER est l'entreprise pharmaceutique de production des médicaments, implantée à (Der El Beida Algérie) depuis l'année 2005. Cette entreprise fabrique des médicaments en formes orales et solides (comprimé, gélules).

2 Description des ateliers des laboratoires BEKER

Laboratoire BEKER se compose de quatre (04) ateliers suivants :

- **Atelier A** : C'est le laboratoire de contrôle de qualité qui est chargé de vérifier la conformité des produits fabriqués par l'usine.

- **Atelier B** : C'est un atelier de production des médicaments, il est représenté par la ligne de production suivante :

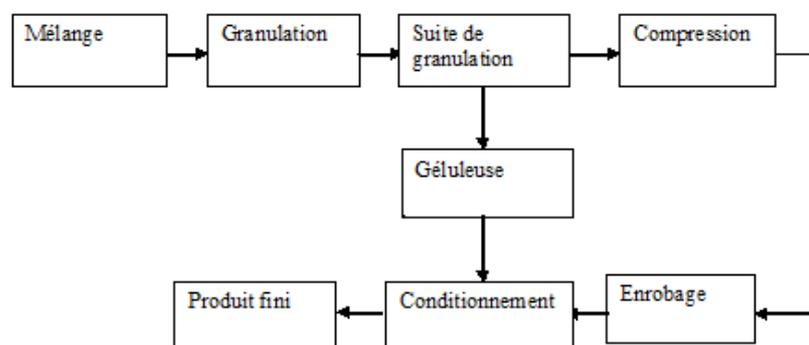


Figure 3.1 : Schéma représentant l'atelier de production.

- **Atelier C** : C'est le département de recherche et de développement galénique qui est destiné à la formulation et la mise en place des produits avant le passage à l'échelle pilote (production).

- **Atelier D** : C'est la zone qui regroupe les équipements des utilités suivantes : deux centrales de traitement d'air, centrale de l'eau glacée, chaudière et compresseur d'air.

- **Remarque**: le compresseur d'air alimente tous les équipements de l'usine.

3 Le choix de l'équipement à étudier

La figure 3.2 représente la ligne de production pharmaceutique principale ainsi que ses différentes zones et équipements. Cette ligne comprend un compresseur d'air qui alimente toutes les machines de production, tous les équipements de recherche et de développement et la majorité des appareils de laboratoire de contrôle de qualité.

Le compresseur d'air est l'équipement le plus stratégique de cette ligne, de ce fait toute panne du compresseur causera l'indisponibilité de tous les équipements de l'usine. En plus, le respect des bonnes pratiques de fabrication et le critère de qualité sont très important dans l'industrie pharmaceutique, d'où la précision des paramètres physiques (pression, température,...) du process l'une des exigences de cette industrie. On comprend alors, la pression de l'air comprimé doit être exacte et tolérée selon les normes et la réglementation internationale de fabrication des médicaments. Donc, la surveillance du compresseur d'air, en temps réel avec la technique des réseaux de neurones artificiels, sert comme outil de base pour l'aide à la décision.

Compte tenu de l'importance de tout ce qui précède, nous avons choisi de surveiller et de diagnostiquer le compresseur d'air avec la méthode des réseaux de neurones artificiels, ce qui fait l'objet de notre étude.

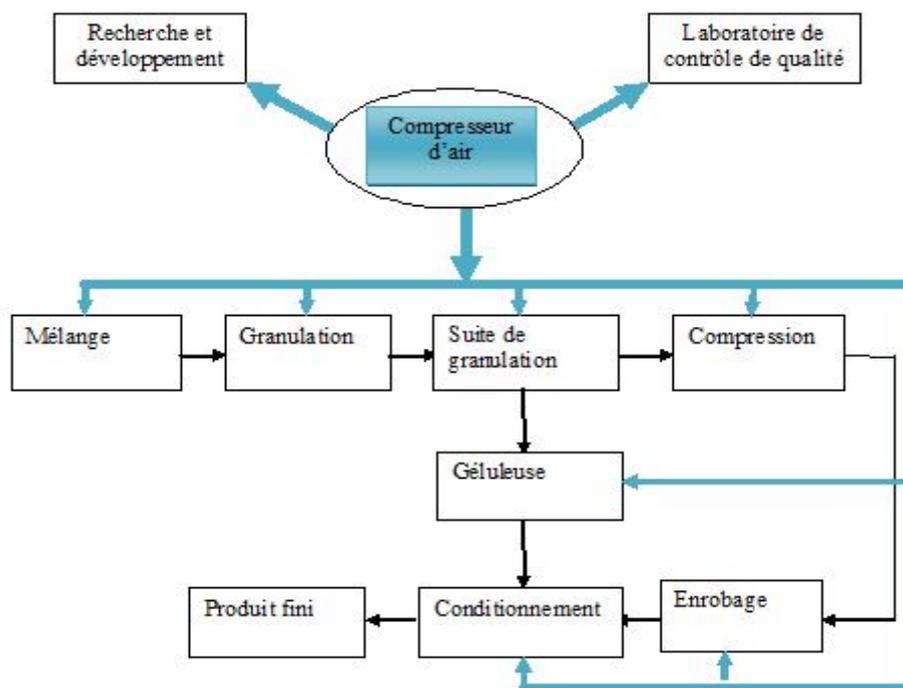


Figure 3.2: Schéma représentant la ligne de production de laboratoire BEKER.

4 Principe de fonctionnement de compresseur d'air

Le compresseur d'air est de type bi-étagés rotatifs à lobes entraînés par le moteur électrique. Le compresseur comprime l'air de l'extérieur en deux étapes ; l'air entre dans la partie de basse pression va être refroidi dans le refroidisseur intermédiaire puis, il entre dans la partie de haute pression. En fin, l'air sort du compresseur, après avoir baissé sa température dans le refroidisseur final, avec une pression de 7 bars. Cette dernière va être distribuée via la tuyauterie vers toutes les machines de la ligne de production si dessus.

Le compresseur d'air est le pivot de la production puisque sans la présence de pression aucune machine n'est en marche. En plus, la précision et la stabilité de la pression de l'air comprimé dans les machines lors de la fabrication des médicaments sont impératives et primordiales dans cette ligne de production pharmaceutique. Pour toutes ces raisons, la surveillance en temps réel du compresseur d'air est la meilleure stratégie pour maintenir la production des médicaments à son optimum.

La figure 3.3 représente, en général, tous les composants du compresseur et ces principaux circuits :

- Circuit d'air
- Circuit de lubrification.

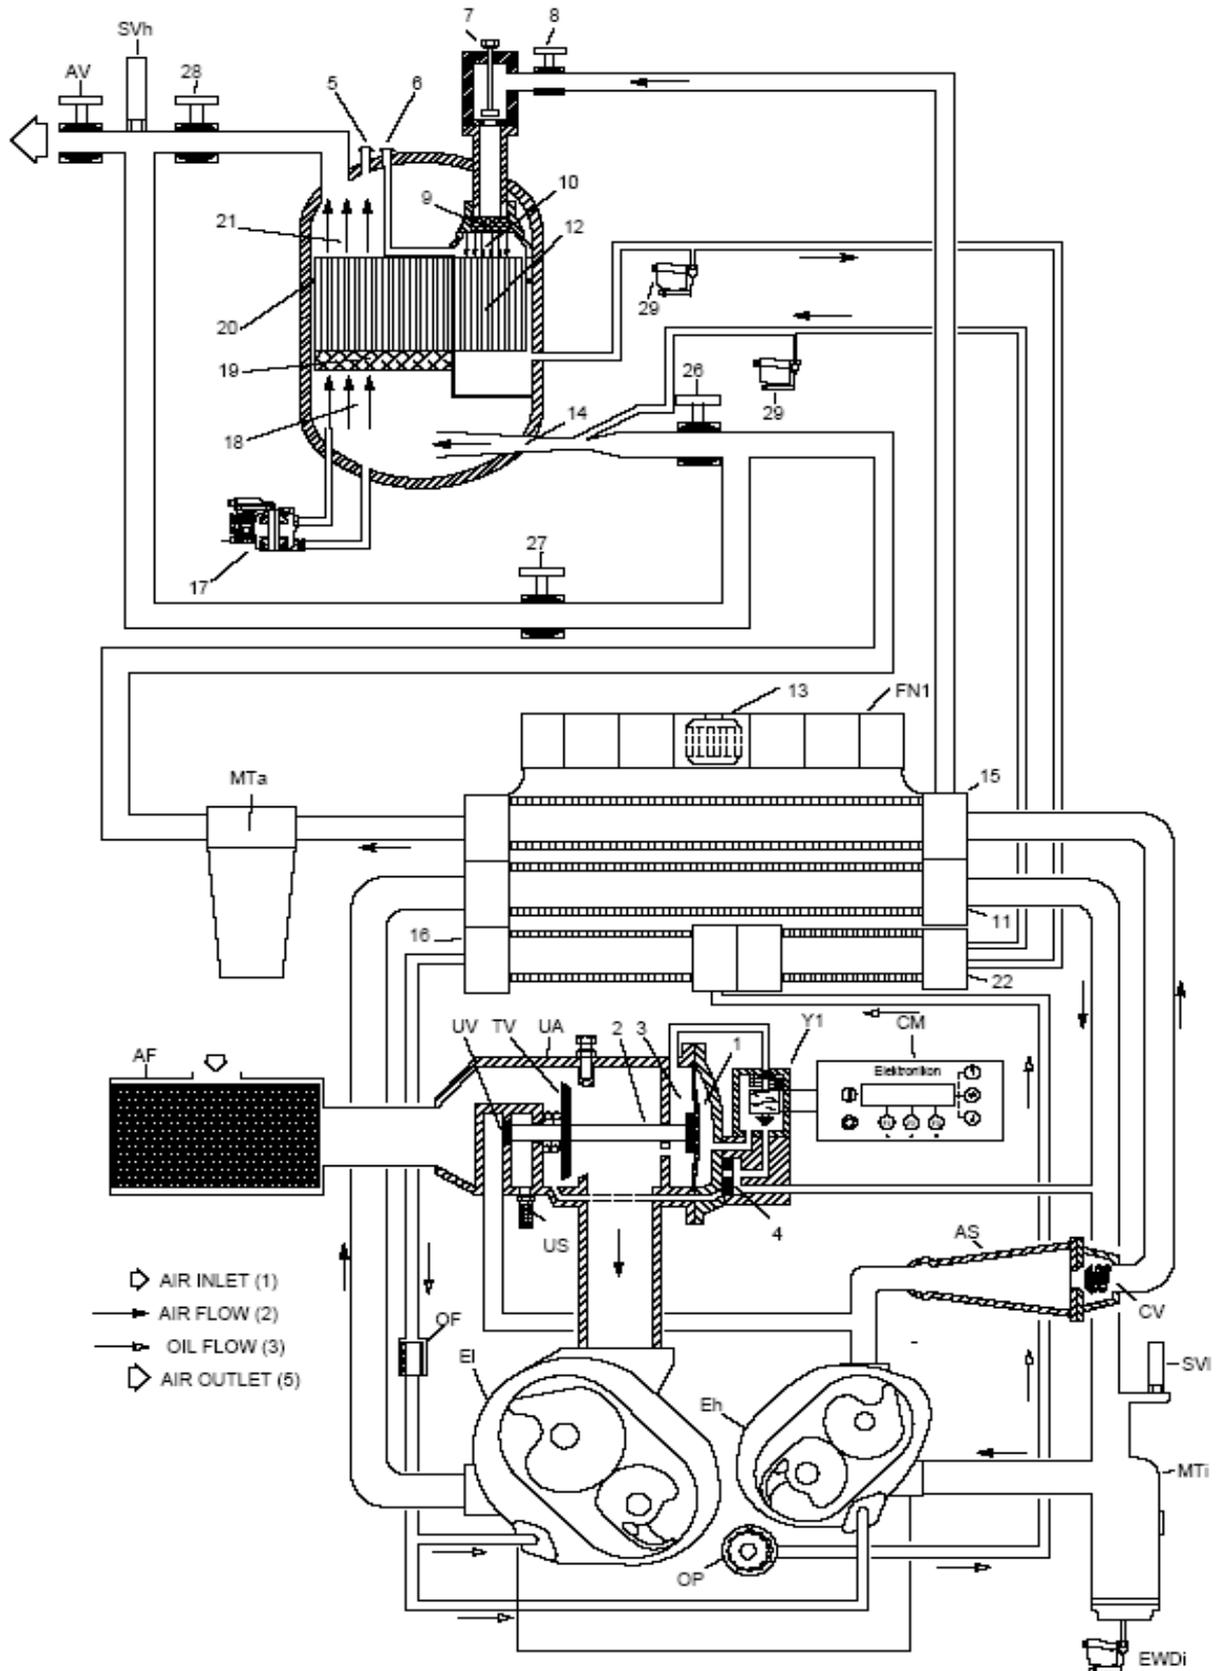


Figure 3.3: Schéma d'écoulement/système de régulation du compresseur d'air.

5 Légende du schéma d'écoulement/système de régulation du compresseur

- AF : Filtre à air
- AS : Amortisseur de pulsations
- AV : Vanne de sortie d'air
- CM : Régulateur Elektronikon
- CV : Clapet anti-retour
- Eh : Elément compresseur haute pression
- El : Elément compresseur basse pression
- EWDi : Purge électronique des condensats, refroidisseur intermédiaire
- FN1 : ventilateur
- MTa : Réservoir des condensats, refroidisseur final
- MTi : Réservoir des condensats, refroidisseur intermédiaire
- OF : Filtre à huile
- OP : Pompe à huile
- SVh : Soupape de sécurité haute pression
- SVi : Soupape de sécurité basse pression
- TV : Valve « tout/rien »
- UA : Déchargeur
- US : Silencieux
- UV : Soupape de décharge
- Y1 : Electrovalve de mise en charge
- 1 : Chambre
- 2 : Plongeur
- 3 : Chambre
- 4 : Diaphragme
- 5 : Vanne pour la connexion (+), jauge de différence de pression
- 6 : Vanne pour la connexion (-), jauge de différence de pression
- 7 : Vanne d'étranglement, entrée d'air de régénération
- 8 : Vanne d'arrêt, entrée d'air de régénération chaud
- 9 : Tamis
- 10 : Secteur étanche, entrée d'air de régénération (coté non saturée)
- 11 : Refroidisseur intermédiaire
- 12 : Rotor
- 13 : Moteur du ventilateur, refroidisseurs d'air
- 14 : Ejecteur
- 15 : Refroidisseur final
- 16 : Refroidisseur d'huile
- 17 : Purge électronique des condensats, air d'entrée
- 18 : Séparateur d'eau, air d'entrée
- 19 : Dispositif antibuée
- 20 : Dispositif d'étanchéité du rotor
- 21 : Compartiment de sortie d'air sec

- 22 : Refroidisseur d'air de régénération
- 23 : Vanne de régulation, refroidisseur d'huile et débit d'eau de refroidissement du refroidisseur intermédiaire
- 24 : Vanne de régulation, débit d'eau de refroidissement du refroidisseur final
- 25 : Vanne de régulation, débit d'eau du refroidisseur d'air de régénération
- 26 : Vanne d'entrée d'air du sécheur IMD
- 27 : Vanne de dérivation du sécheur IMD
- 28 : Vanne de sortie du sécheur IMD
- 29 : Purge électronique, refroidisseur d'air de régénération
- 30 : Vanne de fermeture d'eau, sortie d'eau
- 31 : Vanne d'arrêt, entrée d'eau

6 Les paramètres du compresseur d'air

Le compresseur d'air comprend plusieurs capteurs de pression et de température qui sont :

- PT45 : capteur de pression d'huile ;
- PDT02 : capteur de pression du filtre à air ;
- PT29 : capteur de pression, air sortie compresseur ;
- TT11 : capteur de température, sortie élément basse pression ;
- TT18 : capteur de température, entrée élément haute pression ;
- TT21 : capteur de température, sortie élément haute pression.

