

وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

École Supérieure De Technologies Industrielles
- Annaba -



المدرسة العليا للتكنولوجيا الصناعية
- محاسبة -

Année / 2020

Département du Second Cycle

FILIÈRE

Génie Industriel

MEMOIRE

Présenté en vue de l'obtention du diplôme d'Ingénieur d'État

Classification de défauts des machines tournantes par l'intelligence Artificielle

Spécialité

Maintenance et Fiabilité des Systèmes Industriels

Par

HASSANI Amira

Encadreur :

DJELLAL Adel

Grade

MCB

Établissement d'affiliation

ESTI Annaba

Remerciement

*Avant d'ouvrir ce mémoire, je remercie Dieu tout puissant de m'avoir donné le courage, la force et la patience d'achever ce modeste travail. Je voudrais d'abord adresser mes toutes grâtes à mon encadreur de ce mémoire Monsieur **DJELLAL Adel**, pour sa patience, ses orientations, ses précieuses informations et surtout ses judicieux conseils, qui ont contribué à alimenter ma réflexion, pour le temps qui m'a consacré et pour son aide à surmonter les difficultés rencontrées.*

Je présente mes sincères remerciements aux membres de jury de soutenance pour l'enrichissement qu'ils vont m'apporter à l'occasion de la discussion de la présente recherche.

*Mes sincères remerciements vont également à Madame **REBBANI Fouzia**, la directrice de l'Ecole Supérieure de Technologies Industrielle Annaba qui nous a fourni tous les moyens nécessaires pour assurer un bon déroulement de notre formation.*

*A la fin je voudrais adresser mes vifs remerciements à la direction du département génie Industriel d'ESTI **Annaba** et particulièrement à Monsieur **AYAD Amar** le chef de département et son adjoint **KARABADJI Nour El-Isslam** qui ont assuré une bonne conduite de notre cursus. Je tiens à remercier l'ensemble du personnel d'ESTI **Annaba** qui a consacré leurs efforts afin de nous assurer une efficace formation.*

Dédicace

Je dédie ce modeste mémoire

À mes chers parents pour leurs amour qu'ils m'ont donné, pour leurs encouragements et de l'aide qu'ils m'ont apporté toute au long mes études

Aucun mot, aucune dédicace qui ne pourrait exprimer mon respect, ma considération et mon profond amour pour les sacrifices qu'ils ont consentis pour mon instruction et mon bien-être, puisse Dieu leurs accorder santé, bonheur, prospérité et une longue vie.

À mes adorables sœurs : Safa et Hana que Dieu tout-puissant vous protège, vous bénir, vous apporte le bonheur, les aides à réaliser toute vos vœux et vous offre un avenir plein de succès

À mes grands-parents, mes tantes, mes Oncles, leurs époux et épouses, mes cousins et cousines, mes collègues que le bon Dieu vous protège et vous dirige vers le mieux

À mes chères amies Roumaïssa, Khaoula, Imene et Madjeda merci beaucoup d'être dans ma vie pour me donner de l'énergie positive, merci pour tous les souvenirs.

Résumé

Dans le milieu industriel, les systèmes de production sont de plus en plus complexes et ne peuvent être exempts de perturbations et de défaillances, influant sur la qualité du produit, pouvant provoquer l'arrêt immédiat d'une machine et porter atteinte au bon fonctionnement d'un système de production entier. Le diagnostic de défauts de ces machines, s'appuie essentiellement sur la surveillance de symptômes liés à différentes conditions de dégradation. Ces symptômes peuvent être tirés et extraits de diverses sources d'information, parmi lesquelles, l'analyse vibratoire occupe une place prépondérante. Diverses techniques, de traitement des signaux vibratoires, ont été explorés et expérimentées, sur des données issues de plusieurs campagnes d'essais. Des approches basées sur la variable angulaire ont aussi été investiguées, permettant une multiplication des sources d'information. En plus des techniques classiques, deux nouvelles procédures d'exploitations de l'information position ont été proposées. Pour atteindre une exploitation optimale des sources d'information, plusieurs des techniques de l'intelligence artificielle ont été mises au service du diagnostic de défauts des machines tournantes, où plusieurs techniques de sélection et de transformation d'indicateurs ont été explorées lors de la construction des vecteurs d'entrée des classifieur, et un algorithme efficace a été construit basé sur l'association d'une recherche ascendante et de techniques filtrantes. La combinaison des techniques de traitement des signaux et de l'intelligence artificielle a permis, en plus de fournir des outils de diagnostic efficaces, de quantifier la pertinence des sources d'information exploitées et proposées.

Mots-clés : diagnostic, intelligence artificielle, vibration, approches angulaires, rapport de transmission instantanée, machines tournantes.

Abstract

In the industrial field, production systems are growing in complexity, which increase the risk of failure and disruption. The apparition of such phenomenon, in addition to affecting products quality, could cause immediate shutdown of a machine and undermine the proper functioning of an entire production system. Fault diagnosis of industrial machines, is based mainly on monitoring symptoms related to the different degradation conditions. These symptoms could be extracted from various information sources, where, vibration analysis has a privileged position. Various vibration signal-processing techniques were experienced on data extracted from several test campaign. Approaches based on the angular variable have also been investigated, allowing a proliferation of information sources. Where, in addition of conventional techniques, two new procedures for position information

use have been proposed. In order to achieve optimal exploitation of the several existing information sources, Artificial Intelligence techniques have been used, seeking an optimal fault diagnosis of rotating machinery, where several indicators selection and transformation techniques have been explored in the construction of classifiers input vectors and an efficient algorithm was built based on a combination of forward search procedure and filtering techniques. The combination of signal processing techniques and artificial intelligence has, in addition to providing effective diagnostic tools, quantified the relevance of explored and proposed information sources.

Keywords: diagnosis, AI, vibration, instantaneous transmission ratio, rotating machines.

ملخص

في البيئة الصناعية، تكون أنظمة الإنتاج أكثر تعقيداً ولا يمكن أن تكون خالية من الاضطرابات والفشل، مما يؤثر على جودة المنتج، مما قد يتسبب في الإغلاق الفوري للآلة وإضعاف الأداء السليم للآلة. نظام إنتاج كامل. يعتمد تشخيص الأخطاء لهذه الآلات بشكل أساسي على مراقبة الأعراض المتعلقة بظروف التدهور المختلفة. يمكن استخلاص هذه الأعراض واستخراجها من مصادر مختلفة للمعلومات، من بينها تحليل الاهتزاز الذي يحتل مكانة بارزة. تم استكشاف واختبار العديد من تقنيات معالجة الإشارات الاهتزازية على بيانات من عدة حملات اختبار. كما تم التحقيق في الأساليب القائمة على المتغير الزاوي، مما يسمح بضرب مصادر المعلومات. بالإضافة إلى التقنيات الكلاسيكية، تم اقتراح إجراءين جديدين لاستغلال معلومات الموقع. لتحقيق الاستخدام الأمثل لمصادر المعلومات، تم استخدام العديد من تقنيات الذكاء الاصطناعي لتشخيص الأعطال في الآلات الدوارة، حيث تم استكشاف عدة تقنيات لاختيار وتحويل المؤشرات أثناء البناء. متجهات الإدخال للمصنفات، وتم بناء خوارزمية فعالة بناءً على مزيج من تقنيات البحث والتصنيف من أسفل إلى أعلى. أتاح الجمع بين تقنيات معالجة الإشارات والذكاء الاصطناعي، بالإضافة إلى توفير أدوات تشخيصية فعالة، تحديد مدى ملاءمة مصادر المعلومات المستغلة والمعروضة.

الكلمات المفتاحية: التشخيص، الذكاء الاصطناعي، الاهتزاز، المقاربة الزاوية، نسبة النقل اللحظي، الآلات الدوارة.

Sommaire

Résumé	i
Abstract	i
ملخص	ii
Sommaire.....	iii
Liste de figures	v
Liste des tableaux.....	v
Liste des abréviations.....	vi
Introduction générale.....	1
I. Chapitre 01 : Diagnostic de défauts des machines tournantes par l'analyse vibratoire ..	4
Introduction.....	4
I.1 L'analyse Vibratoire	4
I.2 Vibration.....	4
I.2.1 Définition :	4
I.2.2 Les différentes formes de vibrations.....	5
I.2.3 Vibrations des machines tournantes	7
• Surveillance	8
• Diagnostic.....	8
I.2.4 Principales méthodes d'Analyse vibratoire	8
I.2.5 Outils d'analyse vibratoire	10
I.3 Principaux défauts d'une machine tournante et leurs manifestations	12
I.3.1 Balourd.....	12
I.3.2 Délignage (ou mauvais alignement)	14
I.3.3 Défauts d'engrenages	15
I.3.4 Défauts de roulement	18
I.3.5 Défauts de courroies	21
I.4 Détection de défauts des roulements.....	22
I.4.1 La méthode de l'enveloppe	22
I.4.2 La transformée en ondelettes.....	23
I.4.3 La décomposition en valeurs singulières	23
Conclusion	24
II. Chapitre 02 : Intelligence Artificielle ANN. CNN	26
Introduction.....	26
II.1 IA : Intelligence artificielle	26
II.2 L'apprentissage Automatique.....	27
II.3 Réseaux de neurone artificiel	27
II.3.1 Définition RNA	27

