

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة
الاعلام والاعلام والاعلام والاعلام



UNIVERSITE BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY

جامعة باجي مختار – عنابة

Faculté des Sciences de l'Ingénierie
Département : Génie Mécanique
Domaine : Sciences et Technologies
Filière : Génie Mécanique
Spécialité : Ingénierie de la
Maintenance

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème:

**Détection des défauts mécaniques de roulements
par deep learning**

Présenté par : *TOUAIBIA Omar*

Encadrant : *HAFS Toufik*

MC-A

U.B.M. Annaba

Jury de Soutenance :

KHELIF RABAI	Pr	U.B.M. Annaba	Président
HAFS TOUFIK	MC-A	U.B.M. Annaba	Encadrant
LAISSAOUI RACHID	MA-A	U.B.M. Annaba	Examineur
KALOUCHE ABD KADER	MC-B	U.B.M. Annaba	Examineur

Année Universitaire : 2022/2023



Remerciements

Tout d'abord, louanges à Dieu, qui m'a fournis de la patience au moment de besoin, de la force au moment de la faiblesse et de la volonté contre le désespoir, et aussi je le remercie car il m'a mis dans de bonnes mains.

Je tiens à exprimer mes sincères remerciements à mon encadreur Mr HAFS TOUFIK, enseignant (MCA) au département de électronique, Université Badji Mokhtar Annaba (UBMA) qui a bien voulu me soutenir, m'orienter, me guider et m'aider au cours de la préparation de ce travail.

Mes remerciements vont aussi à Monsieur KHELIF RABIA, Professeur de l'université UBMA, président de jury et à Mr LAISSAOUI RACHID, Professeur de l'université UBMA, membres de jury, et à Monsieur KALOUCHE ABDELKADER Professeur de l'université UBMA, membres de jury, pour avoir examiné ce travail de fin d'étude.

Je remercie tous les enseignants du département Génie mécanique ainsi que les responsables et le personnel administratif.

Je remercie beaucoup ma famille et surtout ma femme pour m'avoir motivé le long de ma préparation du mon travail.

Je remercie aussi tous mes collègues de département Génie Mécanique.





Dédicaces

Je dédie ce mémoire de master :

À ma tendre Mère et mon très cher Père que dieu

Lui fasse miséricorde.

À ma femme.

À mes frères et mes sœurs.

A mon binôme boughaba sofienne

À tous mes collègues de travail et surtout :

Ameur te taher.

À tous ceux qui me sens chers et que j'ai omis de citer.



Résumé:

Ce mémoire se concentre sur la détection des défauts de roulement à l'aide de réseaux de neurones récurrents à mémoire à court terme (LSTM). L'objectif principal est d'obtenir une précision élevée dans la détection précoce des défauts de roulement pour améliorer la maintenance prédictive et réduire les temps d'arrêt coûteux. La méthodologie comprend la collecte de données de vibrations de roulements sains et défectueux, le prétraitement des données, la construction et l'entraînement du modèle LSTM, et l'évaluation des performances. Les résultats ont montré une précision de 96,11 % dans la détection des défauts de roulement, démontrant ainsi l'efficacité de l'approche basée sur LSTM. Cette étude ouvre de nouvelles perspectives pour l'industrie en matière de maintenance prédictive et de gestion des actifs.

Mots-clés : détection des défauts de roulement, LSTM, maintenance prédictive, vibrations, précision, temps d'arrêt coûteux.

Abstract:

This thesis focuses on the detection of rolling bearing defects using Long Short-Term Memory (LSTM) recurrent neural networks. The main objective is to achieve high accuracy in the early detection of bearing faults to improve predictive maintenance and reduce costly downtime. The methodology includes collecting data from healthy and faulty bearing vibrations, preprocessing the data, constructing and training the LSTM model, and evaluating performance. The results showed a 96.11% accuracy in bearing fault detection, demonstrating the effectiveness of the LSTM-based approach. This study opens up new perspectives for the industry in terms of predictive maintenance and asset management.

Keywords: bearing fault detection, LSTM, predictive maintenance, vibrations, accuracy, costly downtime.

ملخص

يركز هذا البحث على اكتشاف أعطال الحمل باستخدام الشبكات العصبية التراكمية ذات الذاكرة القصيرة المدى (LSTM). الهدف الرئيسي هو تحقيق دقة عالية في الكشف المبكر عن أعطال الحمل لتحسين الصيانة التنبؤية وتقليل فترات التوقف المكلفة. تشمل منهجية البحث جمع البيانات من الهزازات الصحية والعاطلة عن العمل، ومعالجة البيانات، وبناء وتدريب نموذج LSTM، وتقييم الأداء. أظهرت النتائج دقة بنسبة 96.11% في اكتشاف أعطال الحمل، مما يدل على فعالية النهج القائم على LSTM. يفتح هذا البحث آفاقاً جديدة للصناعة في مجال الصيانة التنبؤية وإدارة الأصول في الصناعة.

الكلمات الرئيسية: اكتشاف أعطال تحمل الدوران، LSTM، دقة عالية، صيانة التنبؤية، الشبكات العصبية المتكررة.