Les positions des capteurs sont fixées d'après le constructeur. Pour bien connaître ces positions, nous avons les schématisé dans la fig.3.4.

La figure 3.4 montre aussi les deux circuits du compresseur (circuit d'air qu'est en bleu et circuit de lubrification qu'est en rouge) et ces principaux composants qui sont : filtre à air, filtre d'huile, la pompe d'huile « P », le carter d'engrenages (élément basse et haute pression) et les refroidisseurs (refroidisseur d'huile « PH », refroidisseur intermédiaire « RI » et refroidisseur final « RF »).

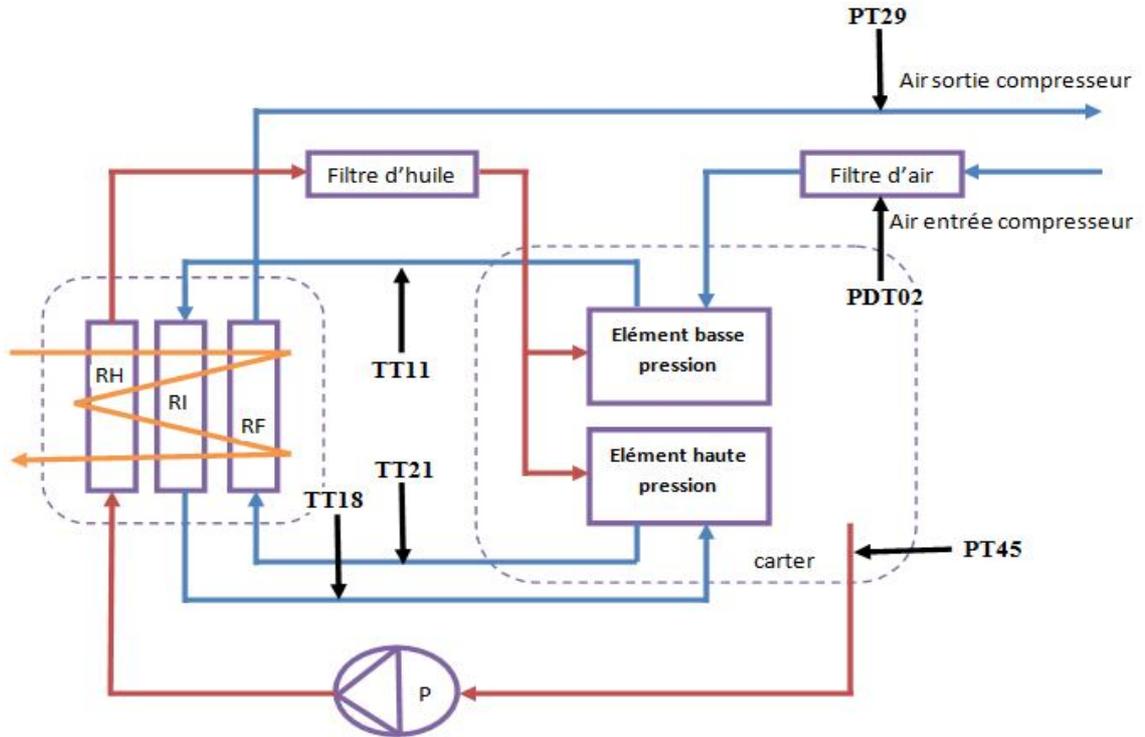


Figure 3.4: Schéma représente le positionnement des capteurs du compresseur d'air soumis à la surveillance.

A la lumière de l'importance des informations transmises par ces différents capteurs, nous allons les exploiter dans notre étude pour diagnostiquer et surveiller en temps réel le compresseur d'air. En effet, toute valeur en dehors des plages de fonctionnement des capteurs sera interprétée comme un défaut à signaler. Les plages de fonctionnement de ces derniers sont données par le constructeur et sont données dans le tableau 3.1.

Tableau 3.1 : Tableau des plages de fonctionnement des capteurs du compresseur d'air.

les paramètres du compresseur	Valeur minimale	Valeur nominale	Valeur maximale
Circuit de lubrification			
PT45 capteur de pression, huile	1.5 bars	2 .5 bars	2.7 bars
Circuit d'air			
PDT02 capteur de pression, filtre à air (ΔP)	-0.100bar	-0.044bar	-0.044bar
PT29 capteur de pression, air de sortie	4 bars	7 bars	7 .3 bars
TT11 capteur de température, sortie élément BP	100 °C	220 °C	225 °C
TT18 capteur de température, entrée HP	60°C	65°C	75°C
TT21 capteur de température, sortie élément HP	100°C	220°C	225°C

7 Argumentation du choix des paramètres

Les indicateurs des pannes du compresseur d'air sont les variations des deux paramètres physiques, la pression et la température.

7.1 Choix des paramètres du circuit de lubrification

Dans le circuit de lubrification, la variation de la pression d'huile causera des pannes qui peuvent être réversibles ou irréversibles pour le compresseur d'air. Ces causes peuvent être dues soit à :

- La qualité d'huile utilisée (mauvaise viscosité de l'huile) ou une baisse de niveau d'huile dans le carter d'engrenages.
- La pompe d'huile est défectueuse.
- Le filtre d'huile est encrassé.
- Le refroidisseur d'huile est sale.
- Système de refroidissement d'huile moteur-ventilateur ne fonctionne pas.

Toutes ces informations seront utilisées dans le diagnostic de ce circuit de lubrification. Donc le choix du paramètre « pression d'huile » est très efficace dans le diagnostic du circuit de lubrification.

7.2 Choix des paramètres du circuit d'air

Les paramètres du circuit d'air sont : la pression du filtre à air, température de la sortie élément basse pression, température de l'entrée élément haute pression, température de la sortie élément haute pression et la pression de sortie du compresseur (la pression du réseau).

Le choix du paramètre « pression du filtre à air » est important, puisqu'il nous aide à surveiller l'état du filtre.

Les températures sont très utiles dans le diagnostic industriel, car dans les parties mécaniques le défaut se manifeste par l'augmentation des températures (par exemple le frottement entre deux pièces mécaniques engendre une augmentation de température).

La pression de sortie du compresseur (pression du réseau) donne une bonne information sur l'état final du compresseur. Et là encore le choix de ce paramètre s'avère être très judicieux dans la surveillance industrielle.

Remarque: L'air comprimé est un gaz réel, alors la variation de la pression d'air est proportionnelle à la variation de la température (d'après les lois de la thermodynamique). Et d'après le constructeur (Atlas Copco), il est important de prendre en considération cette hypothèse pour bien choisir les paramètres à surveiller.

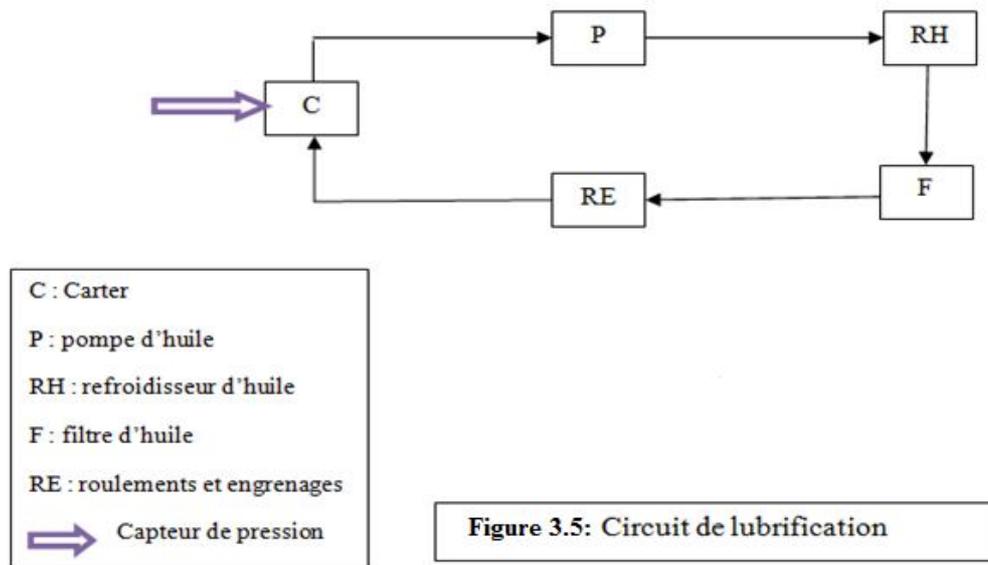
8 Modélisation du compresseur d'air

Le compresseur d'air se compose de deux circuits principaux, le circuit de lubrification et le circuit d'air. Pour la mise en œuvre de notre étude, nous allons procéder par la décomposition du compresseur en deux parties A et B.

La partie A : circuit de lubrification

Dans cette partie nous allons présenter la modélisation du circuit de lubrification dans la Fig.3.7 et ses différents composants. En effet, la pompe d'huile aspire l'huile du carter d'engrenages pour la refroidir dans le refroidisseur d'huile. Ensuite, cette l'huile passe via le filtre pour lubrifier enfin les engrenages et les roulements de synchronisation.

Le capteur de pression placé au niveau du carter mesure en permanence la valeur de la pression d'huile. Toute valeur en dehors de cette plage de fonctionnement [1.5 - 2.7] bars est un défaut à signaler. Donc, ce dernier paramètre est l'indicateur de panne pour ce circuit de lubrification. Pour bien diagnostiquer cette partie, il est recommandé de surveiller en temps réel ce paramètre de pression d'huile, qui est l'entrée du réseau neuronal.

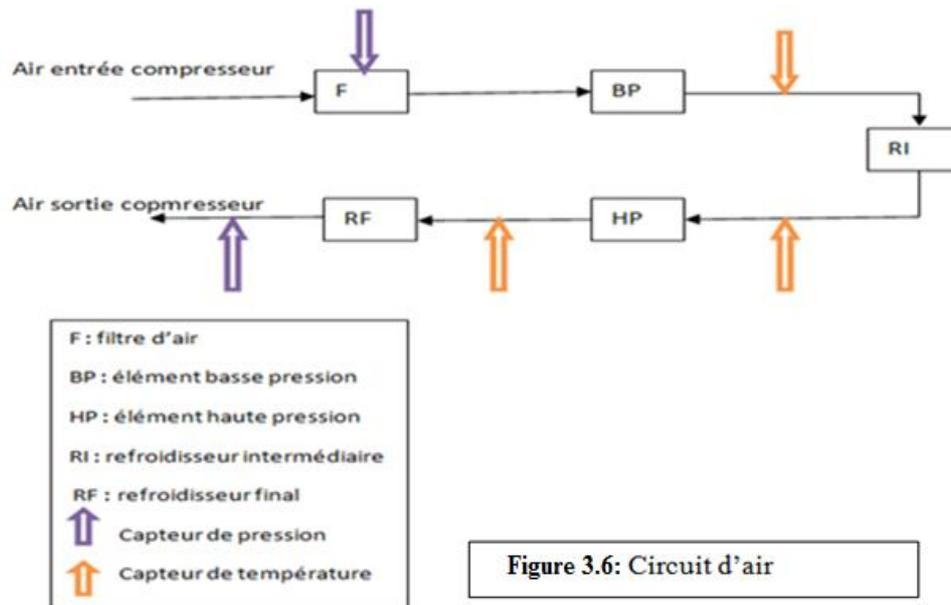


La partie B : circuit d'air

Nous présentons dans la Fig.3.8 le circuit d'air et les positions des capteurs. Le circuit comprend (03) capteurs de température (température sortie basse pression, température entrée élément haute pression et température sortie élément haute pression) et (02) capteurs de pression (pression du filtre à air et pression de sortie du compresseur).

Les indicateurs des pannes pour cette partie sont les variations des valeurs de pression et de température, c'est-à-dire toute valeur en dehors de la plage de fonctionnement de l'un des capteurs précédents est un dysfonctionnement.

Ici dans notre cas, La pression d'air de sortie du compresseur est la conséquence des variations des valeurs de température, c'est-à-dire toute variation de température au niveau du circuit d'air engendre une variation au niveau de la pression d'air de sortie du compresseur. Pour cette raison, nous sommes amenés à surveiller en permanence les pressions pour la détection du défaut en utilisant les réseaux de neurones artificiels et ajouter un programme en parallèle sous forme des contraintes sur les températures pour la localisation du défaut.



9 L'approche neuronale

L'approche que nous avons choisie pour diagnostiquer le compresseur d'air est « les réseaux de neurones artificiels RNA ». Grâce à leur capacité de généralisation, et de classification, il est possible d'effectuer un apprentissage au réseau, pour pouvoir détecter ultérieurement les zones de bon et de mauvais fonctionnement. Donc avoir la possibilité de surveiller le compresseur d'air en temps réel.

Le compresseur comprend deux parties essentielles ; partie A « circuit de lubrification » et partie B « circuit d'air ». Pour mettre en place notre étude, nous allons surveiller les deux dernières parties A et B par la méthode des réseaux de neurones artificiels.

Cette approche, consiste à diagnostiquer et à surveiller en permanence les deux circuits du compresseur en parallèle, en appliquant ainsi un modèle neuronal pour chaque circuit. En effet, les valeurs issues par les capteurs sont les valeurs d'entrées pour les réseaux de neurones et leurs sorties soit un bon fonctionnement que nous assimilons à « 1 » ou un mauvais fonctionnement que nous assimilons à « -1 ».

Les deux modèles que nous avons élaboré, seront représentés dans les deux parties qui suivent:

La partie A : circuit de lubrification

Le modèle proposé pour cette partie est de type réseau multicouches à rétro-propagation du gradient « 1-12-1 », comportant une couche d'entrée avec 1 neurone, une couche cachée avec 12 neurones et une couche de sortie avec 1 neurone. L'optimisation du modèle neuronal est aléatoire à chaque fois en réagissant soit :

1. En variant le nombre de neurones de la couche cachée [48], puis nous allons comparer toutes les différentes architectures. Suite à cette étude comparative, qui est précédée de plusieurs tests d'apprentissage, nous avons jugé que le modèle avec 12 neurones

dans la couche cachée est le plus optimale (il converge rapidement et donne de bons résultats, avec une erreur de l'ordre de 10^{-3} , lors de l'apprentissage. En évitant ainsi le phénomène de sur-apprentissage).

2. En initialisant plusieurs fois les valeurs de poids aléatoirement.
3. En variant le nombre d'itération qui a été fixé à 1300 itérations.

L'entrée du réseau (1-12-1) est la pression d'huile à surveiller et la sortie du réseau soit '1' ou '-1' à détecter.