II.3.2	Inspiration biologique	28
II.4	Neurone Artificiel	28
II.5	Entraînement de réseau de neurone	30
II.6	Les types de réseaux de neurones artificiels	31
II.6.1	Perceptron à une ou plusieurs couches (PMC).....	31
II.6.2	Les cartes de Kohonen ou Kohonen Self-organising Feature Maps (SOFM).....	33
II.6.3	Réseau de Hopfield	33
II.6.4	Réseaux de Neurone Convolutionnal (CNN)	34
	Conclusion	37
III.	Chapitre 03 : Etude de cas classification de défauts des roulements à l'aide de CNN et ANN	39
	Introduction.....	39
III.1	Présentation de l'entreprise CILAS.....	39
III.1.1	CILAS Biskra	39
III.1.2	Historique de LaFargeHolcim	40
III.2	Prétraitement de données	41
	Conclusion	45
	Conclusion générale	46
	Références bibliographiques.....	47

Liste de figures

Figure I-1: Représentation d'une vibration.....	5
Figure I-2: Vibration harmonique.....	6
Figure I-3: Vibration périodique.....	7
Figure I-4: Vibration apériodique.....	7
Figure I-5: Accéléromètre piézoélectrique.....	10
Figure I-6: Chaîne d'acquisition.....	11
Figure I-7: Ecart d'usinage (excentricité et parallélisme)	12
Figure I-8: Spectres fréquentiels du défaut de balourd.	13
Figure I-9: Défaut de délignage.....	14
Figure I-10: Spectre du défaut de délignage.....	15
Figure I-11: Dégradation des dents d'une roue dentée	16
Figure I-12: Spectre RC et peigne de raies du défaut d'engrenages.....	17
Figure I-13: Cepstre du défaut d'engrenages	18
Figure I-14: Défaut d'écaillage de roulement.....	18
Figure I-15: Mise en évidence d'un défaut de roulement par un.....	21
Figure I-16: Transmissions par courroies.....	21
Figure II-1: Neurone Biologique	28
Figure II-2: Structure de Neurone Artificiel.....	29
Figure II-3: Correspondance Neurone Biologique/Neurone Artificiel	29
Figure II-4: Structure, Comportement d'un Perceptron simple.....	32
Figure II-5: Perceptron simple /Perceptron Multicouches	33
Figure II-6: Structure d'un réseau de neurone Convolutionnel CNN	35
Figure II-7: Classification d'image par CNN (Machine learning) et MLP (Deep Learning)	37

Liste des tableaux

Tableau I-2: Principales méthodes d'analyse vibratoire	9
Tableau I-1: Indicateurs vibratoires	11
Tableau II-1: différents types de fonctions de transfert de RNA.....	30

Liste des abréviations

RNA : réseau de neurones artificiels

CNN : Convolutionnal neural network (réseaux de neurones convolutionnels)

CPM : Cycle par minute

RCM : rotation par minute

RMS : Root Mean Square

V_{eff} : Tension efficace

F_r : fréquence de rotation

F_e : fréquence d'engrènement

F_{be} : fréquence d'un défaut localisé sur la bague externe du roulement

F_{bi} : fréquence d'un défaut localisé sur la bague interne du roulement

F_b : fréquence d'un défaut localisé sur l'élément roulant du roulement

F_c : Défaut de cage du roulement

Introduction générale

L'analyse vibratoire occupe une place prépondérante dans le dépistage et le diagnostic de défauts des machines tournantes, et ce, de façon croissante en raison des performances toujours plus accrues en matière de traitement du signal. L'acquisition de l'information vibratoire s'effectue sur plusieurs étapes : Avec en premier lieu, la transformation des déplacements mécaniques en un signal électrique par le biais de capteurs installés sur la machine ; suivie par l'acquisition des signaux à partir des capteurs et leur échantillonnage (classiquement à pas temporel constant) afin de les rendre exploitables par les organes de calcul ; et pour finir le traitement digital des signaux afin de pouvoir extraire une information utile à la reconnaissance des états de fonctionnement. Les géométries discrètes des machines tournantes, ainsi que les mouvements cycliques qu'elles produisent perturbent les techniques classiques d'exploitation des signaux (basée sur un échantillonnage temporel), et ce, de manière plus significative, dans des conditions de fonctionnement non stationnaires (variations de vitesse et de charge). Pour pallier les insuffisances des approches temporelles, des approches alternatives basées sur la variable générique des machines tournantes (variable angulaire), ont suscité ces dernières années, un vif intérêt de la part de la communauté scientifique. Par conséquent, plusieurs techniques d'échantillonnage et de ré-échantillonnage des signaux à pas angulaire constant ont été développées. Parallèlement d'autres sources d'information (vitesses de rotation instantanées, erreurs de transmission. . .), exploitant les positions angulaires des arbres tournants, ont aussi été investiguées et ont montré une certaine compatibilité avec les modes de fonctionnement des machines tournantes. Avec la multiplication des sources d'information et la croissance des techniques de traitement du signal, l'exploitation optimale de l'information, et l'évaluation objective de sa pertinence deviennent des tâches fastidieuses.

Les techniques de l'intelligence artificielles se présentent aujourd'hui comme une solution, permettant de résoudre un grand nombre de ces problèmes. En effet, la fonction de diagnostic pourrait s'assimiler à une fonction de classification, tachant de distinguer, en se basant sur l'information fournie (sous forme de vecteur d'entrée), les conditions de fonctionnement des machines supervisées. Les performances de ces techniques de classification ne sont en fait, que les résultantes de la pertinence de l'information fournie.

Ce mémoire est réparti en trois chapitres dont le premier représente une étude sur le Diagnostic de défauts des machines tournantes par l'analyse vibratoire, le deuxième est consacré pour un état de l'art sur l'intelligence artificielle et les réseaux de neurones artificiels.

Le troisième montre une application effective, de l'une des techniques de l'intelligence artificielle pour le diagnostic des machines tournantes en utilisant les réseaux de neurone artificielles et les réseaux e neurones convolutifs.

CHAPITRE 01 : Diagnostic de défauts des machines tournantes par l'analyse vibratoire

I. Chapitre 01 : Diagnostic de défauts des machines tournantes par l'analyse vibratoire

Introduction

A l'heure actuelle, de plus en plus d'industriels se tournent vers l'analyse vibratoire afin d'obtenir une disponibilité accrue de leurs machines : ils contrôlent l'état réel de leurs équipements (machines tournantes) afin d'éviter des arrêts non planifiés dus aux pannes.

La maintenance des machines par analyse des vibrations permet de mieux gérer les défaillances, en détectant les défauts à un stade précoce, avant qu'ils ne deviennent critiques. Dans les procédures de maintenance, on peut classer les étapes d'intervention en deux niveaux :

- le premier niveau consacré à la surveillance, utilise des indicateurs scalaires (RMS, Facteur de crête, Kurtosis, etc....) pour mettre en évidence l'apparition d'un ou de plusieurs défauts.
- 2. le second niveau caractérisé par le diagnostic, intervient après l'étape de surveillance et utilise les différentes techniques de diagnostic (analyse spectral, cepstral, etc....), afin de localiser plus précisément la nature et le lieu du défaut, c'est une technique plus récente. Dans ce chapitre sont présentées les notions de base d'une vibration et les techniques de surveillance

Ce mémoire présente de manière détaillée et approfondie les techniques de surveillance et de diagnostic des machines tournantes par analyse de vibrations.

I.1 L'analyse Vibratoire

Est un des moyens utilisés pour suivre la santé des machines tournantes en fonctionnement afin d'éviter les arrêts indésirables. Cela s'inscrit dans le cadre d'une politique de maintenance prévisionnelle de l'outil de production industrielle, elle poursuit deux objectifs :

- la détection des défauts.
- l'analyse détaillée des défauts.

I.2 Vibration

I.2.1 Définition :

Selon la norme NFE 90-001 : Une Vibration est une variation avec le temps d'une grandeur caractéristique du mouvement ou de la position d'un système mécanique lorsque la grandeur est alternativement plus grande et plus petite qu'une certaine valeur moyenne ou de référence. Le

mouvement Vibratoire le plus simple à étudier est celui traduisant le déplacement d'un point(A) situé sur un cercle et tournant à une vitesse de rotation (ω) (Figure 1).




Figure I-1: Représentation d'une vibration

La rotation de A entraîne une variation sinusoïdale de sa projection X qui répond à la relation (1) : $X(t) = A \sin(\omega t) \dots (1)$

La fréquence est le nombre de fois qu'un phénomène se répète en un temps donné. Lorsque l'unité choisie est la seconde, la fréquence s'exprime en hertz. Une Vibration qui se produira 50 fois par seconde aura une fréquence de 50 hertz. [20] (1 hertz= 1 cycle/1 seconde). La période T du signal correspond à la durée d'un cycle. Si la fréquence d'un phénomène est de 50 hertz, c'est à dire 50 cycles par seconde, la durée d'un cycle (c'est à dire la période T) est de 1/50° de seconde. La fréquence est donc l'inverse de la période : $F=1/T$.

Le signal Vibratoire obtenu précédemment est une sinusoïde de période T. La période T est fonction de la Vitesse de rotation : plus on tourne vite (ω grand) et plus la période sera petite, donc plus la fréquence sera grande. Donc il existe un lien entre la fréquence et la vitesse de rotation : $\omega = 2\pi f$ et $f = N/60$ avec ω en $\frac{rad}{s}$ f en Hz et N en (1 tr/min).

Sur les machines tournantes industrielles, on utilise souvent le tour par minute pour exprimer une vitesse de rotation, parfois noté CPM (cycle par minute) ou RPM (rotation par minute).