SOMMAIRE

CHPITRE 1 : GENRALITES SUR LA MAINTENANCE ET LES DEFAUT MECANIQUE SUR LESROULEMENTS

1- Introduction générale.....	10
2-La maintenance	11
Introduction.....	11
Définition et objectif de la maintenance.....	11
3- Les types de maintenance.....	12
La maintenance corrective	12
La maintenance préventive.....	13
4- Introduction sur les roulement.....	14
5- Défaits des machines tournantes	14
Balourd	15
Le désalignement	15
Défaits des engrenages	16
6 -Les roulements et leurs avaries	17
Géométrie et constitution d'un roulement.....	17
Différents types des roulements	19
Les facteurs essentiels pour le choix de type de roulement.....	20
6-4-Défaits des roulements	20

CHAPITRE 2 ; les techniques d'IA et l'apprentissage profond

1. Introduction	25
2. C'est quoi l'Intelligence Artificielle (IA)	26
3. L'évolution des réseaux de neurones	27
4. Les réseaux de neurones.....	28
Le neurone biologique	29
Neurone formel.....	30
Réseau de Neurones Artificiels	31
5. L'apprentissage automatique.....	32
L'apprentissage supervisé (Supervised Learning).....	34
L'apprentissage non supervisé (Unsupervised Learning)	35
L'apprentissage par renforcement (Reinforcement Learning)	36
6. Historique d'apprentissage profond	37
7. Domaines d'application de l'apprentissage profond.....	38
8. Les réseaux de neurones convolutifs.....	39
La phase d'extraction des caractéristiques	40
La phase de classification de modèle	41
9. Architecture et fonctionnement du CNN	42
Les différentes couches de CNN	43
La couche convolutive (CONV)	44
Les hyper-paramètres de la couche convolutive	45
9.1.3. La couche entièrement connectée	46
Ajustement des hyperparamètres.....	47

10.	Apprentissage profond et imagerie médicale	48
11.	L'interprétation des images médicales	49
	La Classification.....	50
	Les architectures de classification les plus connues	54
	Exemples des travaux de classification profonde	56
	La Détection et localisation des objets	57
	Les architectures de détection les plus connues.....	58
	Exemples des travaux de détection	60
	La Segmentation.....	62
	Les architectures de segmentation les plus connues	66
12.	Conclusion	72

LISTE DES FIGURES

Figure

Intitulé

Figure I.1: vue d'ensemble des différents types de maintenance

Figure I.2 : défauts désalignement

Figure I-3 : piquûres

Figure1-4 : différentes composantes d'un roulement

Figure1-.5 : une variété de roulements

Figure1-6 : grippage d'une bague

Figure 1-.7 : corrosion sur une piste de roulement

Figure 1-.8 : écaillage par (a) fatigue et (b) superficiel de la bague interne

Figure II.1 :Schéma simplifié d'un neurone biologique

Figure .2.2 : Comparaison entre neurone biologique et neurone formel

Figure 2.3 : architecture globale

Figure 2.4 :La couche de convolution

Figure 2.5 : Profondeur d'un filtre

Figure 2.6 : Le stride d'un filtre

Figure 2.7 : Représentation de la fonction Relu

Figure 2.8 : Représentation de la fonction tangente hyperbolique

Figure 2.9 : Représentation de la fonction sigmoïde

Figure 2.10 :La fonction d'activation Identité

Figure 2.11 : La couche entièrement connectée

Figure 2.12 : Les trois tâches essentielles de l'interprétation d'images

Figure 2.13 : L'architecture du réseau Le Net

Figure 2.14: L'architecture du réseau Alex Net

Figure 2.15 : l'architecture du réseau ZFNET

Figure 2.16 : l'architecture du réseau VGGNet

Figure 2.17 : La structure d'un module d'Inception

Figure 2.18: L'architecture du réseau Inception

Figure 2.19 : La structure des blocs résiduels

Figure 2.20 : L'architecture du réseau RES Net (34 couches)

Figure 2.21: L'architecture du réseau Dense Net

Figure 2.22 : L'architecture de Régions avec réseaux de neurones convolutif (R-CNN)

Figure 2.23 : L'architecture du réseau Fast R-CNN

Figure 2.24 : L'architecture de détection des objets par YOLO

Figure 2.25: L'architecture du réseau fully convolutional network

Figure 2.26 : L'architecture du réseau U-Net

Figure 2.27 : L'architecture du réseau Seg-Net

Figure 3-1 : processus d'apprentissage

Figure 3-2 : Plateforme expérimentale pour l'acquisition de signaux de vibration à partir de roulements à billes.

Figure 4-1 : interface d'apprentissage et de décision

Figure 4-1 : interface d'apprentissage et de décision

LISTE DES Tableaux :

Tableau II.1 : Les domaines d'application

Tableau 2.2: Présentation des types de pooling

Tableau 2.3 : Exemples des travaux de classification profonde

Tableau 2.4 : Exemples des travaux de détection profonde

Tableau 3-1 : Ensemble de données sur les défauts de roulements

Tableau 4-1 : Paramètres du système

Introduction générale :

Les roulements jouent un rôle crucial dans le bon fonctionnement des machines et des systèmes mécaniques. Cependant, en raison de diverses conditions de fonctionnement et de facteurs environnementaux, les roulements sont sujets à des défauts qui peuvent compromettre leur performance et entraîner des défaillances prématurées. La détection précoce et précise de ces défauts est essentielle pour prévenir les pannes coûteuses, minimiser les temps d'arrêt et assurer la sécurité des opérations.

Au fil des années, des progrès significatifs ont été réalisés dans le domaine de la détection des défauts mécaniques des roulements. Les méthodes traditionnelles, telles que l'analyse des vibrations, ont été largement utilisées pour identifier les signes de détérioration des roulements. Cependant, ces approches présentent souvent des limites en termes de sensibilité, de spécificité et de capacité à traiter de grandes quantités de données.

Avec l'avènement des techniques d'apprentissage automatique et de l'intelligence artificielle, de nouvelles perspectives ont émergé dans le domaine de la détection des défauts mécaniques. Les modèles basés sur des réseaux de neurones, tels que les réseaux LSTM (Long Short-Term Memory), ont montré des performances prometteuses en exploitant les capacités de traitement séquentiel et la capacité à apprendre à partir de grandes quantités de données.

Dans cette étude, nous nous intéressons particulièrement à l'utilisation des modèles LSTM pour la détection des défauts mécaniques des roulements. Nous explorons leur potentiel en termes de précision, de robustesse et de capacité à détecter une variété de défauts couramment rencontrés. Nous présentons également des cas d'étude et des résultats expérimentaux pour évaluer l'efficacité de notre approche et pour comparer nos résultats avec d'autres méthodes existantes.