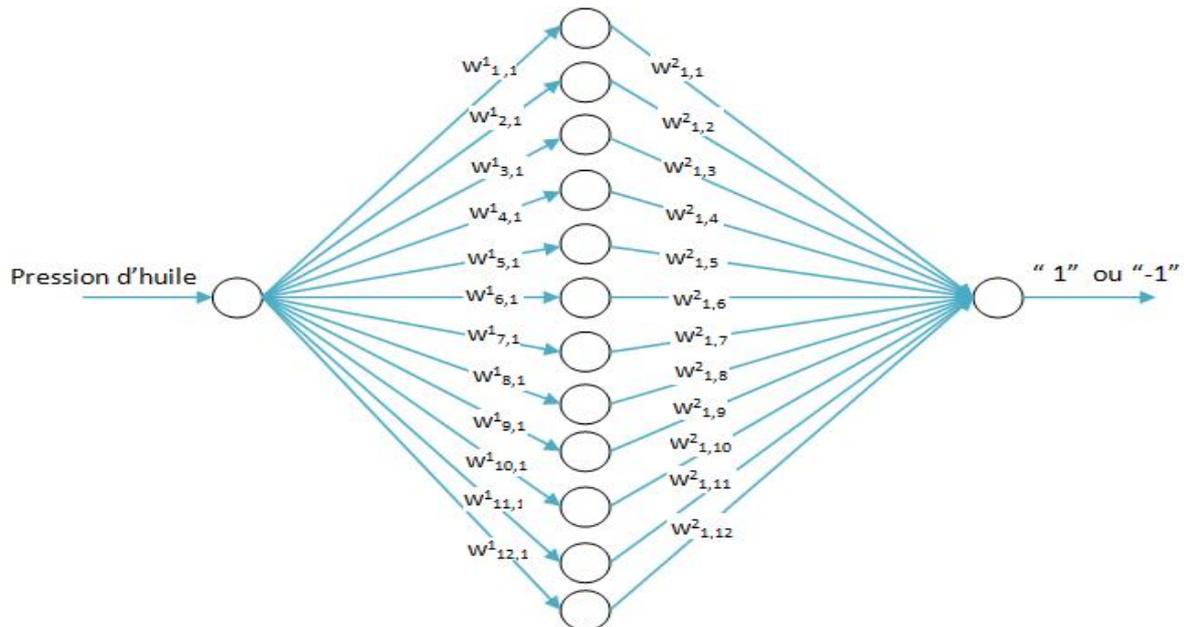


Figure 3.7: Modèle neuronal du circuit de lubrification « 1-12-1 ».

La partie B : circuit d'air

Le modèle proposé pour cette partie est de type réseau multicouches à rétro-propagation du gradient « 2-15-1 », comportant une couche d'entrée avec 2 neurones, une couche cachée avec 15 neurones et une couche de sortie avec 1 neurone. Ce modèle neuronal est optimisé de la même façon que le modèle du circuit de lubrification.

Dans cette partie nous avons utilisé deux (2) capteurs de pression pour la détection de défaut et trois (3) capteurs de températures pour la localisation de défaut en deux phases suivantes :

Première phase : détection de défaut

Pour détecter le défaut dans cette phase nous allons surveiller uniquement les pressions (la pression d'air de l'entrée et de la sortie du compresseur) qui sont les entrées du modèle neuronal « 2-15-1 ».

Deuxième phase : localisation de défaut

Pour localiser le défaut nous avons mis un programme de localisation qui fonctionne avec le réseau de neurones. Une fois que le réseau « 2-15-1 » détecte un défaut, le programme sera exécuté. Ce dernier affiche soit : {BF}, {MFTT11 et MFTT21 et MFTT18}, {MFTT11 et MFTT21}, {MFTT11 et MFTT18}, {MFTT18 et MFTT21}, {MFTT11}, {MFTT21}, {MFTT18}. Donc, le programme localise la zone de mauvais fonctionnement.

Avec :

BF : Bon Fonctionnement ;

MFTT11 : Mauvais Fonctionnement détecté par le capteur de température TT11 ;

MFTT18 : Mauvais Fonctionnement détecté par le capteur de température TT18 ;

MFTT21 : Mauvais Fonctionnement détecté par le capteur de température TT21.

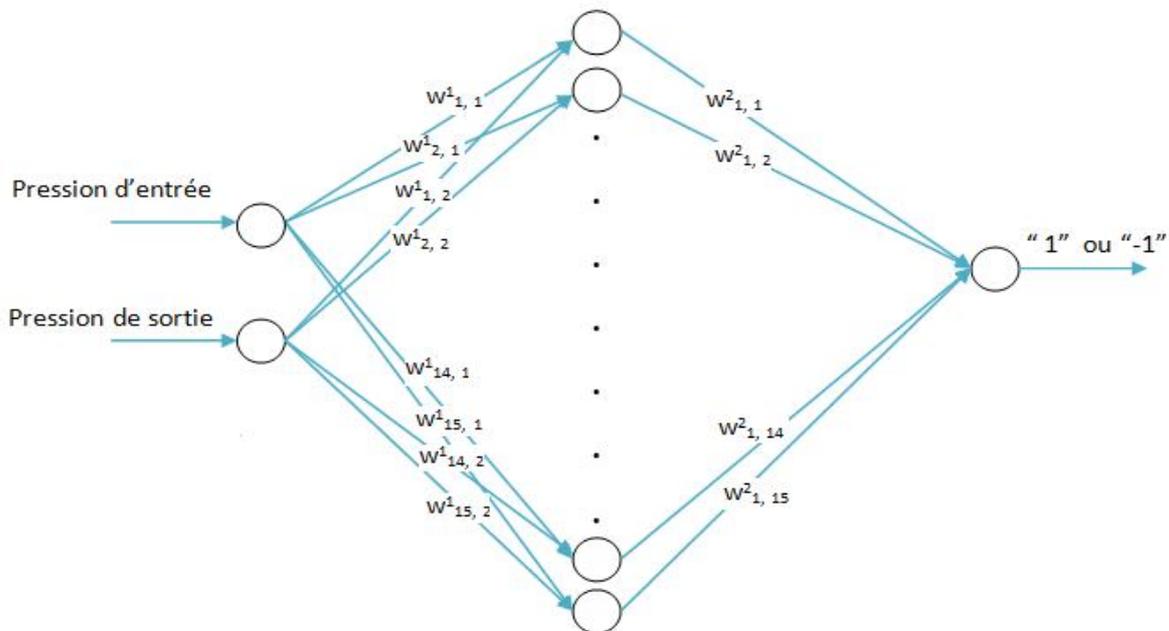


Figure 3.8: Modèle neuronal du circuit d'air « 2-15-1 ».

10 Type de réseau choisi

Les réseaux de neurones multicouches (*feed-forward*) sont les plus appropriés pour le diagnostic et la surveillance des systèmes de production. De par leurs différentes couches et particulièrement leurs couches cachées, où nous pouvons varier le nombre de neurones de telle manière à accélérer la convergence lors de l'apprentissage et d'éviter le phénomène de sur-apprentissage, nous sommes motivés de leur application pour les deux parties A et B du compresseur d'air.

11 Apprentissage du réseau

a. Type d'apprentissage

Le type d'apprentissage est l'apprentissage supervisé (comme définit au chapitre 2). Donc il est nécessaire d'obtenir pour chaque apprentissage de chaque fonction un vecteur de sortie. Ce vecteur contient les valeurs des sorties désirées (les cibles), que le réseau de neurone devra atteindre au cours de l'apprentissage.

b. Principe de l'apprentissage

L'algorithme de rétro-propagation du gradient, permet de fournir les paramètres (poids et biais) qui sont efficacement utilisés par le réseau pour atteindre les valeurs de sorties désirées (les valeurs des sorties désirées appartiennent à l'ensemble $[-1, 1]$). Ceci est possible, si l'apprentissage du réseau a été simulé pour un nombre suffisant d'itération pour assurer la convergence. Donc, à partir des données issues par les capteurs qui sont des valeurs d'entrées du réseau, nous pouvons apprendre au réseau les sorties désirées $[-1, 1]$. Le -1 représente mauvais fonctionnement et le 1 représente le bon fonctionnement du compresseur.

12 Les paramètres d'apprentissage

a. L'erreur (goal)

C'est l'erreur à atteindre par la fonction de coût. Dans notre cas, nous choisissons l'erreur de l'ordre de 0.001 pour le modèle du circuit de lubrification et 0.01 pour le modèle du circuit d'air.

b. Le nombre d'itération

Le nombre d'itération c'est le nombre pour lequel l'algorithme de rétro-propagation est effectué. Il se peut que le réseau converge avant que le réseau n'éteigne les itérations prédéfinies. Ou dans le cas contraire, il ne converge pas du tout. Dans cette étude, nous avons fixé 1300 itérations pour le réseau (1-12-1) et 3500 itérations pour réseau (2-15-1).

c. La fonction d'activation

Nous utilisons la fonction d'activation de type sigmoïde bipolaire, non linéaire et croissante, permet d'introduire un seuil et une saturation pour limiter les amplitudes des sorties du réseau entre $[-1, 1]$. Cette fonction d'activation est la suivante :

$$F(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

d. Le taux d'apprentissage

La performance de l'algorithme de rétro-propagation du gradient est très sensible aux changements du taux d'apprentissage. Si ce dernier est très élevé, l'algorithme peut devenir instable, et s'il est trop petit, l'algorithme prendra un temps trop long pour converger.

Pratiquement il est difficile de déterminer le taux d'apprentissage optimal avant l'entraînement du réseau.

e. Le moment (mc)

Le moment est utilisé pour remédier aux minimums locaux, il est généralement compris entre 0 et 1, (l'explication détaillées du moment est dans le chapitre 2). Dans notre approche, nous avons utilisé le moment uniquement pour le réseau (2-15-1) et sa valeur égale 0.8.

13 Algorithme de rétro-propagation du gradient

Pour la mise en œuvre de l'apprentissage du réseau par l'algorithme de rétro-propagation du gradient, nous avons appliqué l'algorithme suivant les étapes :

Etape 1 : lecture des valeurs des ensembles Entrée/Sortie normalisées.

Etape 2 : nombre des cellules (couche d'entée, couche cachée et couche de sortie).

Etape 3 : initialisation aléatoire des valeurs de poids et biais.

Etape 4 : nombre d'itérations (NB) et le gain d'apprentissage (G).

Etape 5 : calcul d'erreur à rétro-propager.

Etape 6 : modification (ou adaptation) des poids et biais.

Etape 7 : résultats d'apprentissage.

Afin de vérifier la détection de la région du bon (1) et mauvais (-1) fonctionnement, nous avons utilisé diverses valeurs dans la phase de test définie par les graphes 'base de test'.

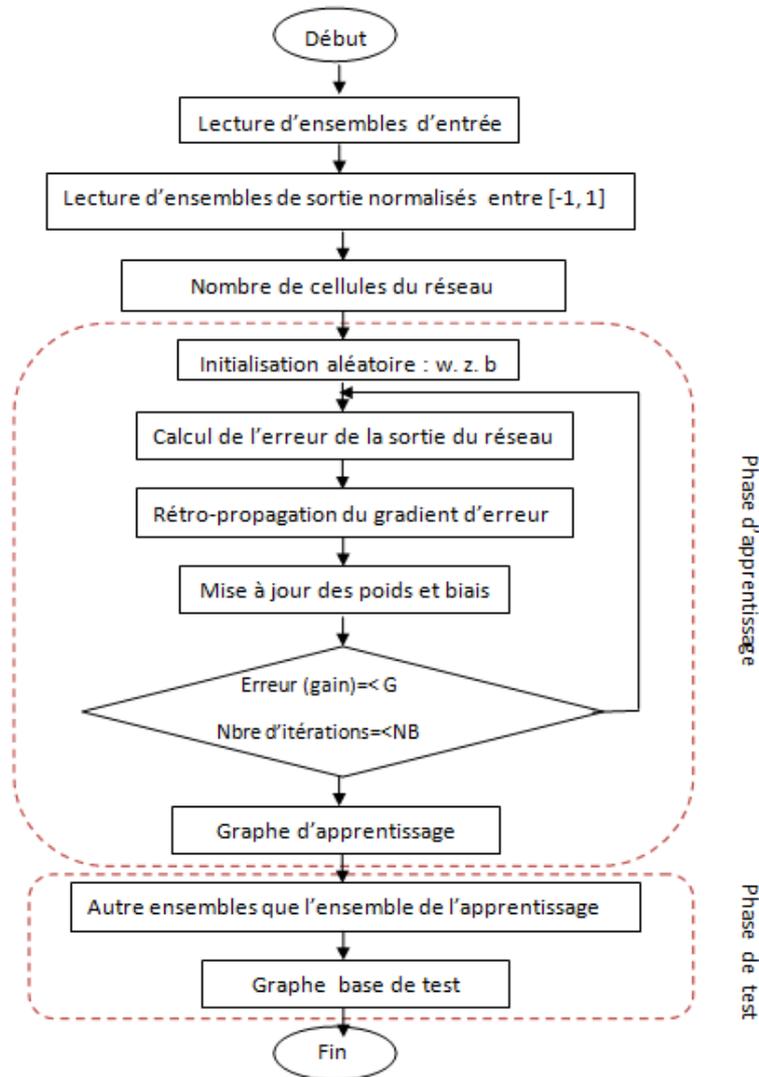


Figure 3.9: Organigramme de l'algorithme de rétro-propagation du gradient.

14 Simulation de l'apprentissage

Après l'apprentissage, il y a des réseaux qui convergent mais qui n'offrent pas une bonne généralisation. La simulation des sorties du réseau après apprentissage permet d'évaluer la qualité de ce dernier. Des figures qui représentent les zones de bons et de mauvais fonctionnement, sont illustrés pour pouvoir juger s' il y a eu un bon ou un mauvais apprentissage du réseau. Cette simulation confirme les caractéristiques de classification et de séparation non linéaire des réseaux multicouches. Un exemple dans la Fig.3.10, montre la séparation non linéaire entre la classe « + » et la classe «-».

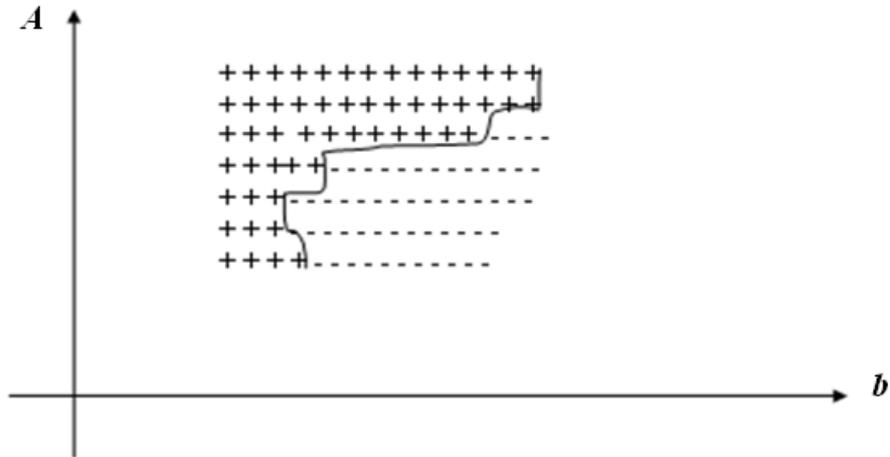


Figure 3.10 : Classification et séparation non linéaire entre deux classes.