I.2.2 Les différentes formes de vibrations

On classe les vibrations d'après l'évolution de la variable considérée dans le temps (périodicité). On distingue ainsi les vibrations :

- 1- Harmoniques
- 2- Périodiques

3- Apériodiques

- **Vibration harmonique**

La sinusoïde : C'est la forme d'onde la plus simple à caractériser. Cette forme d'onde particulière, peut se visualiser comme le mouvement de la projection verticale de l'extrémité d'une aiguille d'une horloge, ou le mouvement de translation d'un système masse – ressort non amorti. La période T correspond à un tour complet de l'aiguille ou au temps que met la masse pour faire un aller-retour. Une sinusoïde est une courbe alternative, de Valeur moyenne nulle, représentée par une fonction mathématique Simple (Figure 2).




Figure I-2: Vibration harmonique

Elle est décrite par l'équation (2) : $X(t) = X \sin(\omega t + \varphi) \dots (2)$ Avec :

ω : Fréquence angulaire ou pulsation du mouvement ($2 \pi f$) en rad/s.

f : fréquence du mouvement en Hz.

φ : Phase du mouvement par rapport à un repère dans le temps.

- **Vibrations périodiques :**

Une vibration périodique est telle qu'elle se reproduit exactement après un certain temps appelé période. Une telle vibration est créée par une excitation elle-même périodique. C'est le cas le plus fréquent rencontré sur les machines. Une Vibration périodique est la composée de plusieurs Vibrations harmoniques (Figure 3).




Figure I-3: Vibration périodique

Elle est décrite par l'équation (3) : $v(t) = \sum_{i=1}^{\infty} v_i \times \sin(\omega_i.t + \varphi_i) \dots (3)$

• **Vibration apériodique :**

Une vibration apériodique est telle que son comportement temporel est quelconque, c'est-à-dire que l'on n'observe jamais de reproductibilité dans le temps. Figure 4.



Figure I-4: Vibration apériodique

Elle est décrite par l'équation : $v(t) = \sum_{i=1}^{\infty} X_i \times \sin(\omega_i.t + \varphi_i) \dots (4)$

I.2.3 Vibrations des machines tournantes

En pratique, une bonne conception produira de faibles niveaux vibratoires dans une machine tournante. Cependant, la machine vieillissant, les fondations travaillent, les pièces se déforment et s'usent, et de légers changements dans ses propriétés dynamiques apparaissent. Les arbres se désalignent, les paliers s'usent, les rotors se déséquilibrent, les courroies se détendent, les jeux augmentent. Tous ces facteurs se traduisent par une augmentation de l'énergie vibratoire qui excite les résonances et ajoute une charge dynamique considérable aux paliers.

Les vibrations recueillies lors des campagnes de mesures sont porteuses d'informations qui caractérisent l'état de fonctionnement de certains composants mécaniques constituant la machine analysée. C'est grâce à l'analyse de ces vibrations qu'il est possible de détecter les composants défectueux et éventuellement de les localiser. Lorsqu'un certain seuil (correspondant à un niveau de

vibration limite) fixé est atteint, il est possible d'estimer la durée de vie résiduelle du composant dans les conditions de fonctionnement données à partir de la connaissance des lois d'endommagement

- **Surveillance**

La comparaison des mesures vibratoires effectuées à intervalles de temps déterminés dans des conditions de fonctionnement identiques permet de suivre l'évolution d'un défaut en exploitant le signal vibratoire [18]. A partir de ces mesures, il est possible d'obtenir un historique de l'évolution du défaut par rapport à un niveau de référence caractérisé par la signature vibratoire de la machine en bon état. La norme [ISO10816] fixe des critères d'évaluation des niveaux vibratoires permettant d'estimer la sévérité des défauts et donc de l'état de fonctionnement de la machine. La sévérité vibratoire représente la valeur efficace de la vitesse de vibration mesurée dans la bande fréquentielle [10-1000 Hz] sachant que les critères d'évaluation dépendent de la classe dans laquelle la machine se situe. Mais ces méthodes dites « mesures des niveaux globaux » restent imprécises et ne permettent pas la détermination de la cause de l'augmentation du niveau vibratoire.

- **Diagnostic**

Pour établir un diagnostic vibratoire, il est souvent nécessaire de faire appel à des outils mathématiques relativement élaborés. Ces outils doivent assister l'opérateur et lui permettre de remonter aux origines du ou des défauts. Mais dans l'absolu, les signaux vibratoires sont insuffisants pour établir un diagnostic. C'est pourquoi il est indispensable de connaître non seulement la cinématique de la machine, mais également les caractéristiques de ses composants ainsi que leurs différents modes de dégradation. La connaissance de ces modes de défaillance et de leurs influences sur le niveau de vibration est à la base d'un diagnostic et d'une surveillance fiable.

1.2.4 Principales méthodes d'Analyse vibratoire

La surveillance des machines ne se limite pas juste à détecter la présence d'un défaut, mais il est aussi nécessaire de pouvoir réaliser un diagnostic approfondi pour le localiser précisément et quantifier sa sévérité. **L'analyse vibratoire** est une technique qui permet de réaliser ce diagnostic

Pour plus de précision, le diagnostic par analyse vibratoire nécessite d'étudier :

- les valeurs du niveau global des vibrations,
- les contenus fréquentiels des signaux à l'aide outils sophistiqués du traitement de signal (spectre, cepstre, analyse d'enveloppe etc...).

Tableau I-1: Principales méthodes d'analyse vibratoire

Méthodes d'analyse vibratoire qualitatives	Principaux avantages	Principales limitations
Analyse temporelle	- adaptée aux faibles vitesses de rotation - permet d'analyser des phénomènes non périodiques (chocs aléatoires, chocs répétitifs à vitesses variable)	- diagnostic souvent difficile
Analyse fréquentielle	- permet de localiser les défauts et de réaliser le diagnostic fiable - ne nécessite pas de mesures supplémentaires	- interprétation des spectres parfois difficile - détection tardive - inopérant à vitesse ou charge variable
Analyse d'enveloppe	- détection de défauts à un stade précoce - permet de déterminer de manière fiable et rapide les fréquences de répétition des chocs	- interprétation des spectres parfois difficile - nécessite de connaître le domaine fréquentiel d'intérêt - inopérant si vitesse ou charge variable - généralement associée à d'autres indicateurs (le Kurtosis par exemple)
Analyse cepstral	- met en évidence les composantes périodiques d'un spectre - permet de localiser et déterminer l'origine des défauts induisant les chocs périodiques - interprétation des spectres complexes	- utilisation en complément d'autres techniques

I.2.5 Outils d'analyse vibratoire

- **Capteurs de vibrations**

Le capteur le plus utilisé est l'accéléromètre piézo-électrique. Il est constitué d'une masselotte placée sur un cristal piézo-électrique dont les deux faces opposées ont été rendues conductrices par dépôt métallique (figure 5). Il possède une très bonne linéarité et une large bande passante. Un capteur monodirectionnel collé sur la paroi d'un bâti mesurera les accélérations normales à celle-ci. Sa masse, bien que légère (environ 20 g), influence malgré tout toutes les mesures, car sur des parois de grandes dimensions et relativement peu épaisses, une masselotte ajoutée peut faire diminuer les fréquences propres de quelques pour cent.

La fixation du capteur sur la structure peut avoir une réelle influence sur la qualité du signal recueilli. Il peut être fixé de diverses façons sur la machine : vissé à même la structure, vissé sur une embase collée, magnétique pour les structures ferriques, ou accolé avec une pointe touche. Cette fixation joue un rôle important sur le résultat des mesures, et la largeur de bande peut s'en trouver affectée.




Figure I-5: Accéléromètre piézoélectrique

- **Chaîne et matériel d'acquisition**

Une surveillance fiable ne peut être obtenue que si d'une part le matériel de mesure est en adéquation avec les caractéristiques vibratoires fournies par les machines et si d'autre part les données le sont avec les outils de post-traitement qui doivent en faciliter le diagnostic. Il est indispensable de posséder

un matériel d'analyse des vibrations qui peut être constituée des éléments suivants : en plus de la structure à étudier, des capteurs, conditionneur, pot vibrant ou marteau d'impact, analyseur et programme d'analyse modale, sont nécessaires, comme le montre la figure ci-dessous.




Figure I-6: Chaîne d'acquisition

Les capteurs doivent être placés sur un certain nombre de points choisis judicieusement, c'est à dire le plus proche possible des sources de vibrations et dans une direction donnée, si ces sources sont connues et si la structure le permet.

Le tableau ci-dessous représente les indicateurs vibratoires.

Tableau I-2: Indicateurs vibratoires

Indicateurs vibratoires simples	Equation	Principaux avantages	Principales limitations
La valeur efficace ou valeur RMS (Root Mean Square)	$RMS = \sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)]^2}$	-est un des premiers indicateurs utilisés en industrie, dû notamment à sa simplicité et à sa rapidité d'exécution.	-L'utilisation du RMS c'est qu'il donne généralement une alarme assez tardive.
Kurtosis (moment statique d'ordre 4)	$kurtosis = \frac{M_4(s(t))}{M_2^2(s(t))} = \frac{\frac{1}{N_e} \sum_{n=1}^{N_e} (s(t) - \bar{s})^4}{[\frac{1}{N_e} \sum_{n=1}^{N_e} (s(t) - \bar{s})^2]^2}$	-adapté à la surveillance des roulements des arbres tournant à de faibles vitesses de rotation (<600 t/min) -détection à stade précoce	-décroissance de l'indicateur en fin de vie des roulements - diagnostic souvent difficile

		- grande sensibilité aux chocs périodiques et non périodique	
Facteur de crête (rapport entre la valeur de crête et la valeur efficace)	$FC = \frac{\text{valeur crête}}{RMS}$ $= \frac{\sup s(t) }{\sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [s(t)]^2}}$	-indépendant des conditions de fonctionnement (dimensions des roulements, charge, vitesse de rotation)	-décroît lorsque les défauts se développent

I.3 Principaux défauts d'une machine tournante et leurs manifestations

I.3.1 Balourd

Quel que soit le soin apporté à la construction des machines, il n'est pas possible de faire coïncider l'axe de rotation avec le centre de gravité de chaque tranche élémentaire du rotor, ce qui caractérise le balourd. Il en résulte que l'arbre en rotation est soumis à des efforts centrifuges qui le déforment. Le balourd est un déséquilibre massique qui provient généralement du défaut d'usinage, d'assemblage et de l'échauffement dissymétrique du rotor lors du fonctionnement figure 7. Les origines des balourds sont multiples.