L'objectif de cette recherche est de contribuer à l'amélioration des techniques de maintenance prédictive et à la réduction des coûts associés aux pannes de roulements. En fournissant des méthodes plus avancées et précises de détection des défauts mécaniques, nous visons à soutenir les efforts

visant à accroître la fiabilité et la durée de vie des systèmes mécaniques dans divers secteurs industriels.

En résumé, cette étude se concentre sur l'utilisation des modèles LSTM pour la détection des défauts mécaniques des roulements, avec l'objectif de fournir des outils et des techniques plus avancés pour améliorer la maintenance prédictive et réduire les risques de défaillance prématurée des roulements.

CHAPITRE I

Généralité sur la maintenance et les défauts des roulements

I. La maintenance:

I-1 Introduction:

Maintenance en fonction de soutien dans les systèmes de production a été évaluée comme un rôle critique et même une condition préalable [1]. Ceci, bien sûr, implique également que la maintenance doit être effectuée de manière efficace, en d'autres termes, l'action de maintenance correcte doit être prise au bon moment. Un entretien inadéquat, d'autre part, peut entraîner une augmentation des coûts pour les raisons suivantes [2]:

- La perte de production.
- Ré usinage.
- Ferraille.
- La main d'œuvre.
- Pièces de rechange
- Amendes pour les commandes en retard.
- Les commandes perdues en raison de clients insatisfaits.

I-2 Définition et objectif de la maintenance :

L'objectif principal de la maintenance devrait être d'assurer le fonctionnement du système d'équipements de production. En outre, l'entretien devrait fournir les bons paramètres: Coût, fiabilité, maintenabilité et la productivité, pour tout système de fabrication automatisé. Coetzee (2004) partage cette opinion sur l'objectif de l'entretien, indiquant que : « Il est la tâche de la fonction de maintenance pour soutenir le processus de production avec des niveaux adéquats de disponibilité, de fiabilité et de fonctionnement à un coût acceptable ». Diverses approches pour effectuer l'entretien existent. En outre, diverses définitions de l'entretien ont été proposées au fil des années, le point commun étant qu'ils se sont éloignés de la perception traditionnelle de l'entretien pour réparer les objets cassés. L'entretien selon l'ISO est défini comme : « La combinaison de toutes les actions techniques, administratives et organisationnelles au cours du cycle de vie d'un actif, lui permettant de conserver ou de récupérer un état de fonctionnement spécifié » [2].

I-3- Les type de maintenance :

En se concentrant sur « ... la conserver, ou restaurer à ... » dans la définition de l'entretien, il devient évident que l'on peut effectuer l'entretien en deux types principaux : la maintenance corrective et la maintenance préventive (voir **Figure I.1**). Les deux types d'entretien traditionnels sont largement utilisés dans pratiquement tous les secteurs industriels [1].

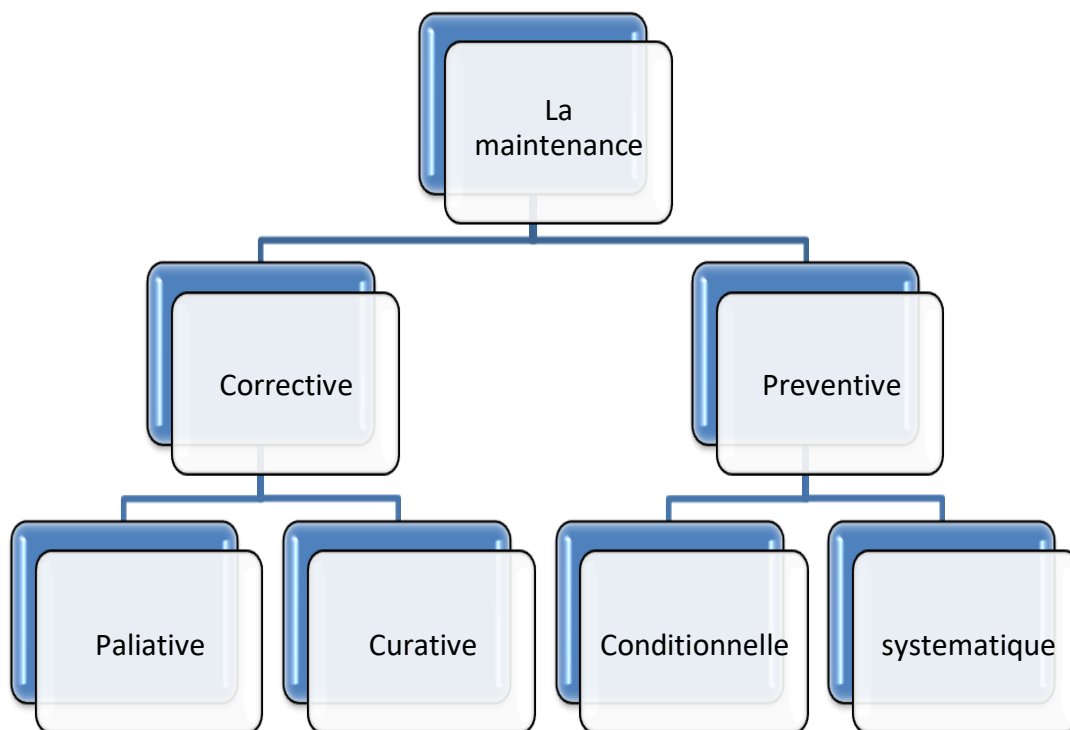


Figure I.1: vue d'ensemble des différents types de maintenance

I-3- a La maintenance corrective :

Semblable à des travaux de réparation, est entreprise après une panne ou lorsque la défaillance évidente a été localisée. Selon la norme (SS-EN 13306), la maintenance corrective est définie comme suit : « Entretien effectué après la reconnaissance de la faute et destiné à mettre un élément dans un état dans lequel il peut accomplir une fonction requise. ». Pour les travaux de réparation, certaines approches de modélisation sont disponibles. Avec la réparation minimale, l'élément défaillant n'est restauré à son état de fonctionnement et l'élément continue comme si rien est arrivé. La probabilité d'une défaillance (le taux d'échec) reste le même qu'il était juste avant l'échec. En utilisant l'approche de réparation minimale signifie que l'élément n'est rendu à un « aussi mauvais que vieux » condition [3].