15 Evaluation des performances des réseaux de neurones

Nous avons choisi d'évaluer les performances des réseaux qui ont fait l'apprentissage, Par la méthode de la régression linéaire entre les sorties du réseau et les sortie désirées (cibles).

$$\text{Avec } A = m T + b$$

A : Les sorties du réseau.

T : les cibles (targets).

m : La pente.

b : La meilleure régression linéaire reliant les cibles aux sorties du réseau.

- Dans le cas d'un ajustement parfait (cibles = sorties du réseau), $m = 1$ et $b=0$.
R : Coefficient de corrélation.
- Plus R est proche de 1 plus nous aurons un bon ajustement entre les cibles et les sorties du réseau.

Exemple :

Dans cet exemple (Fig.3.11), La superposition entre la ligne continue et la ligne en pointillé traduit une corrélation presque parfaite entre les sorties du réseau (qui sont illustrées par des cercles), après entraînement et les cibles.

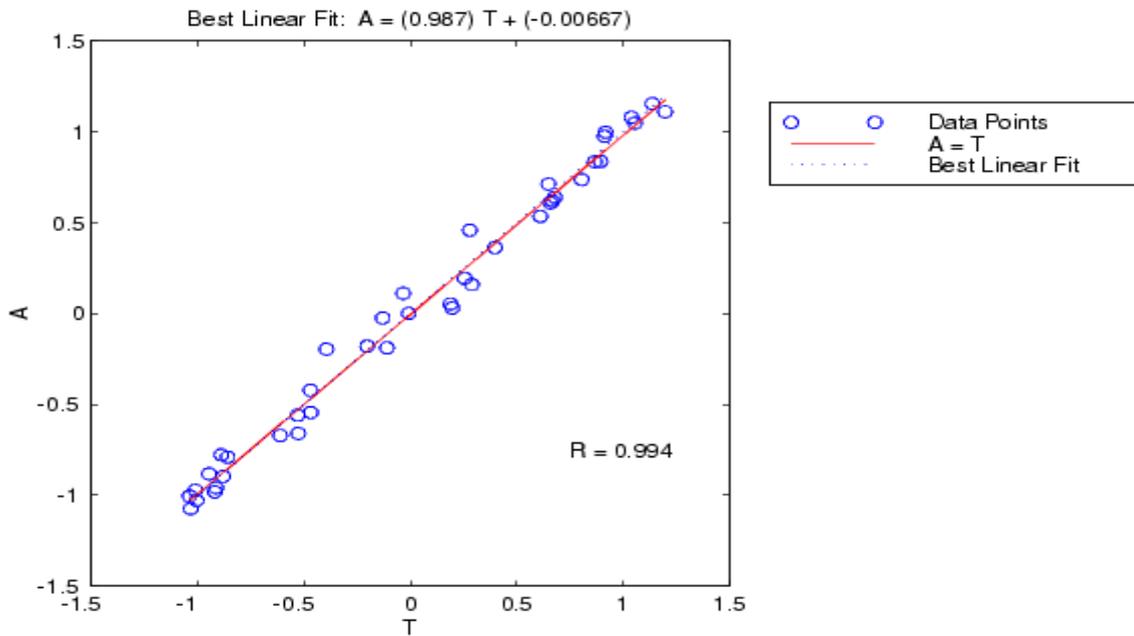


Figure 3.11 : Les performances d'un réseau de neurone par la méthode de la régression linéaire.

Conclusion

Dans ce chapitre nous avons élaboré une étude de cas réel, ou nous avons mis en exergue toutes les parties de notre ligne de production ainsi que tous les paramètres à surveiller. Et encore, nous avons expliqué étape par étape notre approche neuronale de manière à rendre accessible la compréhension de notre stratégie pour aboutir à un diagnostic efficace et fiable d'un point de vue technique et économique.

La simulation, les résultats, les graphes et conclusion seront présentés en détail dans le chapitre suivant.

Chapitre IV : Simulation et résultats

Introduction

Dans le chapitre précédant, nous avons consacré pour la présentation de la ligne de production, le choix de l'équipement étudié, l'importance des paramètres surveillés et l'approche neuronale appliquée. Dans ce chapitre, nous allons procéder par la simulation de l'entraînement des réseaux de neurones. Nous utiliserons ainsi l'apprentissage supervisé et la programmation sera entièrement faite sous MATLAB 7.0.

Après l'apprentissage, les zones de bon et de mauvais fonctionnement seront illustrées, suite à des nombreux tests effectués avec d'autres ensembles d'entrées que ceux utilisés dans la phase d'apprentissage. Tous les paramètres surveillés ainsi que leurs valeurs sont données dans ces deux parties A et B.

1 Partie A : circuit de lubrification

Dans cette partie, nous mettrons en place la simulation de l'entraînement du modèle neuronal (1-12-1). En commençant ainsi par la simulation de l'apprentissage du réseau, la simulation des sorties du réseau et en faisant des bases de tests pour la généralisation du réseau. Par la suite, nous montrerons l'évaluation des performances du réseau (1-12-1).

La pression d'huile du carter d'engrenages du compresseur est le paramètre important à surveiller dans ce circuit de lubrification. Alors, les valeurs de la pression d'huile sont le vecteur d'entrée du réseau neuronal (1-12-1).

La valeur de la pression varie entre 1.5 et 2.7 bars, donc en dehors de cette plage de fonctionnement nous aurons un défaut à détecter par le réseau neuronal (1-12-1).

a. Apprentissage

La simulation de la phase de l'apprentissage du réseau (1-12-1) est présentée dans la Fig.4.1. Cette dernière montre que l'apprentissage converge au bout de 240 itérations avec une erreur de 0.001. Ceci, explique la rapidité de l'apprentissage du réseau neuronal (1-12-1).

De point de vu mathématique, la Fig.4.1 montre que la fonction de coût R (voir le chapitre 2) converge et se stabilise entre deux passages successifs de l'ensemble des données d'entrées et de sorties du réseau, de telle manière que cette dernière est minimisée avec une erreur de 0.001 pour que le réseau atteigne les sorties désirées (du fait que nous avons utilisé l'apprentissage supervisé).

La stabilisation de la fonction coût R entre les deux passages successifs de l'ensemble des données entrées/sorties est donnée par la règle d'arrêt suivante : $\Delta R < \epsilon$ avec, ϵ : erreur d'apprentissage.

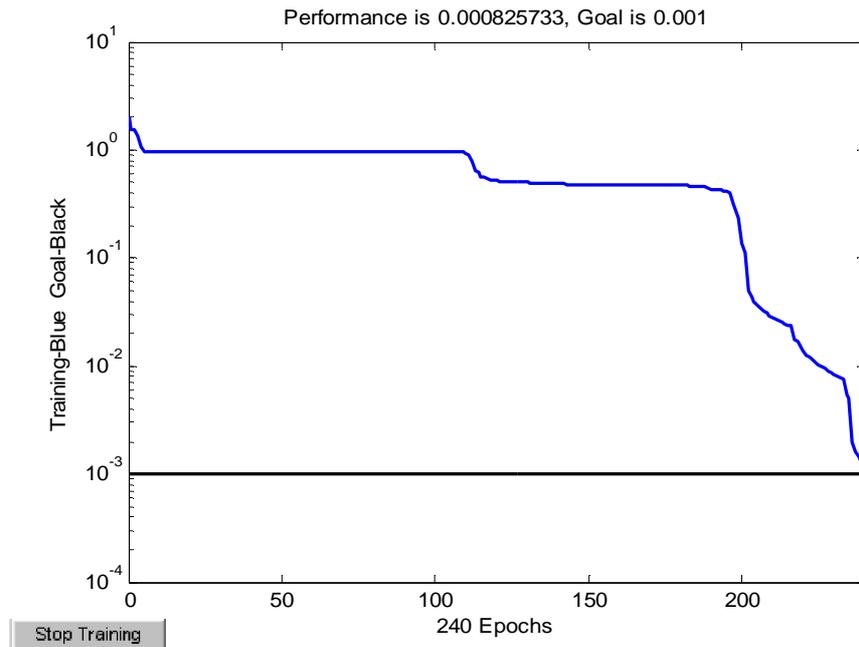


Figure 4.1 : Simulation d'entraînement du réseau (1-12-1).

b. Simulation des sorties du réseau (1-12-1)

Après apprentissage nous simulons les sorties du réseau entraîné, la Fig.4.2 montre l'allure de la courbe d'apprentissage des sorties désirées.

Dans la Fig.4.2 nous observons que toutes les valeurs de l'ensemble de bon fonctionnement sont situées à « 1 » et celles de mauvais fonctionnement sont situées à « -1 ». Ceci montre que le réseau a reconnu efficacement les sorties désirées.

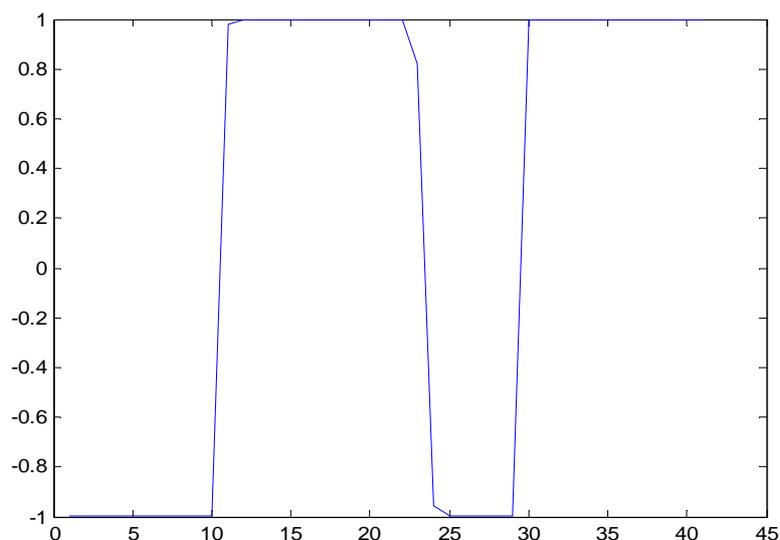


Figure 4.2 : Simulation des sorties du réseau (1-12-1) après apprentissage.

La figure 4.3 représente les sorties du réseau d'une manière discontinue avec les mêmes valeurs de l'ensemble d'entrée précédente. Cette présentation nous permettra de reconnaître le positionnement de toutes les valeurs de la sortie du réseau. Alors, la Fig.4.3 montre efficacement que les sorties du réseau sont identiques aux sorties désirées, ce qui montre la qualité de l'apprentissage.

Nous allons bénéficier de cette présentation, dans ce qui suit, pour évaluer le pourcentage de reconnaissance du réseau.

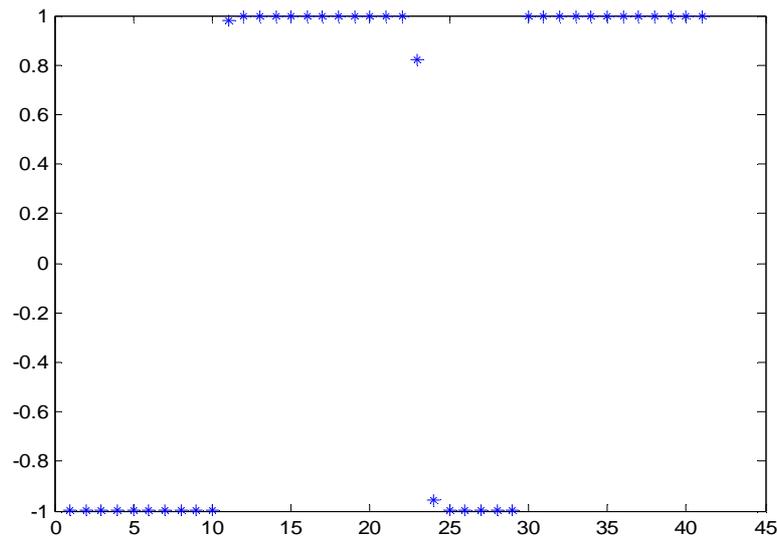


Figure 4.3 : Simulation avec positionnement des sorties du réseau (1-12-1) après apprentissage.

c. Evaluation des performances du réseau (1-12-1)

Dans la figure 4.4 nous allons montrer la corrélation entre les valeurs de sortie du réseau neuronal (1-12-1) et les valeurs désirées (ciblées).

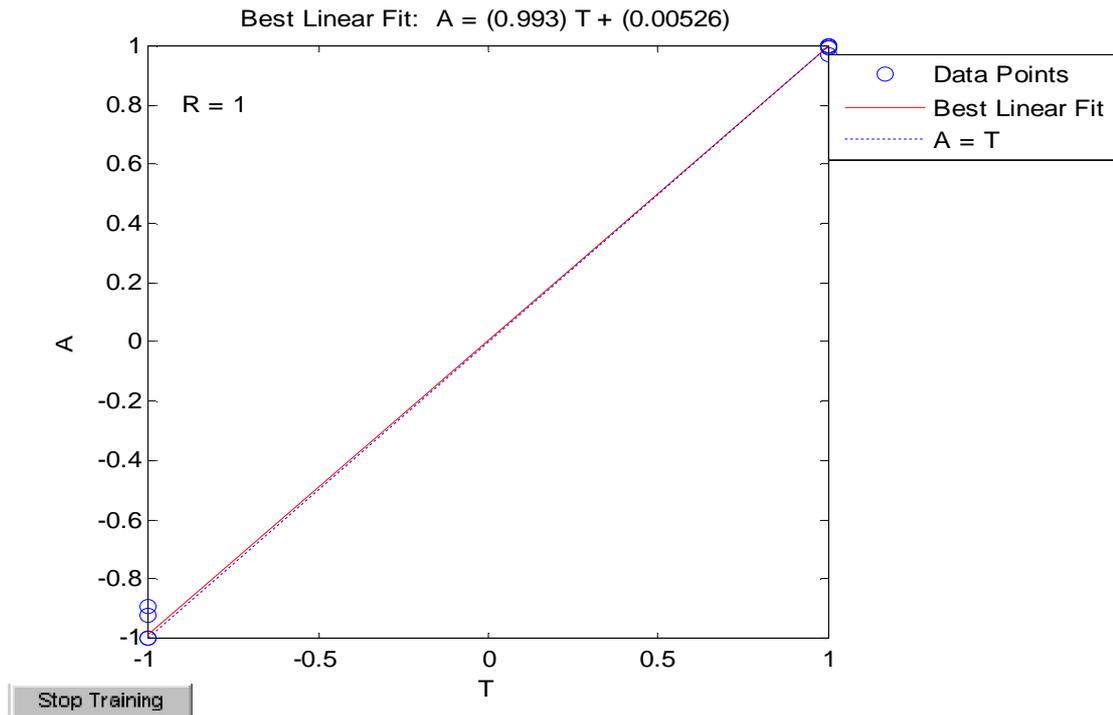


Figure 4.4 : Performances du réseau (1-12-1).

Avec : $(A = 0.993 T + 0.00526)$

$m = 0.993$ étant très proches de 1.