Figure I-7: Ecart d'usinage (excentricité et parallélisme)

➤ Manifestation

Ce défaut se manifeste par :

- l'augmentation du niveau global choisi en basses fréquences, soit D_{cc} [10-1000 Hz], soit V_{eff} [10-1000 Hz],
- la nette augmentation de l'amplitude de la fréquence fondamentale (fréquence de rotation, f_r).

$$f_r = \frac{N}{60}$$

N vitesse de rotation (tr/min).

Exemple : Mise en évidence d'un défaut de balourd figure ci-dessous.




Figure I-8: Spectres fréquentiels du défaut de balourd.

- Le spectre bleu (machine en bon état de fonctionnement) : amplitude de la fréquence fondamentale 1.323 mg pour 16.25 Hz,
- Le spectre rouge (machine en fonctionnement dégradé : défaut d'équilibrage) : amplitude de la fréquence fondamentale 14.199 mg pour 16.25 Hz.

Ce défaut n'est pas directionnel, on recueille la même image dans toutes les directions radiales (verticale, horizontale ou oblique).

➤ Origine des différents types de balourds

- **Balourd d'origine mécanique** : lorsqu'il y a une masse de matière qui se détache du rotor ou vient de déposer sur ce dernier (perte d'ailette ou rupture d'une aube, érosion ou dépôt de matière, fluage du rotor), on observe généralement une évolution instantanée des vibrations.
- **Balourd d'origine thermique** : lorsque les rotors ne sont pas homogènes ou la température n'est pas répartie de façon uniforme, les rotors se déforment sous l'effet de contraintes thermiques : - déformation des rotors de turbines, - déformation des rotors d'alternateurs ou de moteurs électriques.
- **Balourd évolutif** : est dû aux frottements de l'arbre avec un des paliers de la machine et provoquant un échauffement dissymétrique.

I.3.2 Délignage (ou mauvais alignement)

L'arbre moteur et l'arbre récepteur d'une machine ne sont pas parfaitement alignés figure ci-dessous.




Figure I-9: Défaut de délignage

➤ **Manifestation**

Ce défaut se manifeste au cours de :

- l'augmentation du niveau global choisi en basses fréquences Soit D_{cc} [10-1000 Hz], Soit V_{eff} [10-1000 Hz].
- l'augmentation des proches harmoniques de F_r . Le plus souvent l'harmonique de rang 2 tend à s'élever au-delà de la fréquence fondamentale. Parfois le phénomène se transmet aux 3èmes et 4ème harmonique.

Exemple : Mise en évidence d'un défaut de délignage

On ne recueille pas le même signal sur les différentes directions radiales. Ce défaut est plutôt visible sur une direction axiale (figure 1.10). Il peut être d'origine :

- mécanique : desserrage des pieds de fixation de la machine et desserrage des éléments de transmission du mouvement de rotation,
- thermique : croissance thermique des pieds de fixation de la machine en fonctionnement.




Figure I-10: Spectre du défaut de déalignement

1.3.3 Défauts d'engrenages

Ces défauts sont liés aux dégradations de la denture (denture cassée ou abimée, usure uniforme ou non, pitting localisé ou réparti, mauvais centrage) (figure 1.11). On peut observer aussi du fretting (corrosion, frottement) qui se traduit par un enlèvement de métal lorsque l'engrenage est mal lubrifié et que les efforts sont importants.


Les vibrations des engrenages sont dominées par un effort à chaque contact. Un arbre tournant à une fréquence f_r sur lequel est monté un pignon ou une roue comptant z dents sera soumis à z chocs par tour. La fréquence caractéristique de l'engrènement sera :

$$f_e = z \cdot f_r$$




Figure I-11: Dégradation des dents d'une roue dentée

Si l'arbre ou le pignon présente un défaut d'excentricité ou si une dent du pignon présente un défaut localisé, il va apparaître une modulation d'amplitude du signal par la fréquence du signal. Cela se traduira, sur le spectre, par un peigne de raies centré sur la fréquence d'engrènement f_e et de pas f_r . Ce peigne est visible que sur un zoom centré lui aussi sur la fréquence d'engrènement f_e . (Figure 1.12)



On y distingue nettement la fréquence d'engrènement préalablement calculée : $f_e = 8\,175\text{ Hz}$

(a) spectre RC HF : Acc_{eff} [0 - 10 000 Hz]



Le peigne de raies apparaît. Son pas est de 25 Hz, soit la fréquence de rotation de l'arbre primaire

(b) zoom RC : Acc_{eff} [8 040 - 8 240 Hz]

Figure I-12: Spectre RC et peigne de raies du défaut d'engrenages

Si une même machine est le siège de plusieurs engrènements, les images caractéristiques de chacun peuvent se superposer de manière à ne plus être reconnaissables. Le seul outil permettant de dissocier

les différents phénomènes est le spectre (figure 1.13). Il fait apparaître un pic caractéristique pour chaque fréquence de modulation. Cela permet de séparer les phénomènes de chaque ligne d'arbre




Figure I-13: Cepstre du défaut d'engrenages

I.3.4 Défauts de roulement

Les roulements sont parmi les composants les plus sollicités des machines et représentent une source de panne fréquente (figure 1.14). Les défauts que l'on peut y rencontrer sont les suivants : écaillage, grippage, corrosion (qui entraîne l'écaillage), faux effet Brinell, etc... Tous ces défauts se traduisent par une perte de métal et provoquent des chocs répétés des billes sur la cage de roulement.



Figure I-14: Défaut d'écaillage de roulement

Les pistes des roulements et les billes sont chargées cycliquement, ce qui engendre à la surface une dégradation par fatigue qui se présente sous la forme de fissures qui conduisent à l'écaillage puis à la ruine du roulement. Ces fissures peuvent être d'origine superficielle ou provenir de la dégradation de la sous couche du matériau. Cette ruine peut être détectée sur un spectre à partir de l'identification des fréquences caractéristiques du roulement. Celles-ci correspondent aux fréquences des impacts lorsqu'un élément roulant rencontre un défaut. Elles sont données en écrivant que les vitesses aux points de contact entre billes et bagues sont nulles. Elles dépendent du diamètre des éléments roulants (d), du diamètre moyen du roulement (D), du nombre d'éléments roulants (N), de l'angle de contact (φ) et de la fréquence de rotation relative entre les bagues intérieure et extérieure (f_r). Elles sont données par les formules :

- Fréquence d'un défaut localisé sur la bague externe du roulement

$$f_{be} = \left(\frac{N}{2}\right) f_r \left[1 - \left(\frac{d}{D}\right) \cos \varphi\right]$$

- Fréquence d'un défaut localisé sur la bague intérieure

$$f_{bi} = \left(\frac{N}{2}\right) f_r \left[1 + \left(\frac{d}{D}\right) \cos \varphi\right]$$

- Fréquence d'un défaut localisé sur un élément roulant

$$f_b = \left(\frac{D}{d}\right) f_r \left[1 - \left(\left(\frac{d}{D}\right) \cos \varphi\right)^2\right]$$

- Fréquence d'un défaut de cage

$$f_c = \left(\frac{1}{2}\right) f_r \left[1 - \left(\frac{d}{D}\right) \cos \varphi\right]$$

Ces fréquences peuvent être rencontrées pour un roulement en fonctionnement normal (du fait du non linéarité de la raideur de contact sur un roulement en fonctionnement), mais surtout lors de l'apparition de défauts sur les éléments le constituant qui vont engendrer des impulsions produites à chaque fois qu'un élément roulant rencontre un écaillage sur son chemin.

➤ **Manifestation**

Un tel défaut se traduit par une nette augmentation du niveau des fréquences supérieures à 1000 Hz, l'ensemble des fréquences supérieures à 1 kHz augmente sur un PBC ou un spectre RC HF, le facteur K augmente, le facteur de crête FC diminue et le niveau global A_{ceff} [1000-10000 Hz] augmente

➤ Origine

Ce peut être :

- un écaillage de la piste interne (sur l'arbre).
- un écaillage sur la piste externe (sur l'alésage).
- un défaut localisé sur un élément roulant (bille ou rouleau).

Dans tous les cas, il s'agit d'un choc périodique de faible énergie qui excite la structure de la machine. Cette structure répond dans une gamme de fréquences qui lui est propre. Afin de statuer de façon définitive sur un tel défaut, il est conseillé de réaliser une analyse dite d'enveloppe [16] :

1^{er} temps : on détecte la possibilité d'un tel défaut sur spectre PBC ou un spectre RC HF (figure 1.15b) ;

2^e temps : on paramètre une analyse d'enveloppe figure (1.15), en fonction des fréquences dont le niveau a augmenté (forme de « bosse de chameau » ou « cloche »). On parle de « gamme fréquentielle de filtre » : c'est une gamme HF, des fréquences caractéristiques du (ou des) roulement(s) suspecté(s). On parle de « gamme fréquentielle d'analyse » : c'est une gamme BF ou MF ;

3^e temps : analyse du spectre enveloppe obtenu.