La réparation minimale peut être exécutée pour diverses raisons, comme le manque de temps, les pièces de rechange, la compétence, etc. Si l'article est à la place remplacée par un nouveau composant du même type, ou si elle est restaurée à un état « aussi bon que neuf », le taux d'échec diminue au niveau du moment où l'élément vient d'être mis en service. On appelle cela un processus de renouvellement ou parfois une réparation maximale. Ces types de réparations sont les extrêmes de travail de réparation [3]. En conséquence, la plupart des actions de réparation sont situées quelque part entre les deux, et sont souvent appelés réparation imparfaite [4].

En cas de panne sur les fonctions critiques, la maintenance corrective doit être effectuée immédiatement. Cependant, pour les échecs qui ont pas ou peu de conséquences sur le fonctionnement du système complet, la maintenance peut être différée dans le temps à une occasion mieux adaptée. Cependant, signifie que la maintenance corrective à son meilleur ne doit être utilisé que sur les zones non critiques où les coûts d'investissement sont faibles, les conséquences de l'échec sont faibles, aucun risque de sécurité sont immédiats, et l'identification de l'échec rapide et réparation d'une défaillance rapide sont possibles, signifie également que les entreprises par défaut adoptent souvent la maintenance corrective inappropriée, ce qui à long terme peut devenir coûteux. La maintenance corrective est parfois appelée : l'entretien routier [1], l'entretien entraîné l'échec, l'entretien à base d'échec, et la gestion à l'échec d'entretien [1] [2].

I-3-b-La maintenance préventive :

Selon la norme (SS-FR 13306), la maintenance préventive a été définie comme : « Maintenance effectuée à des intervalles prédéterminés ou en fonction de critères prescrits et destiné à réduire la probabilité de défaillance ou de la dégradation du fonctionnement d'un élément. ». La maintenance préventive est divisée en deux types, maintenance systématique et maintenance conditionnelle. Maintenance systématique est planifiée et organisé sans l'apparition de toutes les activités de surveillance. La programmation peut être basée sur le nombre d'heures d'utilisation, le nombre de fois qu'un élément a été utilisé ; le nombre de kilomètres les articles a été utilisés, selon les dates prescrites, et ainsi de suite.

L'entretien est mieux adapté systématique à un élément qui a un âge visible ou USURE caractéristique et où les tâches de maintenance peuvent être effectuées à un moment qui est sûr empêchera un échec de se produire [1].

L'autre type d'entretien préventif, maintenance conditionnelle, n'utilise pas des intervalles prédéterminés et des calendriers. Il surveille plutôt l'état des articles afin de décider

d'un calendrier dynamique de prévention.

I-4-Introduction sur les roulement :

Les roulements sont plus récents par rapport aux paliers lisses, l'apparition des roulements a été conditionnée par le remplacement du frottement de glissement par celui de roulement. Ils sont largement utilisés dans le domaine de la construction mécanique, en particulier dans le domaine des machines tournantes. L'utilisation aussi de ce produit dans le domaine de l'automobile a donné l'occasion de perfectionnement de la méthode de fabrication, ainsi que l'amélioration de sa qualité.

On appelle roulement, une pièce mécanique composé de plusieurs éléments entre deux organes, un mobile et l'autre immobile, le roulement est destiné à remplacer un glissement par roulement afin de réduire le frottement, il est défini deux critères qui sont : le type et les dimensions.

le roulement est un organe mécanique, sa fonction est de permettre la transmission des charges (efforts) entre deux pièces en rotation relative l'une par rapport à l'autre avec un frottement très réduit. Il supporte et assure le guidage d'une charge tournante.

Dans ce chapitre, on va détailler les différents défauts des machines tournantes. En plus, on va présenter la géométrie et la constitution du roulement, les critères du choix des roulements, les défauts principaux qui peuvent affecter un roulement et finalement les fréquences caractéristiques des défauts.

I-5-Défauts des machines tournantes :

Il n'y a pas de bon diagnostic sans une bonne connaissance des défauts. C'est pourquoi, la première démarche d'une action de surveillance est de rechercher quels sont les incidents les plus fréquents sur les machines et comment ils se manifestent (qu'elle est leur signature). Comme son nom l'indique, l'analyse vibratoire utilise les vibrations émises par une machine. Ces vibrations permettent de détecter :

- L'importance du balourd.
- L'importance du désalignement.
- Les défauts de roulement.
- Les défauts d'engrenages.

I-5-a-Balourd :

Le balourd est la cause de vibrations la plus commun et la plus fréquemment rencontrée. Le balourd est un déséquilibre massique autour de l'axe de rotation qui provient généralement du défaut d'usinage, d'assemblage et de l'échauffement dissymétrique du rotor lors du fonctionnement, il est connu de certains automobilistes qui demandent un équilibrage après le changement des pneumatiques pour s'affranchir de l'éventuelle gêne qu'il occasionnerait.

On ne peut réaliser la concentricité parfaite d'un rotor. De cet état imparfait de la concentricité, en rotation, il en résulte des forces centrifuges f qui déforment le rotor et engendrent des déséquilibres. Par l'expression suivante en détermine la force centrifuge

[5] :

$$F = mr\omega^2 \text{ (II. 1)}$$

Où m représente la masse qui balourd, r le rayon du rotor et ω la vitesse de rotation de l'arbre.

I-5-b-Le désalignement :

Le défaut d'alignement est l'une des principales causes de réduction de la durée de vie des équipements, il concerne soit deux arbres liés par un accouplement, soit deux paliers soutenant le même axe. L'arbre moteur et l'arbre récepteur d'une machine ne sont pas parfaitement alignés.