$R=1$

$b = 0.00526$ qui est proche de 0.

A la lumière de ces résultats, nous pouvons juger qu'il y a une bonne corrélation entre les sorties désirées (ciblées) qui sont soit égales à -1 ou égales à 1 et les sorties du réseau neuronal (1-12-1).

Ces résultats sont traduits par la concentration de la plupart des cercles autour de -1 et -0.9 pour les sorties de mauvais fonctionnement et le positionnement de la majorité des cercles autour de 0.95 et 1 pour les sorties de bon fonctionnement.

d. La généralisation du réseau (1-12-1)

Après l'apprentissage il est utile de savoir si le réseau (1-12-1) est capable de se généraliser. C'est-à-dire de reconnaître les points de bon fonctionnement et de mauvais fonctionnement, autre que ceux qui sont donnés dans l'ensemble d'apprentissage. Pour se faire nous avons simulé plusieurs bases de tests qui vont être présentées par la suite. Nous évaluerons le taux de reconnaissance, des différents ensembles des bases de tests, que nous résumerons dans le tableau 4.1.

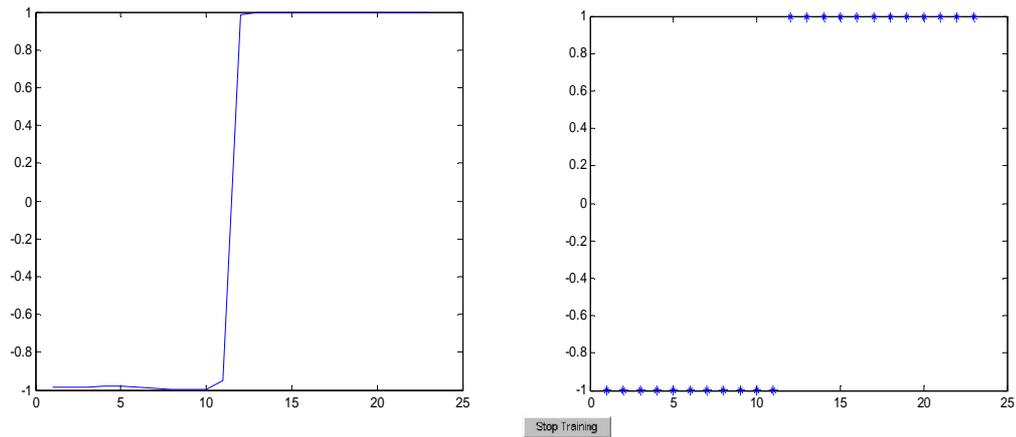


Figure 4.5: Simulation de la base de test (1).

La figure 4.5 illustre la simulation des sorties du réseau, qui sont identiques aux sorties désirées, avec des ensembles d'entrées différents de ceux qui sont donnés dans l'ensemble d'apprentissage. De plus, elle montre une bonne transition entre les bases du bon et du mauvais fonctionnement, ce qui indique l'efficacité du choix de la fonction d'activation (fonction sigmoïde).

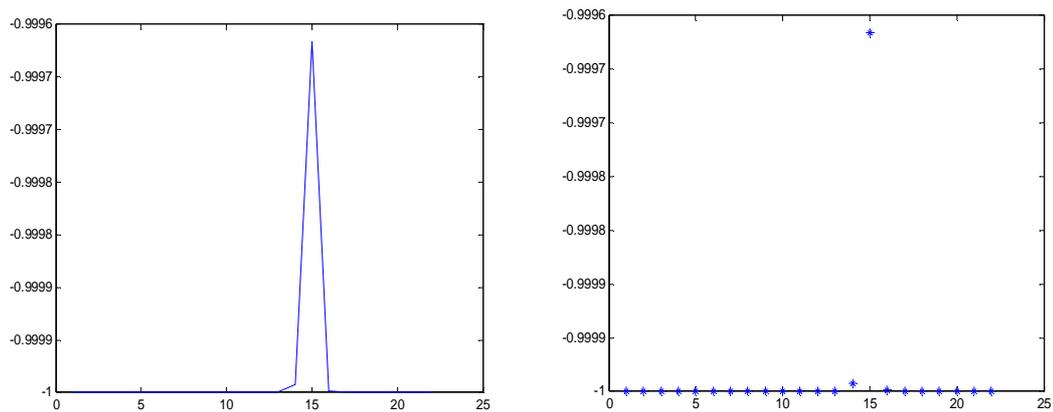


Figure 4.6: Simulation de la base de test (2).

La figure 4.6 montre la simulation de la base de test avec un défaut, La présence du pic revient aux perturbations des valeurs de la pression d'huile du carter d'engrenages (la perturbation est dûe au passage de la pression d'une valeur de 1.49 bars, qui est une valeur en dessous de la plage de fonctionnement du capteur de pression d'huile, à une valeur de 2.8 bars, qui est une valeur en dessus de la plage de fonctionnement).

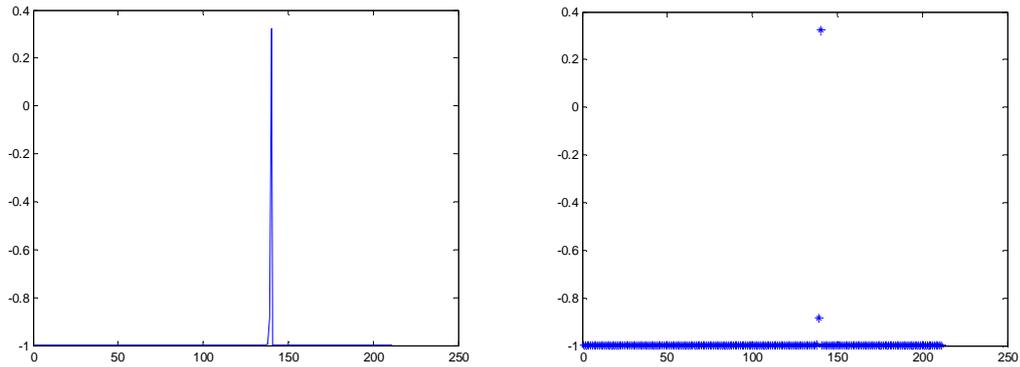


Figure 4.7: Simulation de la base de test (3).

Dans la figure 4.7 nous avons simulé le même défaut de la base de test (2) mais avec un pas de valeur égale à 0.01 contrairement à sa valeur précédente qui valait 0.1 pour voir l'influence du choix de pas dans la détection de défaut et dans la capacité de la généralisation du réseau.

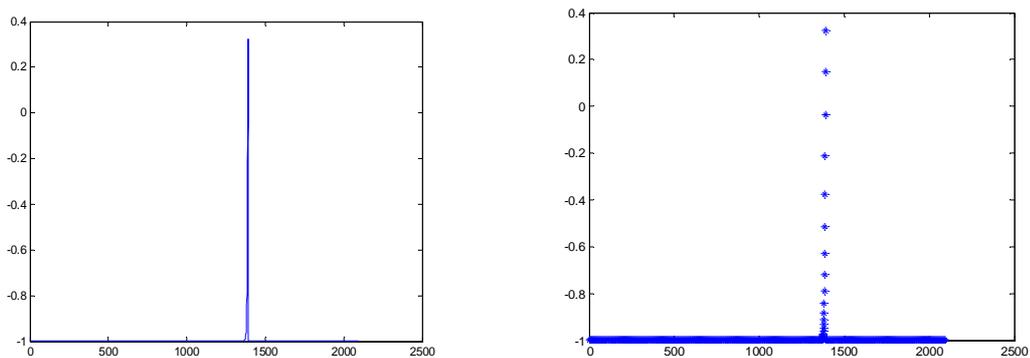


Figure 4.8: Simulation de la base de test (4).

La figure 4.8 montre la simulation des sorties du réseau avec le même défaut de la base de test (2) mais cette fois ci avec un pas égale à 0.001, dans cette figure le pic présente moins de transition, et donc plus de précision pour détecter le défaut, ce qui indique une bonne généralisation du réseau.

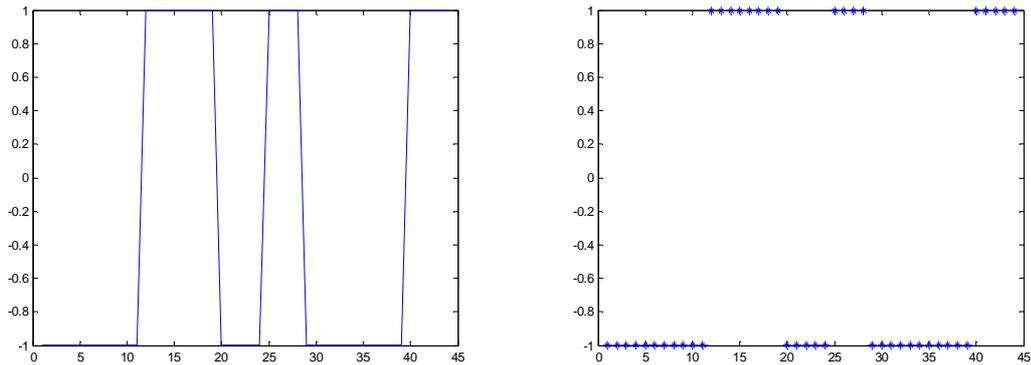


Figure 4.9: Simulation de la base de test (5).

Dans la figure 4.9 nous avons simulé plusieurs ensembles d'entrées du bon et mauvais fonctionnement pour voir la capacité de la généralisation du réseau. La Fig.4.9 montre une bonne détection des zones du bon et du mauvais fonctionnement.

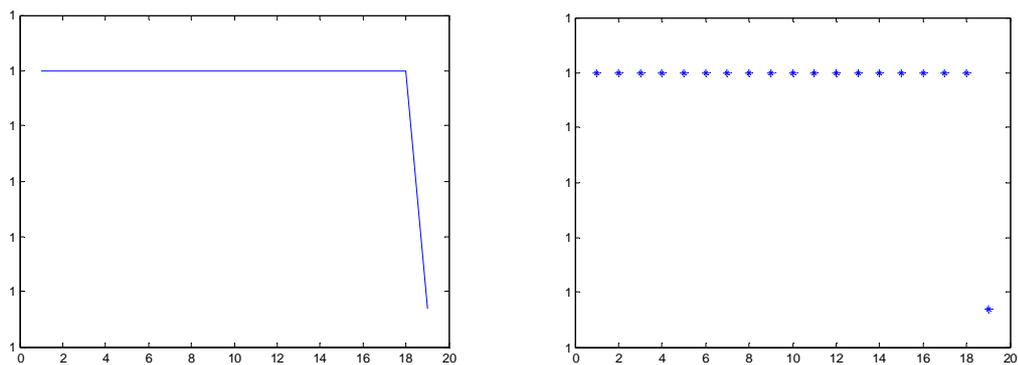


Figure 4.10 : Simulation de la base de test (6).

Dans la figure 4.10 nous avons simulé uniquement les ensembles d'entrées du bon fonctionnement autres que ceux qui sont donnés dans la phase d'apprentissage et dans les autres tests. La Fig.4.10 montre que toutes les sorties sont égales à 1, donc une bonne détection des zones du bon fonctionnement, d'où un bon apprentissage du réseau (illustration d'une bonne capacité de généralisation).

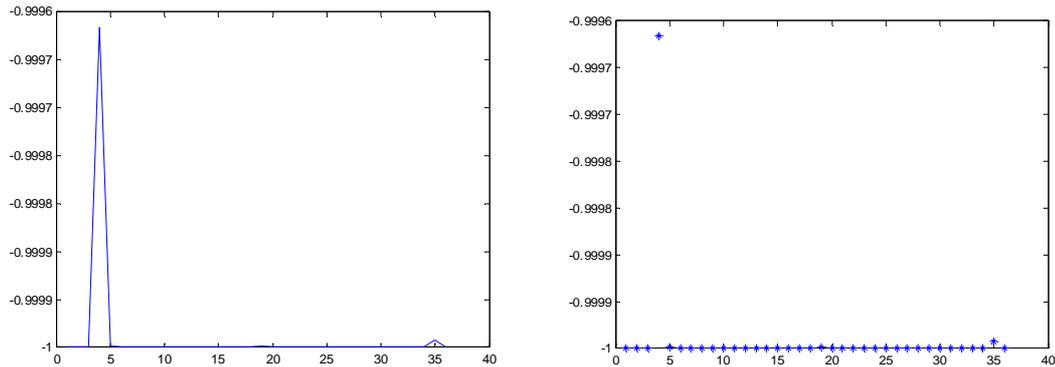


Figure 4.11: Simulation de la base de test (7).

La même interprétation précédente et valide pour la simulation de la base de test (7) présentée dans la Fig.4.11 à la différence des ensembles d'entrées qui sont des ensembles du mauvais fonctionnement.

Tableau 4.1 : Pourcentage de reconnaissance des exemples de chaque base de test lors de la simulation.

La base de test	Le pourcentage de reconnaissance (%)
(1)	100%
(2)	95.45%
(3)	99.05%
(4)	99.33%
(5)	100%
(6)	100%
(7)	97.22%

Le tableau ci-dessus montre une bonne reconnaissance du réseau (1-12-1) des points de bon et de mauvais fonctionnement pour les sept ensembles de bases de tests. En effet, les meilleurs pourcentages ont été donnés pour les bases (1), (5) et (6). La diminution du « pas », engendre le maximum de reconnaissance. Par exemple, pour les bases (2), (3) et (4) avec un pas de 0.1, 0.01 et 0.001 respectivement, elles ont un taux de reconnaissance 95.45%, 99.05% et 99.33% respectivement.

2 Partie B : circuit d'air

Dans cette partie nous nous intéressons aux résultats du circuit d'air. Nous avons mis en premier lieu la surveillance du circuit d'air par le modèle neuronal pour la détection de défaut et un programme de localisation de défaut en deuxième lieu.

2.1 Première phase : détection de défaut

Ici nous allons présenter la simulation de l'entraînement du réseau neuronal (2-15-1) et ses différents tests et résultats. Ce modèle neuronal est mis pour surveiller en temps réel le circuit d'air.

Les valeurs d'entrée du réseau (2-15-1) sont les valeurs de la pression d'entrée et de sortie du compresseur que nous allons surveiller dans cette phase.

a. Apprentissage

Nous commençons ici par la simulation de l'entraînement de l'apprentissage du réseau (2-15-1). La figure 4.12 montre la convergence de l'apprentissage au bout de 700 itérations avec une erreur de 0.01. Ceci dit, l'apprentissage du réseau est effectué selon les paramètres prédéfinis (tel que donné au chapitre 3).