Exemple : Mise en évidence d'un défaut de roulement (figure 1.15)

Le roulement surveillé présente toutes les caractéristiques d'un écaillage ou d'une fissuration sur la piste externe. Le défaut va ensuite contaminer les autres éléments.




Figure I-15: Mise en évidence d'un défaut de roulement par un

I.3.5 Défauts de courroies

Les courroies sont utilisées pour transmettre la puissance entre deux arbres dont la distance n'est pas trop importante. Une courroie, constituée par une bande sans fin passant sur deux poulies, transmet l'énergie grâce à son adhérence sur les poulies.

➤ Manifestation

N_1 et N_2 sont des vitesses de rotation des roues n° 1 et 2 de la figure 1.16.




Figure I-16: Transmissions par courroies

Les fréquences caractéristiques des défauts de courroies sont :

- Roue n°1 : $f_{c1} = f_r \frac{(\pi D_1)}{l}$
- Roue n°2 : $f_{c2} = f_r \frac{(\pi D_2)}{l}$

Où f_r représente la fréquence de rotation de l'arbre et l la longueur de la courroie.

➤ Origine

Les défauts de courroie sont engendrés par la conséquence d'une mauvaise pose, d'une usure ou par le défaut d'alignement des deux poulies. Les statistiques concernant les causes des défaillances et la localisation des défauts dans les machines tournantes permettent de conclure que les organes les plus sensibles sont les engrenages et les roulements.

I.4 Détection de défauts des roulements

La défaillance du roulement est l'une des principales causes de pannes dans les machines tournantes. Un tel défaut peut être catastrophique et engendrer des arrêts de production très coûteux. Pour optimiser la fiabilité des machines ainsi que les coûts directs et indirects, il s'agit non seulement de détecter la présence d'un défaut mais également de changer un élément uniquement quand cela est nécessaire. L'objectif est donc de prédire le niveau de défaillance (sévérité) qui va conduire à la perte de fonction. Cette prédiction consiste tout d'abord à détecter le défaut à son stade naissant et à alerter l'opérateur avant que la défaillance ne soit catastrophique. Les défauts de roulements peuvent être détectés à un stade précoce du développement. Pour estimer l'évolution du défaut de roulement, différents essais de fatigue sont réalisés.

Les méthodes classiques de détection de défauts des roulements :

I.4.1 La méthode de l'enveloppe

La méthode de l'enveloppe est une technique utilisant la résonance haute fréquence du roulement (ou du capteur). Pour ce faire, elle utilise la fréquence de résonance du roulement pour extraire l'information nécessaire à la détermination de la présence du défaut et met en évidence cette information dans une plage fréquentielle normalement observée en analyse vibratoire (0 – 1500 Hz). Plus précisément, la méthode de l'enveloppe utilise la modulation de l'amplitude de la fréquence de résonance du roulement, par la fréquence du défaut.

I.4.2 La transformée en ondelettes

Lorsque le signal n'est pas quasi périodique dans le temps, la transformée de Fourier n'est plus applicable. Il faut alors recourir à un autre outil mathématique : la transformée en ondelettes (TO). Cette dernière permet d'étudier simultanément l'information temporelle et fréquentielle (la méthode de l'enveloppe traitant les signaux dans un domaine puis dans l'autre mais jamais simultanément). De nombreux ouvrages décrivent la transformée en ondelettes. Dans elle est notamment utilisée pour détecter les défauts dans les roulements. Dans cet article, afin d'exploiter et interpréter l'information contenue dans la transformée en ondelettes, la décomposition en valeurs singulières est utilisée.

I.4.3 La décomposition en valeurs singulières

La décomposition en valeurs singulières (SVD) est un outil permettant l'extraction des composantes principales d'une matrice. Dans le cas de signaux vibratoires, ces composantes principales sont en fait liées à des structures de données maximisant l'énergie du signal. A titre d'exemple, la SVD d'une matrice composée des mesures vibratoires en différents points d'une structure, permet sous certaines conditions de retirer les modes propres spatiaux dominants présents dans ces données. Dans cet article, la SVD est utilisée pour décomposer la matrice résultante de la TO en ses différentes composantes à énergie élevée : les composantes parasites de faible énergie, dues au bruit par exemple, sont alors écartées. La SVD met ainsi en évidence des « modes propres fréquentsiels » correspondant aux différentes composantes de haute énergie. La SVD permet ainsi de « zoomer » et de faire apparaître les différentes fréquences caractéristiques des défauts qui n'apparaissent pas clairement lors d'une première transformée en ondelettes. Elle agit un peu comme un filtrage des composantes inintéressantes au profit des composantes dominantes.

Synthèse bibliographique

La méthode de l'enveloppe est une méthode qui se base sur l'excitation de la fréquence de résonance et la recherche de l'information à travers la modulation d'amplitude de cette fréquence de résonance, afin de ramener le signal en basses fréquences. Celle-ci s'est avérée très satisfaisante du point de vue pratique où elle a permis de diagnostiquer aisément le défaut de piste interne. Cette méthode est robuste par rapport au bruit (ceci est dû au filtrage autour de la fréquence de résonance). Toutefois, cette méthode a ses inconvénients : la recherche préalable des fréquences de résonance du roulement (et de son palier) est indispensable.

D'autre part, le choix de la fréquence de résonance autour de laquelle est effectué le filtrage, reste déterminant : les résultats risquent de varier selon que le filtrage s'effectue autour de telle ou telle fréquence de résonance. La transformée en ondelettes est un outil particulier : elle permet de résoudre

le problème de « non stationnarité » et de « non périodicité » en représentant le signal dans le plan temps-fréquence. Celle-ci est donc très utile lorsque les signaux sont non stationnaires, ce qui peut arriver en industrie puisque les mesures sont relevées en fonctionnement. Toutefois, il semble que celle-ci soit mal adaptée à l'analyse directe des signaux car les fréquences caractéristiques des défauts n'apparaissent pas dans le plan temps fréquence sans l'aide d'un post-traitement. Heureusement, il est possible d'utiliser une décomposition en valeurs singulières (SVD) sur les résultats de la TO afin d'extraire l'information représentative du défaut. La SVD décompose la matrice résultante de la TO en modes propres fréquentiels correspondant aux maximums d'énergie (filtration des fréquences d'intérêts). Ceci a permis d'extraire les composantes relatives aux défauts qui étaient invisibles avec la TO. La SVD permet ainsi d'exploiter au mieux les résultats de la transformée en ondelettes.

Conclusion

L'analyse vibration est l'une des moyens utilisés pour suivre la santé des machines tournantes en fonctionnement. L'augmentation de vibration de la machine permet de détecter et, après le traitement, localiser le défaut. Nous avons présenté, dans ce chapitre, des généralités sur l'analyse vibratoire des machines tournantes. Nous avons donné quelques notions et définitions de base utilisés dans le domaine de la surveillance des machines tournantes. Et les différentes techniques d'analyse vibratoire.

Chapitre 02 : Intelligence Artificiel ANN, CNN

II. Chapitre 02 : Intelligence Artificielle ANN. CNN

Introduction

Depuis l'émergence de la robotique et de l'informatique, les chercheurs essaient d'injecter des notions d'intelligence humaine dans des machines. Étant conçue et fabriquée par l'homme, on qualifie cette forme d'intelligence comme « L'intelligence artificielle ». L'intelligence artificielle est le domaine informatique qui s'intéresse à la modélisation et la simulation de tout comportement intelligent observé dans la nature.

Cette approche a été exploitée pour résoudre des problèmes de vie quotidienne, des problèmes logiques et mathématiques, diagnostiquer des maladies...etc. Dans le domaine d'ingénierie l'introduction des techniques de l'intelligence artificielle est devenue très indispensable surtout dans les industries lourdes y compris l'industrie pétrolière et gazière et les entreprises de production dans le but d'augmenter la productivité et l'efficacité des processus opérationnels, d'améliorer le contrôle de la qualité et de diagnostiquer les défauts des machines tournantes dans un temps raisonnable.

Dans ce chapitre on présentera l'approche de l'intelligence artificielle, les réseaux de neurone artificiels en outre les réseaux de neurone convolutionnel.

II.1 IA : Intelligence artificielle

Selon Marvin Minsky «IA est la construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisante par des êtres humains car elles demandent des processus mentaux de haut niveau tels que l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique »

L'intelligence artificielle est la science dont a pour objectifs ; la conception des systèmes capable à reproduire le comportement de l'être humain dans ses activités de raisonnement, la modélisation des phénomènes afin de les comprendre et de les gérer et la création des programmes qui génèrent leur propre connaissance en se modifiant à partir de leurs succès et leurs erreurs.

Dans le monde industriel pour aboutir à des robots de haut-niveau on fait appel à l'intelligence artificielle qui consiste à appliquer des algorithmes qui permettent une modification automatique du comportement du robot jusqu'à l'obtention du comportement désiré afin d'améliorer son comportement dans son environnement, ce qui appelle Apprentissage.