L'objectif du lignage de deux machines est de faire en sorte que les axes des deux lignes d'arbres soient parallèles et confondus. Deux types de défauts de lignage sont donc rencontrés :

a) Désalignement angulaire : il se produit quand l'axe de rotation de deux machines a un angle différent. Le désalignement angulaire se caractérise par une vibration axiale élevée.

b) Désalignement axial : il se produit quand les axes de rotation des deux machines ont le même angle d'orientation. Mais ils sont séparés verticalement, chacun de l'autre. Le désalignement axial (parallèle) se caractérise par une vibration radiale élevée.




Figure 1.2 : défauts désalignement [6].

I-5-c- Défauts des engrenages :

Nous pouvons utiliser les engrenages pour transmettre le mouvement et la puissance mécanique entre deux arbres parallèles ou non parallèles, concourants ou non concourants et

Perpendiculaires ou non perpendiculaires [6]. Ces défauts sont liés aux dégradations de la denture (denture cassée ou abîmée, usure uniforme ou non, les piqûres (pitting) localisé ou réparti, mauvais centrage). On peut observer aussi la corrosion de contact (fretting) qui se traduit par un enlèvement de métal lorsque l'engrenage est lubrifié et que les efforts sont importants.



Figure 1-3: piqûres [6].

I-6- Les roulements et leurs avaries :

Des roulements, il y en a partout... des pédales de vélos, les compresseurs ou les roues de véhicules...etc. Un très grand nombre de systèmes en rotation en sont équipés. Et dans l'industrie, ce sont des composants stratégiques des machines tournantes : situés entre les parties fixes et les parties mobiles de la structure, ils assurent la transmission des efforts et la rotation de l'arbre.

Pour éviter des arrêts de production imprévus et coûteux, il faut alors surveiller en permanence l'état des roulements, et "traquer" tous les signes précurseurs des défauts: un bruit inhabituel, des vibrations anormales, une élévation de température,...etc [7].

I-6-1-Géométrie et constitution d'un roulement :

La performance des roulements est directement liée à la qualité du matériau utilisé en particulier sa propreté (qualité). En effet les concentrations de contraintes liées à la géométrie du contact sont considérablement amplifiées par la présence de défauts de type inclusions nonMétalliques dans la zone mécaniquement sollicitée (zone de charge).

Le roulement sans glissement des éléments roulants sur les chemins (pistes) assure la transmission de la charge (l'énergie) d'une bague à une autre. Afin d'assurer un roulement parfait [6], il faut que les éléments roulants soient complètement séparés par une cage.

De manière générale, les roulements sont constitués de quatre composants essentiels

1. La bague extérieure.
2. La bague intérieure.
3. La cage.
4. Les éléments roulants.




Figure1-.4: différentes composantes d'un roulement [6].

a-La bague extérieure :

C'est l'élément qui limite les dimensions extérieures du roulement. Elle sera montée dans un logement fixe (bague extérieure fixe) ou dans un moyeu tournant (Bague extérieure tournante).

b-La bague intérieure :

Elle est montée sur un arbre fixe ou mobile. C'est-à-dire, elle est fixe si la bague extérieure est mobile, et le contraire.

c-La cage :

Elle a pour rôle de maintenir le même écartement entre les éléments roulants, à fin de préserver la même zone de charge du roulement, elle ne supporte aucune charge.

d-Les éléments roulants :

Ils s'agissent des billes, rouleaux et des aiguilles. Ce sont les éléments des roulements qui assurent la transmission de la charge entre les deux bagues du roulement, ils sont responsables de la rotation relative d'une bague par rapport à l'autre.

I-6--2Différents types des roulements :

Quel que soit la taille, la qualité et la matière utilisée pour la fabrication du roulement, les roulements sont classés de plusieurs manières .En premier lieu, ils sont classés d'après la forme des éléments roulant utilisés (roulements à billes ou à rouleaux), et ce d'après l'importance de la charge appliquée au roulement (si la charge est importante, il faut choisir le roulement à rouleaux, ce type de roulement est très proche de celui à billes, la cage contenant des rouleaux au lieu de billes. Selon la forme des rouleaux il peut être possible de séparer les bagues. Le problème d'assemblage du roulement n'est alors plus le même.

Le roulement à rouleaux supporte un effort radial supérieur par rapport au roulement à billes, car le contact des éléments roulants avec les bagues est linéaire.

On utilise le roulement à rouleaux pour augmenter la surface de contact afin de minimiser les contraintes ou les pressions sur les pistes. En deuxième lieu, ils sont classés d'après la direction d'application de ces charges, à cet effet, il existe les roulements radiaux s'il s'agit d'une charge radiale et des roulements axiaux (butées) dans le cas d'une charge axiale importante.

➤ Les roulements rigides à billes (à rouleaux cylindriques) : ce sont les roulements les plus répandus, ils sont conçus pour des charges radiales, mais peuvent supporter une petite

charge axiale. Les roulements à rouleaux peuvent supporter des charges plus élevées.

Les roulements à aiguilles : ils possèdent une forme cylindrique, et sont suffisamment fin pour résoudre le problème où l'espace radial est fin.

➤ Les roulements à aiguilles : ils possèdent une forme cylindrique, et sont suffisamment fin pour résoudre le problème où l'espace radial est fin.

➤ Roulements à billes à contact oblique : l'architecture de ces roulements les rend capable de supporter des charges axiales et radiales à la fois.

➤ Roulements à rotules sur billes (de même sur rouleaux) : Ce type de roulement est célèbre, inventé en 1907 par le fondateur de SKF Sven Wingquist, a permis de résoudre l'un des problèmes industriels les plus épineux de l'époque, celui des arrêts de production récurrents dus à des défaillances de roulements. Comme l'alignement des arbres n'était pas suffisamment précis pour permettre une utilisation normale des roulements rigides à billes, les pannes étaient fréquentes. Les roulements à rotule sur billes à deux rangées, qui tolèrent un défaut d'alignement pour une durée de service identique, ont permis de résoudre le problème [8].



Figure1-.5: une variété de roulements [6].