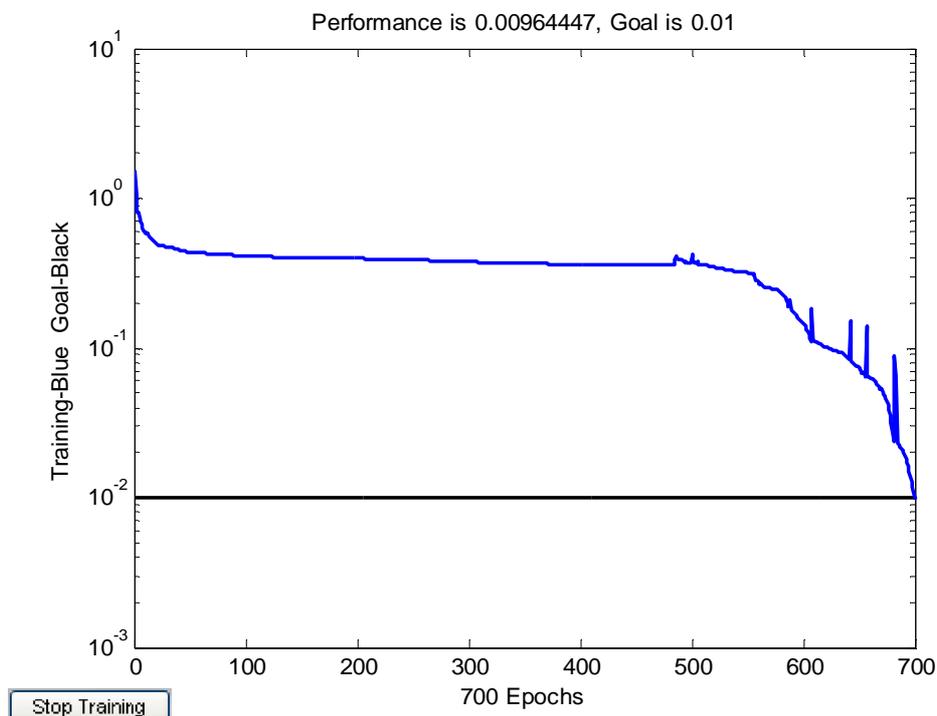


Figure 4.12: Simulation d'entraînement du réseau (2-15-1).

b. Simulation des sorties du réseau (2-15-1)

Après apprentissage nous simulons les sorties du réseau entraîné, dans la Fig.4.13 pour voir s'ils sont proches des sorties désirées (du fait qu'on a utilisé l'apprentissage supervisé).

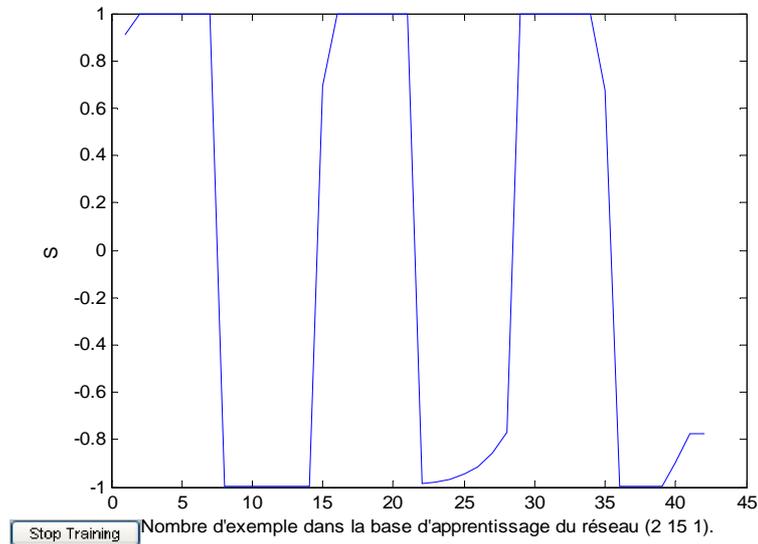


Figure 4.13: Simulation des sorties du réseau (2-15-1) après apprentissage.

La figure 4.14 montre le positionnement des sorties du réseau vis-à-vis des sorties désirées « 1 » ou « -1 ». Nous observons que la plus part des sorties du réseau sont identiques aux sorties désirées hormis quelques positions qui sont au voisinage de « 1 » et « -1 ». Les positions des sorties du réseau qui sont un peu loin de « 1 » ou « -1 » ne sont pas dues au mauvais apprentissage mais sont dues à la linéarité de la fonction d'activation utilisée (fonction sigmoïde).

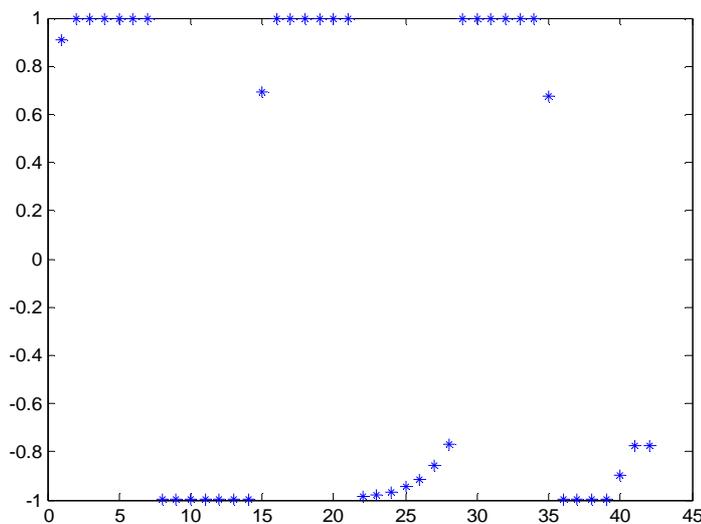


Figure 4.14: Simulation des sorties du réseau (2-15-1) après apprentissage.

c. Evaluation des performances du réseau (2-15-1)

La figure 4.15 ci-dessous nous permet de voir une correspondance entre les sorties du réseau neuronal (2-15-1) et les sorties désirées (ciblées).

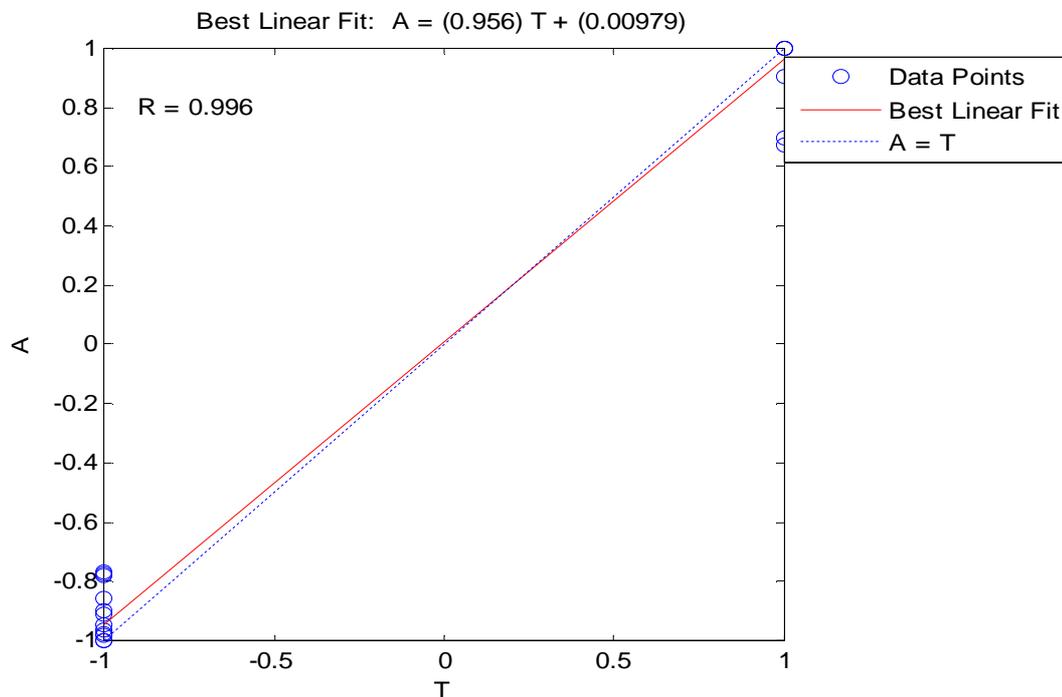


Figure 4.15: Performances du réseau (2-15-1).

Avec : $(A = 0.956 T + 0.00979)$

$m = 0.956$ étant très proches de 1.

$R=0.996$ qui est proche de 1

$b = 0.00979$ qui est proche de 0.

Ces résultats, nous permettent de déduire qu'il y a une bonne corrélation entre les sorties désirées (ciblées) qui sont soit égales à -1 ou égales à 1 et les sorties du réseau neuronal (2-15-1).

Ces résultats sont traduits par la concentration de la plupart des cercles autour de -1 et -0.85 pour les sorties de mauvais fonctionnement et le positionnement de la majorité des cercles autour de 0.75 et 1 pour les sorties de bon fonctionnement.

d. La généralisation du réseau (2-15-1)

Après l'apprentissage il est utile de savoir si le réseau (2-15-1) est capable de se généraliser. C'est-à-dire de reconnaître les points de bon fonctionnement et de mauvais fonctionnement, autre que ceux qui sont donnés dans l'ensemble d'apprentissage. Pour se faire nous avons simulé plusieurs bases de tests qui vont être présentées ultérieurement. Nous évaluerons le taux de reconnaissance, des différents ensembles des bases de tests, que nous résumerons dans le tableau 4.2.

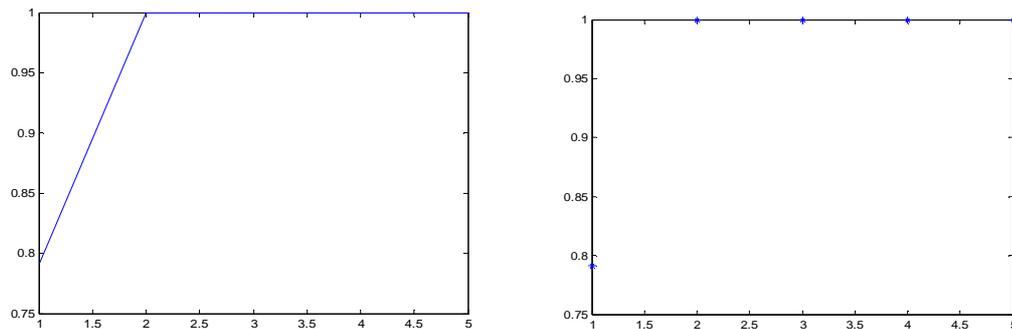


Figure 4.16: Simulation de la base de test (1).

La figure 4.16 illustre la simulation des sorties du réseau, qui sont identiques aux sorties désirées, avec des ensembles d'entrées du bon fonctionnement différents de ceux qui sont donnés dans l'ensemble d'apprentissage.

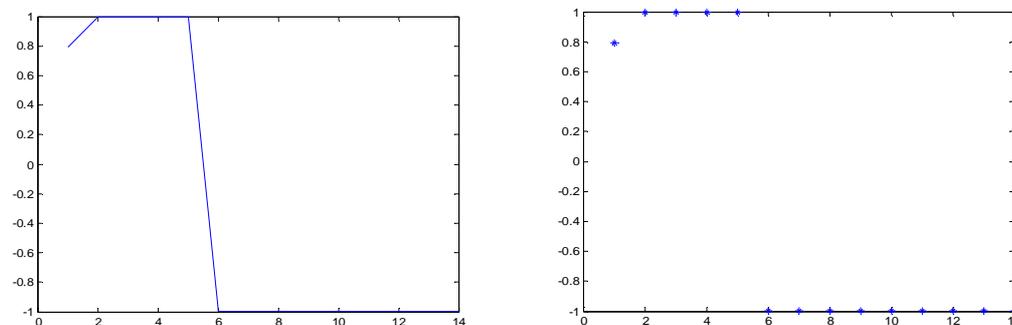


Figure 4.17: Simulation de la base de test (2).

Dans la figure 4.17 nous avons procédé par la simulation des sorties du réseau, les ensembles d'entrées du test sont les ensembles des zones de bon et du mauvais fonctionnement à détecter.

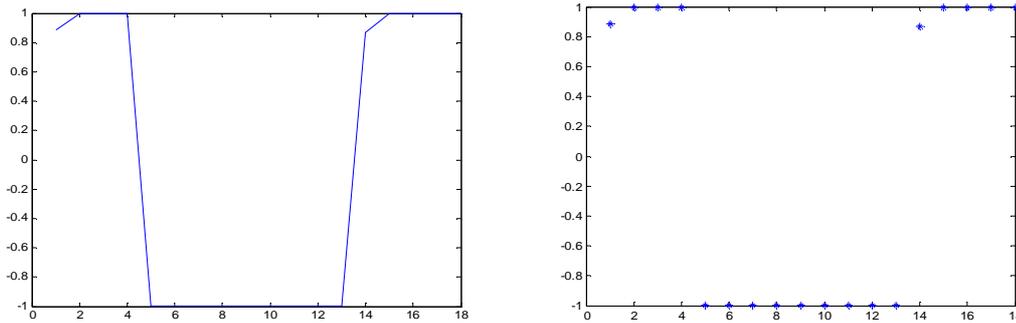


Figure 4.18: Simulation de la base de test (3).

La simulation des sorties du réseau avec des différents ensembles d'entrées dans la Fig.4.18 montre une bonne transition entre les régions du bon et du mauvais fonctionnement, à l'exception de quelques pertes de données aux 1^{er} et 14^{eme} points qui sont dues au choix de la fonction d'activation (fonction sigmoïde), qui est une fonction non linéaire.

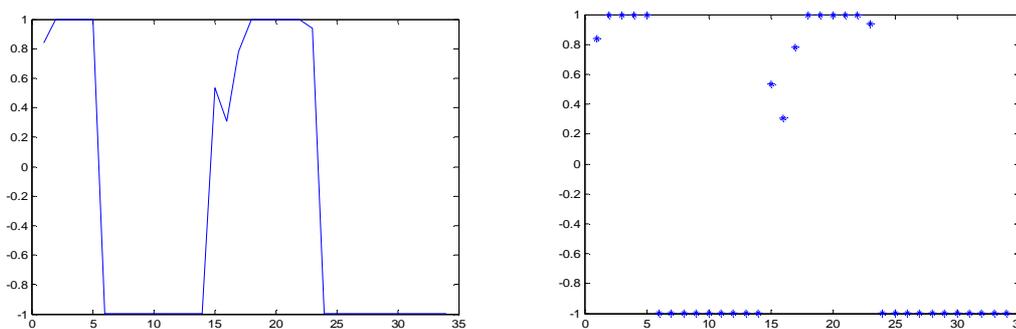


Figure 4.19: Simulation de la base de test (4).

La figure 4.19 illustre la simulation des sorties du réseau, qui sont égales aux sorties désirées, avec des divers ensembles d'entrées du bon et du mauvais fonctionnement différents de ceux qui sont donnés dans l'ensemble d'apprentissage. Elle montre aussi une bonne détection des zones du bon et du mauvais fonctionnement à partir du 15^{eme} et du 16^{eme} point, qui se sont apparus lors du passage du mauvais au bon fonctionnement, qui trouve son explication dans le choix aléatoire des ensembles d'entrées et le non linéarité de la fonction sigmoïde.

Tableau 4.2 : Pourcentage de reconnaissance des exemples de chaque base de test lors de la simulation.