II.2 L'apprentissage Automatique

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement. (Touzet 1992)

L'apprentissage machine (Machine Learning) est un sous-domaine de l'intelligence artificielle, qui donne à un système une capacité de compréhension grâce à ses algorithmes. Il est basé sur l'idée de faire apprendre des algorithmes à partir de données et de faire des prédictions avec ces données et par cela les ordinateurs apprennent à résoudre des tâches spécifiques, sans avoir besoin de les programmer. Il existe 3 types ou catégories de l'apprentissage machine. Le premier s'appelle l'apprentissage supervisé où, après avoir présenté les données et les résultats souhaités aux ordinateurs, ils auront la capacité de faire des prédictions pour de nouvelles données d'entrée. Le second est l'apprentissage non supervisé où l'on ne donne à l'ordinateur que les données et où il doit trouver une structure avec un sens par lui-même sans l'intervention d'une supervision extérieure. Elle dépend principalement du clustering. Le processus d'apprentissage se fait par l'observation et non par l'exemple. Le troisième est l'apprentissage par renforcement où la machine se comporte comme un agent qui apprend de son environnement d'une manière interactive jusqu'à ce qu'il découvre les comportements qui produisent des récompenses (Abdelkader s. d.)

L'apprentissage d'un réseau de neurones est ainsi défini comme un problème d'optimisation qui consiste à trouver les coefficients du réseau minimisant une fonction de coût. L'apprentissage est mis en œuvre par un système d'apprentissage qui comprend le réseau dont les coefficients sont à estimer, les séquences d'apprentissage et leur processus générateur (processus, modèle de référence.), et l'algorithme utilisé pour l'estimation.

II.3 Réseaux de neurone artificiel

II.3.1 Définition RNA

Les réseaux de neurones artificiels (RNA) sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau. (Touzet 1998).

Ils sont utilisés pour résoudre des problèmes complexes en optimisation non linéaire ainsi que la classification d'une façon autonome.

II.3.2 Inspiration biologique

La conception des réseaux de neurones artificiels s'appuie essentiellement sur la structure des neurones biologiques du cerveau humain figure 1. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels se sont développés.

Le neurone du cerveau peut être considéré comme un automate comprenant :

La cellule centrale (ou soma) contenant le noyau, elle effectue des transformations biochimiques nécessaire qui assure la vie du neurone.

Les dendrites recevant les signaux d'autre neurone par l'intermédiaire des synapses.

L'axone qui achemine l'information en sortie de la cellule vers d'autres neurones par son extrémité. La jonction entre deux neurones est appelé synapses, les neurones sont séparé par un petit espace synaptique de l'ordre d'un centimètre de microns.




Figure II-1: Neurone Biologique

II.4 Neurone Artificiel

Est un processeur élémentaire qui reçoit un nombre variable d'entrées en provenance de neurones amonts, A chacune de ces entrées est associée un poids w représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals.

Le neurone propage son nouvel état interne sur son axone. Dans un modèle riche le neurone fonctionne avec des valeurs réels on dit que le réseau neuronal en état de transition lorsque tous ses neurones calculent en parallèle leur interne état en fonction de leurs entrées.

Romuald Boné, Jean-Pierre Asselin de Beauville et Monique Zollinger expliquent que : « Le neurone artificiel (ou cellule) reçoit des signaux (entrées) en provenance de l'environnement et des autres neurones auxquels il est relié. À chacune des entrées est associé un poids représentatif de la "force" de la connexion inter-neuronale. Chaque processeur possède sa propre fonction de transition (ou fonction d'activation ou fonction de transfert) qui lui permet de calculer sa sortie (ou son état) à partir des entrées et du poids des connexions associées. »




Figure II-2: Structure de Neurone Artificiel

La Figure 2 montre la structure du réseau de neurone artificiel, il possède des nœuds de traitement représentés par des cercles ainsi que des connexions à d'autres neurones qui sont représentés comme flèches.









Figure II-3: Correspondance Neurone Biologique/Neurone Artificiel

La figure ci-dessus montre la correspondance entre le neurone biologique et le neurone artificiel, le neurone artificiel est réalisé pour simuler le neurone biologique ou les poids correspondant aux connexions synaptiques, la fonction de transfert correspond au corps cellulaire qui traite les signaux

d'entrée et produit une réponse, et les éléments de sortie fonctionnent comme l'axone qui permet d'envoyer la réponse à l'unité qui suit.

Il existe plusieurs fonctions de transfert et le choix de type de la fonction de transfert dépend des exigences de la simulation.

Tableau II-1: différents types de fonctions de transfert de RNA

Nom	Valeur	Représentation
Seuil	$F(x)=0$ si $x<0$ $F(x)=1$ si $x>0$	
Linéaire	$F(x)=x$	
Linéaire saturée	$F(x)=0$ si $x<0$ $F(x)=x$ si $0 \leq x \leq 1$ $F(x)=1$ si $x>1$	
Sigmoïde	$F(x)= (1 + e^{-x})^{-1}$	
Tangente hyperbolique	$F(x)= (e^x - e^{-x}) \cdot (e^x + e^{-x})^{-1}$	

II.5 Entraînement de réseau de neurone

L'entraînement des réseaux de neurones artificiels est un processus graduel itératif dans lequel les poids du réseau sont modifiés plusieurs fois selon un but défini avant d'atteindre les valeurs finales. Parmi les méthodes d'entraînement du réseau l'algorithme de rétro propagation du gradient est le plus utilisé.

Cet algorithme est une méthode qui permet de calculer le gradient de l'erreur pour chaque neurone d'un réseau, de la dernière couche vers la première.

L'entraînement de réseaux de neurones artificiels se fait par quatre étapes :

Le calcul préalable : il permet de déterminer tous les poids de connexion établis sur des conditions initiales de valeurs aléatoires. Les valeurs d'unités de sortie sont donc évaluées une première fois. Ensuite la différence entre les valeurs du premier calcul et les valeurs attendues est estimée et prise compte dans chaque unité

La rétro propagation-couche de sortie : Dans cette étape, la différence précédemment établie dans l'étape 1 sera divisé dans les unités de la couche de sortie par des fonctions prédéfinies.

Les fonctions d'entraînement sont différentes des fonctions de transfert. Les déviations partielles de l'erreur de rétro propagation sur le poids de connexion sont calculés en considérant leurs entrées comme valeurs constantes et les poids comme des variables.

La rétro propagation-couche cachée : les erreurs de l'unité de sortie sont transmis aux unités cachées par les fonctions définis pour la couche cachée. Les dérivations partiales de rétro propagation des unités de la couche de sortie sont évaluées sur les poids de connexions entre la couche cachée et la couche de sortie. Comme pour la deuxième étape, les valeurs entrées de la couche d'entrée sont traitées comme valeurs constantes, les résultats des dérivations partiales sont fonction des poids de toutes les connexions des unités de la couche sortie l'unité cachée.

La mise à jour des poids : lorsque toutes les dérivations partiales de rétro propagation sont bien calculées les poids de connexion seront mise à jour en une direction de gradient négative. Une valeur constante est définie comme la longueur du pas de correction. Les nouveaux poids de connexions sont ainsi évalués et un nouveau calcul sera lancé jusqu'à l'obtention des valeurs finales des unités de sortie qui sont approuvées par l'attendu du calcul.(Liu 2013)

II.6 Les types de réseaux de neurones artificiels

Le choix de la structure de réseau de neurone artificiel à utiliser est en fonction de la méthode d'apprentissage utilisée et de l'objectif à atteindre.

Les différents types de RNA sont distingué par : la topologie de réseau, le nœud ou le type de neurone, la règle d'apprentissage associé au réseau.

II.6.1 Perceptron à une ou plusieurs couches (PMC)

➤ Le perceptron simple

Le perceptron est un réseau monocouche dont la dynamique est déclenchée par la réception en entrée d'information.

Ce réseau est dit simple car il ne se compose que de deux couches : une couche d'entrée et une couche de sortie ce qui implique une seule matrice de poids. L'ensemble des unités de la couche d'entrée sont connectés à celles de la couche de sortie.

Fonctionnement

Les entrées e_1 et e_2 sont pondérées par les poids w_1 et w_2 pendant l'apprentissage le neurone de la figure 4 réalise une simple somme pondérée de ses entrées, compare le résultat avec une valeur de seuil S , et fourni une réponse x binaire en sortie.

Par exemple :

Si $x = +1$ on dit que la classe est A

Si $x = -1$ on dit que la classe est B




Figure II-4: Structure, Comportement d'un Perceptron simple

➤ Le Perceptron multicouches (PMC)

MLP (Multi-Layer Perceptron), le perceptron multicouche est le réseau le plus utilisé, il se compose d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches cachées. Si le réseau possède n couches, alors il possède $n-1$ matrice de poids.

Le MLP doté d'une couche cachée est théoriquement un approximateur universel de fonctions. En théorie, il suffit donc d'ajouter un nombre de neurones suffisant au niveau de la couche cachée pour approximer n'importe quelle fonction non linéaire. (Anon s. d.)

Fonctionnement du MLP

Quand la couche d'entrée reçoit des informations grâce aux connexions la première étape est le décodage des informations reçus en valeurs binaires, les neurones de la couche d'entrée distribuent ses valeurs aux neurones de la couche intermédiaire. Chacun des neurones de la couche cachée réalise la somme pondérée de ses entrées. Ce processus est effectué en parallèle et indépendamment pour tous les neurones de la couche cachée. Lorsque le vecteur d'activation de la couche cachée a été obtenu, le

même processus est répété avec les neurones de la couche de sortie, le neurone de sortie prend la somme pondérée de ses entrées et applique la fonction non linéaire à la somme pondérée et génère un résultat final (sortie de ANN)




Figure II-5: Perceptron simple /Perceptron Multicouches

La figure 5 représente à gauche un perceptron simple qui se compose de deux couches ; couche d'entrée et couche de sortie et à droite un Perceptron multicouches contenant une couche d'entrée, couche cachée et couche de sortie.