I-6-3 Les facteurs essentiels pour le choix de type de roulement :

Le choix du type et de la taille d'un roulement est basé sur les conditions de fonctionnement et les caractéristiques de construction à fin d'assurer un bon fonctionnement à des coûts réduits [6]. Les facteurs qu'il faut tenir en considération pour réaliser un choix optimal de roulement sont les suivants :

- Savoir la nature, la direction ainsi que l'intensité de la charge que doit supporter le roulement.
- La vitesse de rotation du roulement.
- La durée de vie souhaitée (demandée).
- La température à laquelle le roulement va travailler.
- La précision de fonctionnement à fin de permettre fixé le jeu interne de chaque roulement.
- Il faut tenir en compte le mode de la lubrification, ainsi que le type du lubrifiant.
- La nature de la machine pour faire le choix du type de montage du roulement.
- La matière de l'arbre et du logement qui permette de calculer le jeu résiduel (fonctionnel) du roulement.
- La nature de la machine pour faire le choix du type de montage du roulement.
- La matière de l'arbre et du logement qui permette de calculer le jeu résiduel (fonctionnel) du roulement.
- L'encombrement (l'espace) réservé au roulement.

I-6--4-Défauts des roulements :

a-Causes principales des défauts :

Les roulements peuvent être endommagés par des causes externes comme:

- Contamination du roulement par des particules extérieures :
poussière, grains de sable...
- Corrosion engendrée par la pénétration d'eau, d'acides...
- Lubrification inadéquate qui peut causer un échauffement et l'usure du roulement.
- Mauvais alignement du rotor.
- Courant qui traverse le roulement et qui cause des arcs électriques [9].

b-Origine des défauts de roulement :

✓ **Mauvaise lubrification:**

Le mauvais choix d'un lubrifiant ou des quantités inadaptées de lubrifiant causent environ 36% des avaries de roulements. Une mauvaise lubrification réduite d'une manière significative la durée de vie d'un roulement et comme, bien souvent, un roulement est un composant mécanique difficile d'accès, cela engendre des arrêts de maintenance longs et donc coûteux.

✓ **Pollution:**

Un roulement est un composant mécanique de précision. Son bon fonctionnement risque d'être gravement compromis par la contamination des chemins de roulement et/ou du lubrifiant par des corps étrangers. On estime ainsi que 14% des défaillances de roulements sont dues à ce phénomène.

✓ **Mauvais montage :**

Environ 16% des avaries de roulements sont dues à un mauvais montage ou à l'utilisation d'outils inadaptés.

✓ **Fatigue:**

Les machines ne fonctionnent pas toujours dans des conditions optimales, loin s'en faut. Surcharges, entretiens insuffisants ou inadaptés sont responsables d'environ 34% des défaillances de roulements. Un roulement qui fonctionne dans des conditions de surcharge.

c-Principaux défauts :

Les roulements sont parmi les composants les plus critiques des machines et représentent une source de panne fréquente. On peut noter deux types de défauts caractéristiques de la détérioration des roulements : les défauts dits naturels dus à la fatigue des roulements et des défauts dus à un mauvais montage ou une mauvaise utilisation du roulement.

En associant les différentes techniques de contrôle, l'expérience du personnel de la maintenance ainsi que l'historique des machines. Nous pouvons identifier les types de détérioration des roulements de la manière suivante :

d-Le grippage :

Le grippage est un mode d'endommagement instantané. Les matériaux en contact se soudent sous pression et température généralement dans des conditions de vitesses moyennes et élevées. Il résulte d'un manque de lubrifiant ; les contacts métal-métal entraînent des

échauffements qui facilitent les microsoudures et le transfert de métal.

Donc, on peut dire que le grippage est un phénomène caractérisé par des micro - arrachements des particules métalliques.




Figure1-6: grippage d'une bague [10].

e- La corrosion :

La corrosion chimique se produit par la présence de l'humidité aux points de contact des éléments roulants avec les chemins. Surtout quand les roulements viennent d'être nettoyés et sont contaminés par la transpiration des mains.

La corrosion de contact (fretting) apporte une pâte brune formée par la rouille et le lubrifiant. Une corrosion profonde entraîne la rupture des bagues. due au mauvais choix d'ajustements entre les bagues et les arbres.



Figure 1-7: corrosion sur une piste de roulement [10].

f-Usure :

Usure par déformation : C'est une déformation plastique des chemins des roulements, causée par des chocs importants ou une vibration à haute fréquence. C'est une usure sans perte de matière (présence des empreintes) [11].

Usure par abrasion : L'usure par abrasion donne aux roulements une couche brillante, due au glissement des éléments roulants sur les pistes, et ce par le manque ou une mauvaise

lubrification.

1-La fissuration des bagues :

C'est l'apparition de fissures et de petites cassures sur les éléments du roulement. Les coups lors du montage, le non-respect des portées de roulement (ajustement trop serré). Sont responsables sur ce type de détérioration, elle provoquées par une déformation plastique.

2-L'écaillage :

Le cas le plus rencontré est un défaut d'écaillage dû à la fatigue des roulements. Ce défaut survient sous l'effet de la fatigue due aux contraintes de cisaillement alternées qui sévissent en sous- couche. Le fonctionnement élasto hydrodynamique (type de lubrification dépendant l'élasticité du matériau) crée, par dépassement de la limite d'élasticité, des microdéformations permanentes et des fissures qui se propagent vers la surface et conduisent [11].




Figure 1-8: écaillage par (a) fatigue et (b) superficiel de la bague interne [11].

CHPIRE II

Concepts de base sur leDEEP LEARNING

I-Introduction

L'Intelligence Artificielle IA consiste à mettre en œuvre des systèmes informatiques pouvant imiter l'intelligence humaine et même de prendre des décisions.