La base de test	Le pourcentage de reconnaissance (%)
(1)	100%
(2)	100%
(3)	100%
(4)	91.17%

Le tableau ci-dessus montre une bonne reconnaissance du réseau (2-15-1) des points de bon et de mauvais fonctionnement pour les quatre ensembles de bases de tests. C'est dans les régions de transition entre le fonctionnement normale et le fonctionnement anormale, que nous rencontrons le moins de reconnaissance. Cette transition est due au choix de la fonction sigmoïde comme fonction d'activation pour le réseau (2-15-1). Par exemple, pour la base de test (4) de la Fig.4.19, ou la transition du mauvais vers le bon fonctionnement est entre le 15^{ème} et le 16^{ème} point.

2.2 Deuxième phase : localisation de défaut

Pour localiser le défaut nous avons mis un programme qui fonctionne avec le réseau de neurones. Une fois que le réseau détecte un défaut (la sortie du réseau est égale à $S = -1$) le programme sera exécuté. Ce programme est sous forme des contraintes sur les valeurs de température pour localiser le défaut. Une fois que $S = -1$, le programme exécute et il affiche soit : {BF}, {MFTT11 et MFTT21 et MFTT18}, {MFTT11 et MFTT21}, {MFTT11 et MFTT18}, {MFTT18 et MFTT21}, {MFTT11}, {MFTT21}, {MFTT18}.

Avec :

BF : Bon Fonctionnement ;

MFTT11 : Mauvais Fonctionnement détecté par le capteur de température TT11 ;

MFTT18 : Mauvais Fonctionnement détecté par le capteur de température TT18 ;

MFTT21 : Mauvais Fonctionnement détecté par le capteur de température TT21.

Conclusion

Dans ce chapitre nous avons simulés les deux parties du compresseur, circuit d'air et circuit de lubrification, dans le but d'aboutir à une surveillance et à un diagnostic fiable. Les paramètres que nous avons choisis sont : PT45 capteur de pression d'huile, PDT02 capteur de pression de filtre à air, PT29 capteur de pression d'air de sortie du compresseur, TT11 capteur de température de sortie élément basse pression, TT18 capteur de température d'entrée élément haute température, TT21 capteur de température de sortie élément haute pression.

Ce travail a été développé afin d'arriver à une surveillance fiable du compresseur d'air. Nous nous sommes donc appliqués à bien choisir nos bases d'apprentissage en donnant toutes les possibilités de bon et de mauvais fonctionnement pour tous les ensembles. Tout en prenant soin de ne pas trop augmenter le nombre d'exemples afin d'éviter le sur-apprentissage.

L'architecture des réseaux de neurones a été choisie essentiellement par des réseaux à une couche d'entrée, à une seule couche cachée, où nous avons varié le nombre de neurones pour atteindre une bonne convergence du réseau. Dans la dernière couche il y a un seul neurone pour les sorties du réseau « 1 » ou « -1 ».

Le fait que le réseau converge n'implique pas forcément un bon apprentissage. Et nous remédions à cette confusion par :

- La simulation des sorties du réseau après apprentissage.
- La simulation des bases de tests avec d'autres ensembles que les ensembles d'apprentissage, pour voir la capacité de généralisation du réseau.

Ces deux alternatives donnent une appréciation très représentative de l'apprentissage. Si nous avons un bon apprentissage, les fonctionnements normaux et anormaux de la machine sont égaux ou très proche respectivement de « 1 » et de « -1 ». Sinon ils seront bruités et s'éloigneront des sorties désirées.

Après l'entraînement de chaque réseau de neurones nous avons évalué, leurs performances par la méthode de la régression linéaire. Les résultats de cette dernière anticipent le résultat de la qualité de la généralisation.

La validation de notre travail c'est effectuée au fur et à mesure de notre étude. Cela en testant chaque réseau de neurones, par le pourcentage de reconnaissance des exemples de bases de tests, afin de voir sa capacité de généralisation. Dans notre approche neuronale, nous avons abouti à des meilleurs résultats lors de la généralisation.

Les résultats que nous avons obtenus indiquent de surveillance fiable, et surtout que la baisse du taux de généralisation revient aux transitions entre les fonctionnements normaux et anormaux de la machine. Car nous avons choisi la fonction sigmoïde qui assure la continuité.

Nous avons évalué les qualités d'apprentissage des réseaux par le calcul de leurs erreurs d'apprentissage. Plus l'erreur est élevée plus il y a une grande différence entre les sorties désirées et les sorties des réseaux donc un apprentissage moins intéressant pour que ce réseau soit utilisé.

Conclusion générale et perspectives

Le travail de recherche présenté dans ce mémoire porte sur l'étude des réseaux de neurones artificiels pour la surveillance et le diagnostic de la ligne de production pharmaceutique. Dans l'objectif de minimiser au maximum les fausses alertes et de détecter toute dégradation avant que le système n'atteigne le seuil de défaillance. Un mauvais diagnostic pourrait se poser en un problème inverse. Au lieu de fausses alertes, il pourrait y avoir un emballement ou une dégénérescence quelque part dans la machine, que le système mis en place ne détecte pas. Par exemple une augmentation de température ou une diminution de la pression.

Pour se faire, nous avons pris un cas réel d'un compresseur d'air, qu'est l'équipement le plus stratégique dans la ligne de production pharmaceutique BEKER Laboratoire, avec des données et paramètres réels. Le perceptron multicouche est le réseau neuronal choisi pour la surveillance et le diagnostic du compresseur d'air. Ce dernier comporte une couche d'entrée, qu'est l'entrée des valeurs des paramètres à surveiller, une couche cachée et une couche de sortie, qui comporte un neurone pour les sorties de bon fonctionnement « 1 » ou mauvais fonctionnement « -1 ».

L'apprentissage du réseau dépend de plusieurs paramètres qui sont : l'erreur à atteindre par la fonction de coût, le nombre d'itération, le taux d'apprentissage et la fonction d'activation. Une bonne répartition des différentes bases à apprendre au réseau donne de très bons résultats, ce qu'est montré dans la phase de test. Donc un bon apprentissage dépend aussi du bon choix des bases d'apprentissage pour obtenir une bonne généralisation.

Nous avons également tenté de dévier les problèmes liés à l'apprentissage, tel que le sur-apprentissage, les minima locaux et les temps trop long d'apprentissage, Par des algorithmes et des paramètres d'apprentissage tel que le moment pour les minima locaux et la rétro-propagation résilient pour la réduction de la durée d'apprentissage.

Nous avons simulé les sorties des réseaux après apprentissage pour voir s'il y a eu un bon apprentissage car l'algorithme de rétro-propagation de gradient pourrait très bien converger pour diverse architecture du réseau. Nous avons opté pour l'apprentissage supervisé, car nous disposons pour chaque entrée une sortie connue.

Après l'entraînement de chaque réseau de neurones nous avons évalué, leurs performances par la méthode de la régression linéaire.

Pour tester la capacité de généralisation des réseaux, nous avons pris sept ensembles de tests pour le premier modèle et quatre ensembles pour le deuxième. Les résultats obtenus après la généralisation sont les pourcentages de reconnaissance des réseaux des points de bon et de mauvais fonctionnement. Ceci montre la qualité d'apprentissage et la crédibilité des résultats du réseau neuronal employé.

Lors de la généralisation on a constaté une baisse du pourcentage de reconnaissance de quelques bases de tests ceci revient aux transitions entre les fonctionnements normaux et

anormaux de la machine. Ce qui est due au choix de la fonction sigmoïde qui est une fonction continue.

Enfin, afin de poursuivre ce travail plusieurs perspectives pourraient s'ouvrir, comme par exemple :

- ✓ La conjugaison d'autre méthode de l'intelligence artificielle, tel que les réseaux de Pétri ou les algorithmes génétiques, aux réseaux de neurones. Surtout pour l'optimisation des temps de détection et d'intervention.
- ✓ Trouver un algorithme qui pourrait donner le nombre de couche cachés et de neurone dans chacune d'elle en fonction de la taille des entrées et des sorties.
- ✓ L'application réelle de cette approche au compresseur d'air.

Références Bibliographiques

- [1] DJALAL-Eddine KHODJA, « *Diagnostic automatique des défaillances d'un système électromécanique par application des réseaux de neurones artificiels* », Mémoire de magister, université de Boumerdes, 2001.
- [2] Mohamed Ryad ZEMOURI, « *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance* », Thèse de doctorat, université de Franche-Comté, 2004.
- [3] Marc Parizeau, « *Le perceptron multicouche et son algorithme de rétro-propagation des erreurs* », Université Laval, 2004.
- [4] Nicolas Palluat, Daniel Racoceanu, Nouredine Zerhouni, « *Utilisation des réseaux de neurones pour le pronostic et la surveillance dynamique* », RSTI-RIA. Volume 19-n°6, Rue Alain Savary, F-25000 Besançon, pp 911 à 948, 2005.
- [5] F. Souahi, A. Hachmaoui, C. E. Chitour, « *Caractérisation des mélanges complexes par une méthode utilisant les réseaux de neurones artificiels* », Journal de la société Algérienne de chimie, 2007.
- [6] Mohamed Bouamar, Mohamed Ladjal, « *Système multi-capteur utilisant les réseaux de neurones artificiels pour la surveillance des eaux potables* », Mémoire de magister, Université de M'sila, Algérie, 2007.
- [7] R.Mahdaoui, H.L.Mouss, « *Diagnostic Industriel par Neuro-Floue Application à Un Système de Production* », Mémoire de magister, Université de Batna, 2007.
- [8] François Denis Rémi Gilleron, Boris PIERRE-JUSTIN, « *Définition et expressivité des réseaux multicouches l'algorithme de rétro-propagation du gradient* », 2007.
- [9] Nedjma SALHI, « *Surveillance et diagnostic d'une chaîne de production par les réseaux de neurones artificiels* », Mémoire de magister, Université de boumerdes, 2008.
- [10] Alp Mestan, « *Introduction aux Réseaux de Neurones Artificiels Feed Forward* », 2008.
- [11] R.Bigret, J.L.Feron, « *Diagnostic, Maintenance et disponibilité des machines tournantes* », Ed, Masson, Paris 1994.
- [12] H.Buller, « *Réglage logique floue* », Presse Polytechnique Nomandes, Lausanne, 1994.
- [13] J.N.Chatain, « *Diagnostic par système expert* », Ed, Hermès Paris, 1993.
- [14] B.Dubuisson, « *Détection et diagnostic des pannes sur processus* », Technique de l'ingénieur, R7597, 1992.

- [15] C.Faure, L.Miclet, « *Intelligence artificielle et reconnaissance des formes* », technique de l'ingénieur, H1900, 1990.
- [16] F.Filippetti, G.Franceschini, C.Tassoni, « *Neural Networks approach to electric machine on-line diagnostics* » EPE BRIGHTON, pp.213-218, 1993.
- [17] F.Filippetti, G.Franceschini, C.Tassoni, P.Vas, « *A fuzzy logic approach to on-line induction motor diagnosis based on stator current monitoring* » IEEE-KTH, Stocholm, Sweden, pp.156-161, 1995.
- [18] F.Filippetti, G.Franceschini, C.Tassoni, S.Zond, P.Vas, « *AI techniques in induction machines diagnosis including the speed ripple effect* » IEEE Transaction on industries applications, vol.34, n°1, pp.98-108, 1998.
- [19] J.Hato, « *Intelligence artificielle et reconnaissance des formes, Introduction* », Technique de l'ingénieur H1900, 1990.
- [20] M.G.M.Madden, P.J.Nolan, « *Monitoring and diagnosis of multiple inceptient faults using faults tree induction* », IEE, proceeding contrôle theory, Appl, vol 146, n°2, pp.204-212, 1999.
- [21] J.Morel, « *Vibration des machines et diagnostic de leur état mécanique* », Ed. Eyrolles, 1996.
- [22] R.K.Rayaudu, S.Samarasinghe, D.Kulasivi, « *A comparison of model-based reasoning and learning approaches to power transmission fault diagnosis* », Artificiel neural network and expert system, proceedings, second New Zealand international tow-stream conference on puplished, pp 218-222, 1995.
- [23] J.Richalet, « *Modélisation et identification des processus* », Technique de l'ingénieur R7140, 1987.
- [24] G.Rostaing, « *Diagnostic de défauts dans les entrainements électriques* » Thèse de doctorat, Université de Grenoble, 1997.
- [25] R.Scattolini, N.Cattane, « *Detection of sensor faults in a large flexible structure* », IEEE proc.control.theory.Appl, vol.146, n°5, pp.383-388, 1999.
- [26] T.Sorsa, HN.Koivo, « *Neural networks in process fault diagnosis* », IEEE transaction on systems, vol.21, n°4, pp.815-825, 1991.
- [27] G.Zwingelsten, « *Diagnostic des défaillances : théorie pratique pour les systèmes industriels* », Ed. Hermès Paris, 1995.
- [28] Claude Touzet, « *Les réseaux de neurones artificiels* », Livre, 1992.
- [29] E. Davalo, P. Naim, « *Des réseaux de neurones* », éd. Eyrolles, Parie, 1993.

- [30] T.A.Freman, D.M.Skapura, « *Neural networks: algorithm, applications and programming techniques* », CNS, Computation and neural systems series, 1992.
- [31] M.Gondran, C.Miller, « *Réseaux de neurones et apprentissage* », Revue REE n° 3, pp. 6-9, 1997.
- [32] G.Z winngelsten, « *Diagnostic des défaillances : théorie et pratique pour les systèmes industriels* », Ed. Hermès Parie, 1995.
- [33] D.Lefebvre, A.E.Moudni, « *Détection et localisation des défaillances dans les systèmes de production par réseaux de neurones* », AP – JESA, Vol.34, pp.1048- 1072, 2000.
- [34] J.L. Amat, G.Yahhiaoui, « *Technique avancées pour le traitement de l'information, réseaux de neurones, logique flou, algorithme génétique* », Edition CEPAUDIES, Toulouse France, 1996.
- [35] G. Dreyfus, AL.Eyrolles, « *Réseaux de neurones : méthodologie et applications* », 2002.
- [36] L.Personnaz, I.Rivals, « *Réseaux de neurones formels pour la modélisation, la commande, et la classification* », CNRS éditions, collection Sciences et Techniques de l'Ingénieur, 2003.
- [37] Y.Ziquel, J.Ermont, « *Apprentissage par Réseaux de neurones* », Rapport de projet, 2004-2005.
- [38] F.Moutarde, « *Introduction aux réseaux de neurones*'. Ecole des Mines de Paris », 2007.
- [39] M. Mouchaweh, « *Micro conception d'un système de diagnostic et prédictif basé sur la méthode de Fuzzy Pattern Matching pour la surveillance en ligne des systèmes évolutifs. Application à la supervision et au diagnostic d'une ligne de peinture trempé* », Thèse de Doctorat, université de Reims Champagne-Ardenne, 2002.
- [40] M.Basseville, A.Beneviste, Q.Zhangh, « *Surveillance d'installation industrielle démarche générale et conception de l'algorithmique* », INRIA, Vol.2889, pp. 26-35, 1987.
- [41] L.Baghli, « *Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques* », Thèse de doctorat, Nancy France, 1999.
- [42] E.Chetate, P.Naim, « *Des réseaux de neurones* », éd. Eyrolles, Paris, 1993.
- [43] T.Fukuda, T.Shbata, « *Theory and application of neuronal networks for industriel systems* », IEEE Transaction on industriel electronics, vol 39, N°6, pp. 472-489, 1992.
- [44] M.Gondran, C.Miller, « *Réseaux de neurones et apprentissage* », Revue REE n°3, pp. 6-9, 1997.