II.6.2 Les cartes de Kohonen ou Kohonen Self-organising Feature Maps (SOFM)

Ce type de réseau est inspiré de l'organisation du cortex, les réseaux auto-organisés se distinguent par une connectivité locale. Ils sont surtout adaptés pour le traitement d'informations spatiales. Le modèle le plus connu de ce type est la carte auto-organisatrices de Kohonen appelée aussi carte auto-adaptative ou SOFM pour self-organizing features map.

La méthode d'apprentissage de ce type de réseau est non-supervisée. Ils peuvent être utilisés pour cartographier un espace réel ou encore étudier la répartition de données dans un espace de grandes dimensions comme dans le cas de problème de quantification vectorielle, de clusterisation ou de classification.

II.6.3 Réseau de Hopfield

Il s'agit d'un réseau qui se compose d'une seule couche où toutes les unités sont interconnectées. Il s'agit d'une mémoire auto-associative : constituée d'une seule couche qui représente à la fois l'entrée du réseau et sa sortie.

Les connaissances mémorisées étant distribuées dans le réseau et non localisées à une adresse, il est possible de récupérer l'entièreté d'une donnée, juste en présentant une version dégradée. Le modèle de Hopfield est un système dynamique, temporel il prend en considération le facteur du temps. Il faut

savoir que cette dernière affirmation est sujet à débat : le fait que Hopfield soit un réseau temporel ne fait pas le consensus et selon la définition que qu'est-ce qu'un réseau temporel, certains affirmeront que oui et d'autres que non.(Anon s. d.)

II.6.4 Réseaux de Neurone Convolutionnal (CNN)

Les réseaux de neurones convolutionnels ou CNN « Convolutionnel Neural Network » ont été introduits pour la première fois par Fukushima, ils peuvent de définir part une extension des MLP permettant de répondre efficacement aux principaux défauts des MLP. Ils sont principalement utilisé dans les problèmes de reconnaissance et de classification comme l'identification des images d'entrée, des vidéos ou encore dans le traitement naturel du langage. Ils sont invariants à de légères distorsions de l'image, et implémentent la notion de partage des poids permettant de réduire considérablement le nombre de paramètres du réseau. Ce partage des poids permet en outre de prendre en compte de manière forte les corrélations locales contenues dans une image. Les réseaux de neurones convolutionnels ont initialement été inspirés par la découverte faite par Hubel et Wiesel de neurones sensibles aux aspects locaux et sélectifs en orientation dans le système visuel du chat.(Mokri 2017)

Ils sont réputés pour leur robustesse aux faibles variations d'entrée, le faible taux de prétraitement nécessaires à leur fonctionnement, et ne requièrent aucun choix d'extracteur de caractéristiques spécifiques.

L'architecture proposée repose sur plusieurs réseaux de neurones profonds alternant entre couches de convolution et couches d'aggrégation (pooling). La figure 6 montre un CNN typique avec quatre couches, y compris une couche convolutionnelle (C_1 , C_3), une couche de pooling (P_2) et une couche de neurones complètement connectés (D_4).

Le début de l'architecture consistant en une succession de couches de convolution et d'aggrégation (pooling) est dédié à l'extraction automatique de caractéristiques, tandis que la seconde partie, composée de couches de neurones complètement connectés est dédiée à la classification.




Figure II-6: Structure d'un réseau de neurone Convolutionnel CNN

Comparé à d'autres architectures profondes, CNN a une capacité importante pour extraire des caractéristiques spatiales. Dans cette section, nous présentons brièvement la structure d'un CNN typique

➤ Couche de convolution

Les couches convolutives constituent le noyau du réseau convolutif. Ces couches se composent d'une grille rectangulaire de neurones qui ont un petit champ réceptif étendu à travers toute la profondeur du volume d'entrée. Ainsi, la couche convolutionnelle est juste une convolution d'image de la couche précédente, où les poids spécifient le filtre de convolution.

La couche Convolutionnel est utilisée comme extracteur d'entités locales. L'entrée est transformée en cartes d'entités avec des formes similaires par convolution et non-linéarité à une couche convolutive. La convolution est réalisée par plusieurs noyaux apprentissables (également appelés filtres), après le filtrage par convolution la couche convolutive renvoie les entités "feature maps", qui sont ensuite normalisées avec une fonction d'activation et/ou redimensionnées.

Ce procédé peut être réitéré plusieurs fois : on filtre les features maps obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles features maps à normaliser et redimensionner, et qu'on peut filtrer à nouveau, et ainsi de suite. Finalement, les valeurs des dernières feature maps sont concaténées dans un vecteur. Ce vecteur définit la sortie du premier bloc, et l'entrée du second.

Trois stratégies importantes sont adoptées par la couche convolutive pour améliorer les performances du réseau - champs réceptifs, connectivité clairsemée et partage de paramètres - qui peut remarquablement réduire le nombre de variables libres

➤ Couche d'aggrégation (pooling)

Après chaque couche convolutive, il peut y avoir une couche de pooling qui se place souvent entre deux couches convolutives. La couche de pooling sous-échantillonne leur entrée autrement dit cette couche produit des versions sous-échantillonnées des cartes d'entrée par opération de pooling en réduisant progressivement la taille spatiale des images, tout en préservant leurs caractéristiques importantes ce qui diminue le nombre de paramètres et de calculs dans le réseau.

Il y a plusieurs façons de faire cette mise en commun, comme prendre la moyenne ou le maximum, ou une combinaison linéaire apprise des neurones dans le bloc.

➤ Couche totalement connecté

Enfin, après plusieurs couches de convolution et pooling, le raisonnement de haut niveau dans le réseau neuronal se fait via des couches totalement connectées qui constitue toujours la dernière couche d'un réseau de neurones convolutif ou non. Les neurones de cette couche ont des connexions complètes à toutes les activations de la couche précédente. Cette couche de connexion a pour but de classer l'image d'entrée dans différentes classes.

La dernière couche du CNN renvoie un vecteur de taille N soit $z = (z_1 \dots z_N)$, où N est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe. Pour calculer la probabilité la couche multiplie chaque élément en entrée par un poids, fait la somme, puis applique une fonction d'activation Softmax qui se définit par : $\sigma(z) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$ pour $j \in \{1 \dots N\}$

En CNN, elle attribue des probabilités décimales à chaque classe d'un problème à plusieurs classes. La somme de ces probabilités décimales doit être égale à 1.

La figure 7 montre chemin de classification d'une image pris par le réseau de neurone MLP et CNN ; le réseau multicouche MLP est composé de couches entièrement connectées dont sa mission est l'extraction et la classification des données reçues en entrée. Pour le réseau de neurone convolutionnel CNN est composé des couches convolutionnelles dont sa mission principale est l'extraction des données ces couches sont suivies de couches complètement connectées qui ont pour but la classification des entités de la couche précédente.




Figure II-7: Classification d'image par CNN (Machine learning) et MLP (Deep Learning)

Conclusion

De nombreux problèmes peuvent s'exprimer comme de problèmes d'optimisation combinatoires qui ne peuvent pas être résolus d'une manière exacte et dans un temps raisonnable. L'intelligence artificielle offre la possibilité de trouver des résultats pertinents aux différents problèmes grâce à la capacité d'apprentissage automatique en utilisant le type réseau de neurone artificiel adéquat selon la complexité de problème à résoudre.

Cependant le perceptron multicouche est conçu à résoudre des problèmes d'optimisation en ajoutant plus de couches neuronales quand le problème est plus compliqué et les réseaux de neurone convolutionnel sont utilisés souvent dans la classification des images et reconnaissance de forme.

CHAPITRE 03 : Etude de cas classification de défauts des roulements à l'aide de CNN et ANN

III. Chapitre 03 : Etude de cas classification de défauts des roulements à l'aide de CNN et ANN

Introduction

La machine learning a prouvé son efficacité dans de nombreux problèmes complexes avec l'utilisation de réseaux de neurones artificiels pour apprendre et extraire des modèles et des informations significatives depuis les données afin de résoudre le problème dans un temps raisonnable.

Dans le cadre de mon projet qui consiste l'application des réseaux de neurones convolutifs pour la détection des défauts prédéfinis des roulements à l'aide des signaux sans aucune extraction des caractéristiques. L'acquisition des signaux se fait en mesurant les vibrations d'une ID-Fan au sein de la multinationale Cilas (Cimenterie Lafarge Souakri) à Biskra.

On représentera dans ce chapitre l'efficacité de CNN à localiser et identifier les défauts des roulements.

III.1 Présentation de l'entreprise CILAS

III.1.1 CILAS Biskra

Cilas Biskra est le fruit d'un partenariat d'exception, dans le cadre de la règle d'investissement 49/51, entre le Groupe International LaFargeHolcim, leader mondial des matériaux de construction et le Groupe industriel Souakri Frères. Ce fleuron industriel est un projet Greenfield d'un investissement de 33 milliards de dinars construit en 21 mois, avec une excellente performance en matière de santé et sécurité, emploiera à terme plus de 200 personnes et contribuera à réduire significativement les importations de ciment, Celle-ci bénéficie des technologies de fabrication les plus avancées avec un fort focus service client tout en minimisant au maximum son empreinte environnementale. Elle assure, selon ses dirigeants, des opérations de broyage, réalisées avec le plus gros broyeur vertical au monde. Les activités d'ensachage et de palettisation sont entièrement automatisées pour mieux servir la clientèle avec une efficacité énergétique de - 30% par rapport à la référence. Cilas s'engage également pour une réduction des émissions de poussière avec l'utilisation du plus grand filtre à manche au monde. Lafarge Algérie est le premier producteur de matériaux de construction à travers ses activités ciment, granulats, béton et plâtre.