Le terme Apprentissage automatique ou Machine Learning (ML) date du milieu du 20^{ème} siècle. En 1950, le mathématicien britannique *Alan Turing* a proposé la première machine capable d'apprendre et de simuler l'intelligence réelle. Depuis, plus d'un demi-siècle, les techniques d'IA sont devenues pluridisciplinaires et reconnues un développement considérablement dans le but de créer des algorithmes capables d'apprendre et de s'améliorer de manière autonome. Ce qui fait l'appariation de l'apprentissage profond **qui est un algorithme de haut niveau d'abstraction qui permet de modéliser des grands ensembles de données.**

Récemment, les ordinateurs modernes ont fait de grands progrès sur le plan matériel et logiciel, en plus un développement élevé des technologies en terme d'acquisition d'images (microscopes, caméras, capteurs) et de stockage engendrent des bases de données riches en information, qui facilite la recherche et augmentes les taux de réussite des systèmes tout en diminuant l'intervention humaine.

Les réseaux d'apprentissage profond (Deep Learning) dérive de l'apprentissage automatique qui été largement utilisé dans différents domaines quelque soit leur degrés de complexité grâce à son avantage d'extraction automatique des caractéristiques la chose pour laquelle il a prouvé son efficacité par rapport aux méthodes d'apprentissage classique.

L'objectif principal de notre thèse est l'analyse de comportement de Deep Learning pour améliorer l'interprétation des images rétiniennes en utilisant deux approches différentes basées CNN ; une approche globale et une approche locale qui seront respectivement détaillées dans les chapitres 3 et 4, raison pour laquelle ce chapitre est consacré à l'illustration des principaux concepts de l'apprentissage profond en commençant par le classifieur noyaux qui est le réseau de neurones, passant par l'apprentissage profond et ses domaines d'application, ensuite nous allons présenter et détailler les réseaux de neurones convolutifs et leurs architectures dont nous allons concentrer sur la manière d'ajustement des hyper paramètres. Nous citons aussi les fonctions d'activation.

Dans la dernière partie, Nous allons clarifier le domaine d'interprétation des images qui englobe trois tâches essentielles (Classification, détection, segmentation) où nous avons analysé quelques architectures connues en classification, en détection des objets et en

segmentation dont nous allons mis en revue les travaux récents des chercheurs qui sont présents dans différentes architectures dans ce domaine.

I. Concept d'Intelligence Artificielle (IA)

Le terme **Intelligence Artificielle** (IA, ou AI en anglais pour Artificial Intelligence) est créé par le mathématicien **John McCarthy** en 1956 . Dans le but d'élaborer des algorithmes capables de prendre en charge les tâches habituellement de l'être humain basant sur l'apprentissage.

Selon le dictionnaire français, l'intelligence artificielle est un ensemble de théories et de techniques mises en œuvre en vue de réaliser un système informatique qui simule l'intelligence humaine. Autrement dit, l'IA est un domaine très vaste qui s'intéresse à la construction des machines intelligentes capables d'effectuer des tâches qui nécessitent généralement une intelligence humaine. Un système est qualifié intelligent, s'il est capable d'apprendre et d'exécuter une tâche liée au processus auquel il a été affecté sans aucune intervention humaine et avec une grande précision. L'intelligence artificielle a été utilisée dans une variété de domaines tels que : Finance et banques, Militaire, Médecine, Renseignement policier, Droit, Logistique, Transports, Industrie et Robotique.

II. L'évolution des réseaux de neurones :

Depuis leur apparition, les réseaux de neurones ont connu une évolution remarquable jusqu'à ce jour. Les fondateurs des réseaux de neurones sont les neurologues **Warren McCulloch** et **Walter Pitts** après leurs travaux publiés dans le célèbre article : " What the frog's eye tells to the frog's brain". Où ils ont présenté un modèle mathématique simplifié de neurone biologique souvent appelé neurone formel.

En 1949, **Donald Hebb** a introduit une règle qui permet de modifier les valeurs des coefficients synaptiques en fonction des unités qui les relient. Cette règle est très utilisée dans le modèle actuel elle est même appelée « règle de Hebb ».

Ainsi, Le premier système artificiel de perceptron qui a la possibilité d'apprendre fut introduit en 1957 par **Franck Rosenblatt**.

L'année 1982, marque l'apparition du premier modèle de réseau complètement récurrent qui a été réalisé par le physicien **John Joseph Hopfield**, permettant de résoudre la limitation des réseaux de neurone envers les problèmes non-linéaires.

En 1986, pour le traitement des événements non-linéaires une approche de perceptron multicouches a été introduite par **Rumelhart**. Par la suite **Werbos** , **Yann le Cun**, **Marvin**

Minsky ont proposé des systèmes semblables au perceptron de Rumelhart et qui sont tous basés sur la rétropropagation du gradient [13].

III. Les réseaux de neurones

1. Le neurone biologique

Le neurone est un type particulier de cellule du corps humain. La combinaison de ces neurones avec les cellules gliales constitue le tissu nerveux. Les neurones représentent l'unité fonctionnelle du système nerveux, il y a environ neuf fois plus de cellules gliales que de neurones dans le cerveau, son rôle est de faciliter la connexion des neurones et assurer leur alimentation avec un grand soutien. Les neurones sont les éléments de base du système nerveux central (cerveau) [13], le cerveau humain comprend environ 100 milliards de neurones, où ses derniers assurent la transmission d'un signal (influx nerveux). Elles sont composées de trois parties (Figure 2.1), le corps cellulaire, les synapses et l'axone :

- Corps (Somme) : Elle contient le noyau du neurone, c'est là où se déroulent toutes les activités nécessaires à la survie de la cellule.
- Axone: son rôle principal est d'assurer la communication avec les autres neurones.
- Synapse : C'est une jonction entre les terminaisons axonales et les autres cellules. L'impulsion nerveuse est une manifestation de la communication intercellulaire.




Figure 2.1 : Schéma simplifié d'un neurone biologique [13].

2. Neurone formel :

Un neurone formel est un modèle mathématique non linéaire, paramétré, à des valeurs bornées. Il est inspiré de son équivalent biologique et composé des signaux d'entrées (représentant les dendrites) et d'un signal de sortie (représentant l'axone) ainsi d'une fonction d'activation (représentant le soma).