[45] T.Hara, A.Itok, K.Yatsuka, K.Kishi, K.Hirotsu, « *Application of the neural network to detecting corona discharge occuring in power cables* », Technology Update series, IEEE, pp.255-260, 1996.

[46] T.Herihari, R.Boudjera, K.Djabara, « *Utilisation des réseaux de neurones artificiels pour la détection des défaillances d'un capteur* », SAE'99, Université de Boumerdes, pp.230-233, 1999.

[47] H.Kanoh, K.Kanumaru, M.Kaneta, M.Nishiura , « *A study on practical fault location system for power transmission lines using neural network* », Technology Update series, IEEE, pp. 245-249, 1996.

[48] I.Belaidi, R.Tahmi, K.Mohammedi, « *Configuration optimale d'un réseau de neurones adapté à la surveillance en ligne de l'usure des outils de tournage* », 18^{ème} Congrès Français de mécanique, 2007.

Annexe 1

Description générale du compresseur d'air

Le compresseur ZT45 est un compresseur bi-étagés rotatif à lobes entraînés par un moteur électrique, il est refroidi par l'air et comprend principalement les éléments suivants :

- Régulateur Elektronikon (1)
- Filtre d'air (AF)
- Filtre d'huile (OF)
- Élément compresseur basse pression (EL)
- Élément compresseur haute pression (Eh)
- Refroidisseur intermédiaire (Ci)
- Refroidisseur d'huile (Co)
- Refroidisseur final (Ca)
- Refroidisseur, air de régénération (Car)
- Ventilateur (FN)
- Moteur électrique (M1)
- Moteur de ventilateur (M2)
- Accouplement d'entraînement
- Carter d'engrenages
- Voyant de niveau d'huile (SG)
- Bouchon de remplissage d'huile (FC)
- Soupapes de sécurités (SVh,SVI)
- Valve « tout/rien » (TV)
- Réservoir des condensats, refroidisseur intermédiaire (MTi)
- Sécheur d'air IMD

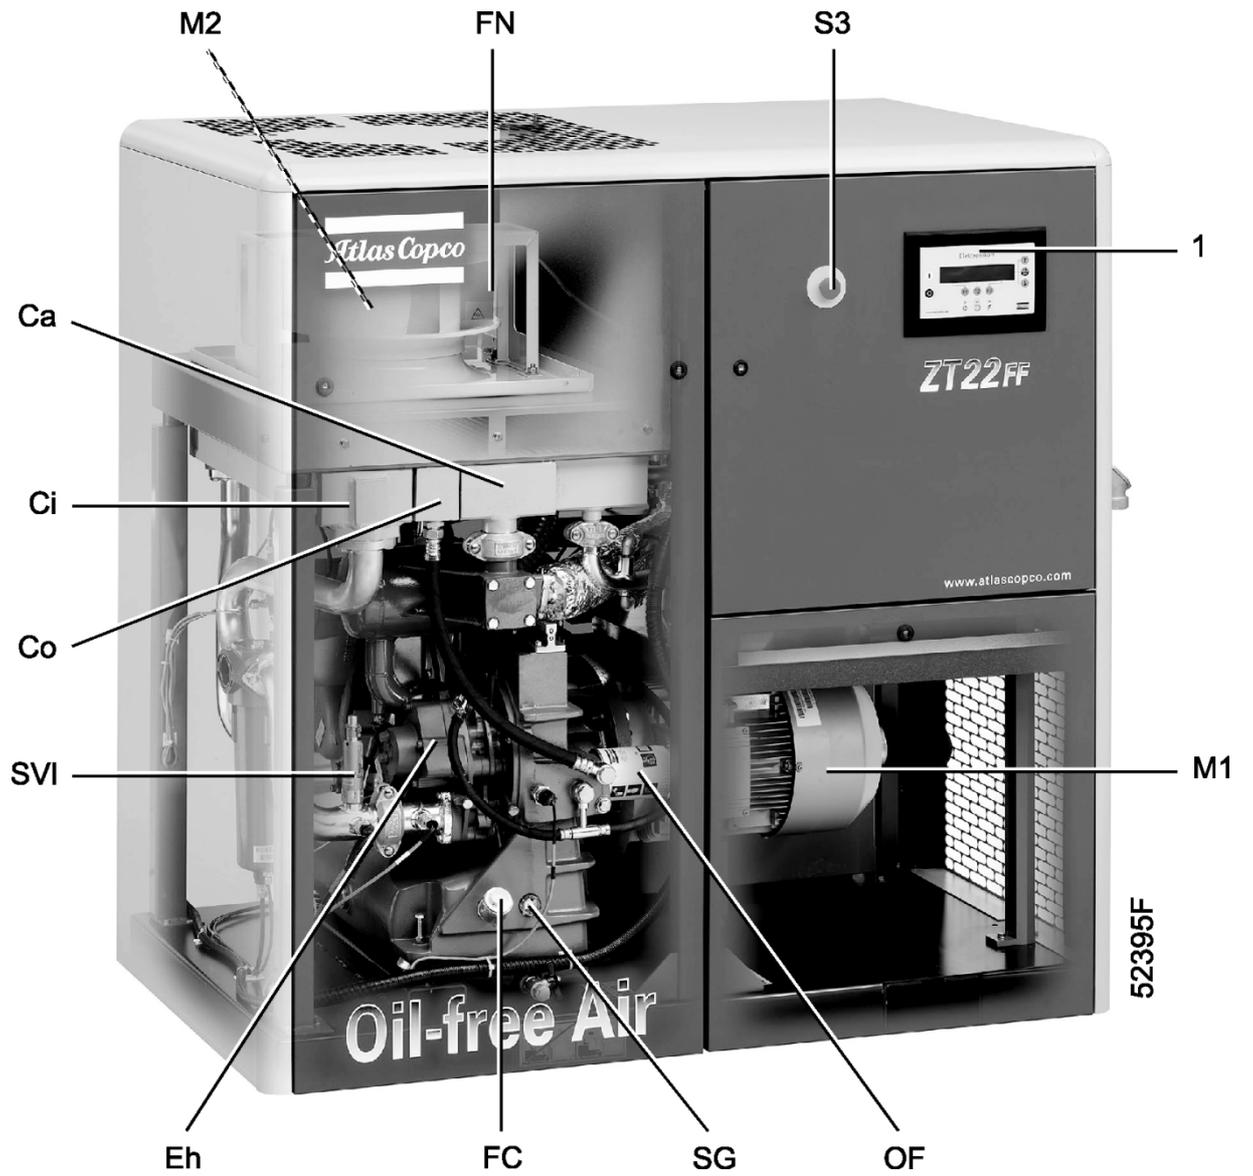


Figure annexe 1.1 : Vue avant du compresseur d'air.

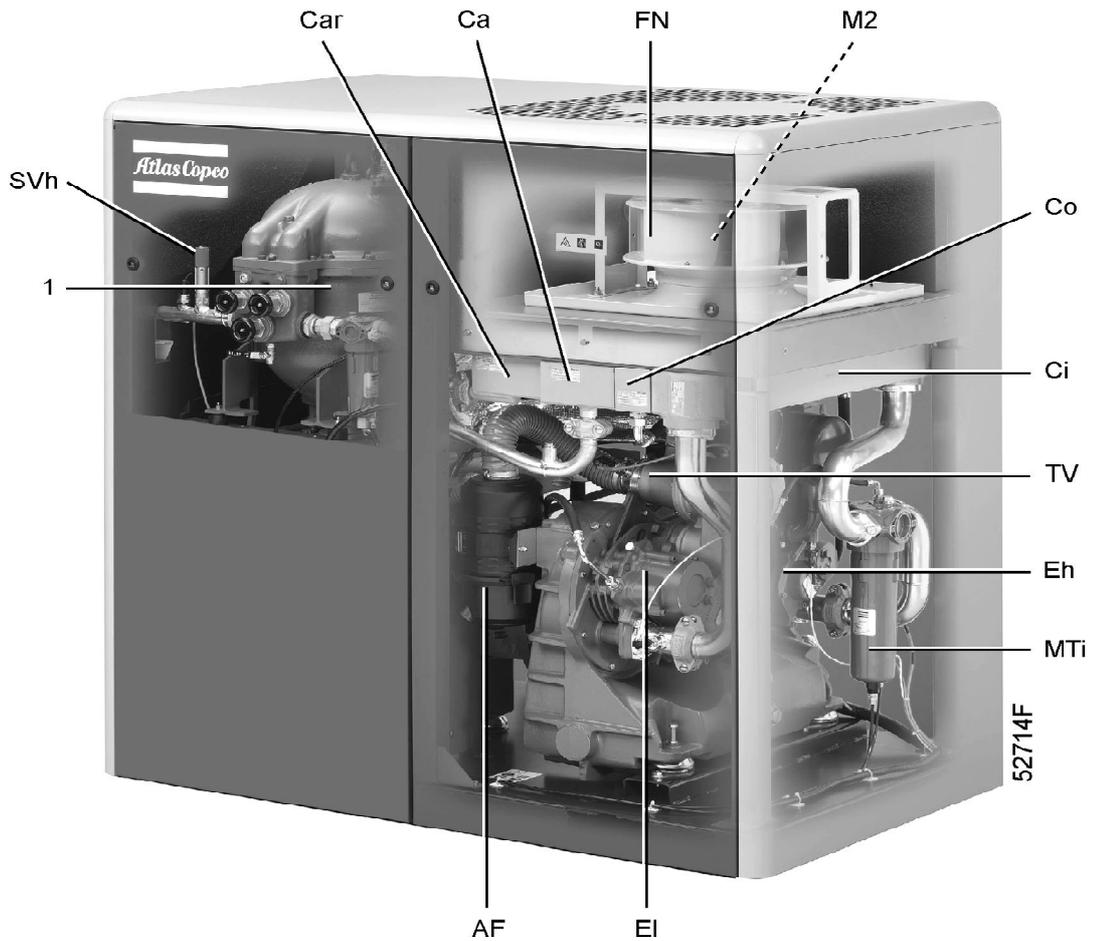


Figure annexe 1.2 : Vue arrière du compresseur d'air.

Annexe 2 : Historique du compresseur d'air de l'année 2009

	<h1>Dossier Historique</h1>	Réf : BMM.02
		Version : 01
Département : <p style="text-align: center;">Maintenance</p>	Compresseur d'Air ATLAS-COPCO ZT45 FF	Page : 01

Désignation	Compresseur d'Air
Constructeur	ATLAS-COPCO
N° ID	0 7201
N° série	AII705496
Type	ZT45 FF
Localisation	Utilités/ U1
Date de fabrication	Juin 2005
Date de mise en service	2006



Code du mode de défaillance		Code de la cause de défaillance			
Mécanique	1	Accident	1	Santé matière	9
Electrique	2	Mauvaise utilisation	2	Mauvaise conception	10
Electronique	3	Défaillance seconde	3	Mauvaise réalisation	11
Pneumatique	4	Environnement non conforme	4	Mauvais montage	12
Hydraulique	5	Consignes non respectées	5	Usure	13
Autre	6	Mauvaise intervention antérieure	6	Corrosion	14
		Défaut entretien	7	Fatigue	15
		Nettoyage insuffisant	8	Autre	16

	Dossier Historique	Réf : BMM.02
		Version : 01
Département : Maintenance	Compresseur d'Air ATLAS-COPCO ZT45 FF	Page : 02

Date d'apparition de la défaillance	Compteur	Réf/N° RC	Mode de défaillance	Cause de la défaillance	Description de la défaillance	Description de l'intervention	Niveau de maintenance	Durées	
								TA	TI
14/01/2009	/	/	/	/	<ul style="list-style-type: none"> Fuite d'air au niveau du raccord Union de la vanne d'arrêt d'air de régénération. 	<ul style="list-style-type: none"> Serrage du raccord union de la vanne d'arrêt d'air de régénération. 	3	/	10mn
20/01/2009	/	/	/	/	<ul style="list-style-type: none"> Fuite d'air au niveau de l'électrovalve reniflard y3 	<ul style="list-style-type: none"> Etanchéité irréalisable Prévoir changement de pièce 	2	/	/
28/01/2010	/	/	/	/	<ul style="list-style-type: none"> Baisse de la pression d'huile, 1.3 bar 	<ul style="list-style-type: none"> Rechange de filtre à huile 	2	2h	30mn
02/02/2009	/	/	/	/	<ul style="list-style-type: none"> 'Défaut électrique' compresseur ne démarre pas 	<ul style="list-style-type: none"> Changer le contacteur Essai Ok 	3	1h30	15mn
14/03/2009	/	/	/	/	<ul style="list-style-type: none"> Relais contacteur K02 Défectueux 	/	/	/	/
19/04/2009	/	/	/	/	<ul style="list-style-type: none"> Alarme haute température huile 	<ul style="list-style-type: none"> Nettoyage du réfrigérant d'huile. Essai Ok 	2	30mn	20mn
07/05/2009	/	/	/	/	<ul style="list-style-type: none"> Alarme 'haute température d'air de la sortie' 	<ul style="list-style-type: none"> Fausse alarme, défaut sonde de température changer la sonde Pt1000 	3	2h45mn	1h

	<h2>Dossier Historique</h2>	Réf : BMM.02
		Version : 01
Département :	Compresseur d' Air ATLAS-COPCO ZT45 FF	Page : 03
Maintenance		

Date d'apparition de la défaillance	Compteur	Réf/N° RC	Mode de défaillance	Cause de la défaillance	Description de la défaillance	Description de l'intervention	Niveau de maintenance	Durées	
								TA	TI
20/10/2009	/	/	/	/	<ul style="list-style-type: none"> Affichage interrompu. Défaut électrique. Fusible F7 de la commande est détérioré. (perturbation réseau) 	<ul style="list-style-type: none"> F7 défectueux Changer fusible, tester les composants électriques. Essai ok. 	10mn	5mn	2mn
17/11/2009	/	/	/	/	<ul style="list-style-type: none"> Défaut : Pression intermédiaire. 	<ul style="list-style-type: none"> Nettoyage du filtre à air, étancher le cadre filtre avec pate spéciale. 	2mn	20mn	15mn

Tableau annexe 2 : Historique de la maintenance préventive du compresseur d'air de l'année 2009

TABLEAU DES ACTIVITES D'ENTRETIEN POUR L'ANNEE 2009		
ACTIVITE	FREQUENCE	Date d'intervention
1- Contrôle de l'étanchéité des circuits d'air et d'huile.	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
2- Nettoyage des composants électriques et des éléments extérieurs.	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
3- Nettoyage des échangeurs de chaleur.	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
4- Graissage des roulements du moteur électrique principal	6 mois	04/01/2009 08/06/2009
5- Contrôle du filtre d'air (éventuel remplacement).	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
6- Vidange du carter.	6 mois	04/01/2009 08/06/2009
7- Vérification des soupapes de sécurité.	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
8- Test des purgeurs.	3 mois	04/01/2009 10/03/2009 08/06/2009 10/10/2009
9- Vérification des serrages de la boulonnerie.	6 mois	04/01/2009 08/06/2009
10- Contrôle du circuit d'air comprimé et de la bouteille d'air.	6 mois	04/01/2009 08/06/2009