III.1.2 Historique de LaFargeHolcim

Le 7 avril 2014, le groupe suisse Holcim et le groupe français Lafarge annoncent leur projet de fusion au taux d'une action Holcim pour une action Lafarge. Le 7 juillet 2014, les deux groupes annoncent une liste d'actifs proposés pour désinvestissement afin de permettre la fusion.

En mars 2015, sous la pression des actionnaires d'Holcim, le conseil d'administration d'Holcim envoie un courrier au groupe Lafarge faisant part de nouvelles exigences dans le cadre du projet de fusion entre les deux groupes. Le groupe suisse réclame un relèvement de la parité d'échange en sa faveur (0,875 action Holcim pour une action Lafarge) et un autre président que le français Bruno Lafont pour le nouvel ensemble. Un nouvel accord se met en place pour une nouvelle parité d'échange : 9 actions Holcim pour 10 actions Lafarge.

Cependant un mouvement anti-Lafarge semble se dessiner. Après les contestations concernant la parité, les actionnaires contestataires s'en prennent aux objectifs de cette fusion et considèrent les gains chiffrés présentés par les deux groupes comme irréalistes. Le deuxième actionnaire du groupe Holcim avec 10 % des actions, le russe Filaret Galtchev, a rejeté le nouveau compromis et trouve les avancées insuffisantes. Par ailleurs des actionnaires individuels se sont réunis et appellent, sur un site internet créé pour l'occasion (Holcimshareholders.ch), à voter contre le projet de fusion qui est présenté à l'assemblée générale du 8 mai 2015.

Le 10 juillet 2015, la fusion de Lafarge et d'Holcim est effective et comporte trois changements par rapport au projet de fusion entre égaux initial :


- Le changement de parité en faveur des actionnaires d'Holcim,
- Le renoncement du PDG français de Lafarge, Bruno Lafont, à un poste de direction générale au profit d'Éric Olsen, ancien de chez Lafarge.
- Le choix de la Suisse comme siège du nouveau groupe.
- Le nouvel ensemble est officiellement lancé le 15 juillet 2015 et prend le nom de LafargeHolcim.

Aujourd'hui, elle est leader mondial de la construction et acteur majeur dans les activités ciment, granulats et béton. Présente sur plus de 80 pays, Lafarge contribue à la construction des villes dans le monde entier avec des solutions innovantes pour les rendre plus accueillantes, plus compactes, plus durables, plus belles et mieux connectées.

III.2 Prétraitement de données

Avant d'être introduites dans le réseau, les données doivent être normalisées entre -1 et 1

$X_n = \frac{2 \times (x - x_{min})}{x_{max} - x_{min}} - 1$ Est utilisée pour générer les images d'entraînement et de test : pour chaque classe un total de 35 signaux de taille (1×4096) est utilisé : 20 pour l'entraînement et 15 pour le test.



Ensuite on utilise la fonction « reshape » pour générer les images (feature maps), la fonction « reshape » transforme nos vecteurs d'entraînement et de test en matrice carré de taille « m »


Exemple simplifié :

```
A = 1:10;
B = reshape(A, [5,2])
```

B = 5×2

1	6
2	7
3	8
4	9
5	10

La taille « m » est un paramètre essentiel qui joue un rôle très important dans la précision de notre programme. Et finalement, on les affiche en image de niveau de gris en utilisant la fonction « imshow » (chaque valeur dans la matrice correspond à un niveau de gris selon la norme uint8 (figure).



- **Résultat et discussion :**

Le CNN utilisé est composé de la couche d'input, 2 couches de convolution, une couche entièrement connectée et la couche de sortie. L'étude est menée en variant le couple (nombre de vecteurs d'apprentissages, nombre de vecteurs de test) et la taille des images.

- Pour (5,5) :

m	Précision	Nombre d'images (entraînement)	Nombre d'images (test)	Temps d'entraînement
6	84.51 %	2×568	2×568	43 sec
11	94.38 %	2×169	2×169	15 sec
16	99.38 %	2×80	2×80	14 sec
21	90.22 %	2×46	2×46	19 sec
26	90.00 %	2×30	2×30	18 sec
31	100 %	2×21	2×21	24 sec

- Pour (10,10) :


m	Précision	Nombre d'images (entraînement)	Nombre d'images (test)	Temps d'entraînement
6	86.63 %	2×1137	2×1137	35 sec
11	97.78 %	2×338	2×338	34 sec
16	94.38 %	2×160	2×160	27 sec
21	90.22 %	2×92	2×92	24 sec
26	90.83 %	2×60	2×60	35 sec
31	100 %	2×42	2×42	37 sec

- Pour (20,15) :

m	Précision	Nombre d'images (entraînement)	Nombre d'images (test)	Temps d'entraînement
6	93.55 %	2×2275	2×1706	1 min 4 sec (met validation criterion)
11	96.35 %	2×677	2×507	40 sec (met validation criterion)
16	96.25 %	2×320	2×240	50 sec (met validation criterion)

- Pour (25,10) :

m	Précision	Nombre d'images (entraînement)	Nombre d'images (test)	Temps d'entraînement
6	93.10 %	2×2844	2×1137	1 min 0 sec
11	96.75 %	2×846	2×338	1 min 22 sec
16	96.88 %	2×400	2×160	54 Sec
21	100 %	2×232	2×92	1 min 12 Sec
26	100 %	2×151	2×60	1 min 11 Sec
31	100 %	2×106	2×42	56 Sec



On observe qu'une précision de 100% est obtenue pour $m = 31$ dans les 2 premiers cas $\{(5,5), (10,10)\}$ pour un temps de calcul de 24 sec et 31 sec respectivement. Sauf que pour les 2 derniers cas $\{(20,15), (25,10)\}$, la précision maximale est obtenue pour $m = 21$ en prenant un temps de calcul de 48 sec et 1 min 12 sec respectivement. Il faut prendre en considération aussi le nombre d'images dans chaque cas : dans le premier cas le nombre d'images utilisé pour l'apprentissage/ test est $2 \times 21 / 2 \times 21$ respectivement, tant que pour le deuxième cas il est $2 \times 42 / 2 \times 42$. Dans le troisième et quatrième cas il est significativement plus grand : $2 \times 185 / 2 \times 139$ et $2 \times 232 / 2 \times 92$ respectivement.

On observe aussi que pour $m = 16$, on peut avoir un résultat important ($> 95\%$) dans un temps réduit (différence de + 8 sec dans tous les cas mentionnés précédemment). Le seul critère qui marque la différence c'est le nombre des échantillons d'apprentissage et de test, ce qui est négligeable dans le deuxième et troisième cas où on obtient une précision de 100% pour $m = 21$, mais il est important pour les 2 premiers cas où le résultat mentionné est obtenu pour $m = 31$.

Conclusion

Nous avons atteint une très grande précision en utilisant uniquement l'architecture prédéfinie de Matlab, et en utilisant un nombre moyen des vecteurs pour chaque classe et en présence des défauts combinés, ce qui est un avantage majeur par rapport à la méthode classique de détection des défauts. Ce programme peut être développé facilement pour localiser et identifier les défauts.

Il est important de mentionner que tous les résultats obtenus au-dessus peuvent être optimisés en utilisant un Laptop ou un PC plus puissant.

Conclusion générale

Les travaux de ce mémoire, se sont attaqués à la surveillance des conditions de fonctionnement des machines tournantes, tirant avantage des possibilités offertes par les techniques de l'intelligence artificielle, pour l'exploitation des avancées réalisées en matière de traitement du signal et la construction d'outils de diagnostic. En premier lieu, nous avons commencé par étudier le domaine des machines tournantes, ce qui nous a permis d'analyser un nombre important de défaillances pouvant altérer leurs fonctionnements. Concernant les techniques de surveillance de ces machines, plusieurs approches ont été parcourues et décrites dans le premier chapitre, où une attention particulière a été donnée aux techniques à base d'analyse vibratoire et de positions angulaires. Une analyse de l'état de l'art du diagnostic des machines tournantes, nous a permis de prendre conscience de l'énorme quantité d'information que nous pouvons en extraire, mettant au clair un énorme frein en vue de l'automatisation de leur surveillance.

L'étude expérimentale sur la classification de défauts des machines tournantes par les techniques d'intelligence artificielles y compris ; la techniques des réseaux de neurones artificielles de type perceptron et les réseaux de neurone convolutives. On associant ce dernies aux techniques de traitement du signal a approuvé l'efficacité des techniques l'intelligence artificielles en terme de la simplicité, l'obtention des résultats pertinentes et précises, et en terme de temps qui est très réduit ce qui conduit une diminution de temps d'arrêt et diminution des couts d'intervention.

Références bibliographiques

- Abdelkader, Medjdoubi. s. d. « L'ANALYSE DU SENTIMENT UTILISANT LE DEEP LEARNING ». 84.
- Anon. s. d. « Architecture des réseaux de neurones : Réseaux de neurones artificiels classiques (2/3) ! - Intelligence mécanique ». Consulté 7 septembre 2020 (<http://www.scilogs.fr/intelligence-mecanique/architecture-des-reseaux-de-neurones-reseaux-de-neurones-artificiels-classiques-2-3/>).
- Liu, Taikai. 2013. « Implémentation de méthodes d'intelligence artificielle pour le contrôle du procédé de projection thermique ». phdthesis, Université de Technologie de Belfort-Montbéliard.
- Mokri, Mohammed Zakaria. 2017. « Classification des images avec les réseaux de neurones convolutionnels. » PhD Thesis, 09-01-2018.
- Touzet, Claude. 1992. *les réseaux de neurones artificiels, introduction au connexionnisme*.
- Touzet, Claude. 1998. « Des réseaux de neurones artificiels à la robotique coopérative ». PhD Thesis.