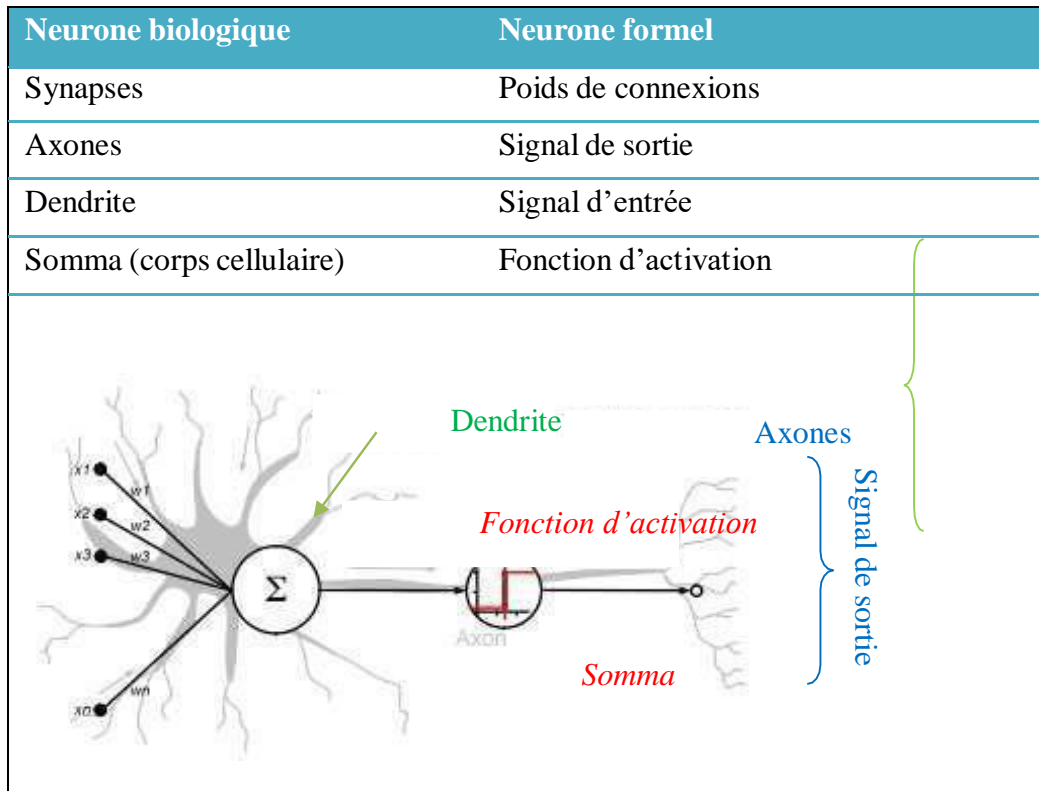


Figure .2.2 : Comparaison entre neurone biologique et neurone formel [13]

Le neurone traite ses entrées et communique la sortie qui peut être le résultat final du système ou l'une des entrées d'un autre neurone ce qui forme un réseau neuronal.

Chaque neurone est défini par trois caractéristiques principales: son état, ses connexions avec d'autres neurones et sa fonction d'activation

Réseau de Neurones Artificiels

Un Réseau de Neurones Artificiels (RNA) est un ensemble de neurones formels organisés en couches fonctionnant en parallèle, où chaque neurone artificiel est un processeur élémentaire qui reçoit un nombre variable d'entrées en provenance d'autres neurones. Chaque entrée possède un poids ' w ' qui représente la force de la connexion. Chaque neurone est doté d'une sortie unique, qui peut être utilisée ensuite pour alimenter un nombre variable de neurones avals [14].

IV. L'apprentissage Automatique

L'apprentissage est un concept basé sur plusieurs mécanismes qui nous permettent l'acquisition de connaissances et leur réutiliser ultérieurement. Pour nous, les êtres humains, notre apprentissage se fait quotidiennement tout au long de notre vie par la collecte d'informations de l'environnement avec nos cinq sens, ainsi les expériences acquises de la répétition des événements dans la vie, et de notre jugement.

Pour faciliter nos recherches, nous avons créé l'ordinateur, qui permet de résoudre en quelques secondes des calculs qui nous prendraient des années de travail [15].

L'apprentissage automatique, qu'il soit *supervisé* ou non *supervisé*, est un sous domaine de l'intelligence artificielle (IA) son objectif est de faire entraîner des modèles pour résoudre des problèmes à partir d'un ensemble de données [16]. Les algorithmes d'apprentissage automatique ont fourni des solutions très encourageantes à des problèmes complexes dans différents domaines : reconnaissance de la parole, traduction du langage naturel, véhicules autonome...etc.

Selon l'inventeur Américain de machine learning: Arthur Samuel [16], qui a défini l'apprentissage automatique en 1959, comme un outil qui permet à une machine d'avoir des connaissances sans être explicitement programmée et sans aucune intervention humaine. Après, en 1998, un autre chercheur américain au nom de Tom Mitchell [17] a donné une autre définition de l'apprentissage c'est quand la performance d'une machine augmente avec de nouvelles expériences on dit que cette machine apprend.

Il existe trois principaux paradigmes d'apprentissage automatique :

L'apprentissage supervisé (Supervised Learning) :

Consiste d'entraîner la machine avec des exemples x **étiquetés** pour avoir une relation avec leurs sorties désirées y selon la fonction ($f: x \rightarrow y$).

Quelques algorithmes d'apprentissage supervisé :

- Machine à vecteurs de support (SVM)
- Réseau de neurones (RNA)
- Méthode des k plus proches voisins (KPP)
- Arbre de décision
- Classification naïve bayésienne...

L'apprentissage non supervisé:

L'objectif principal de l'apprentissage **non supervisé** est de découvrir des modèles cachés dans les données d'où les exemples x ne sont pas **étiquetés**.

Quelques algorithmes d'apprentissage non supervisé :

- Clustering (segmentation, regroupement) : construire des classes automatiquement en fonction des exemples disponibles
- Règles d'association : analyser les relations entre les variables ou détecter des associations
- Réduction de dimensions

L'apprentissage par renforcement

Les entrées sont un ensemble de rétroactions provenant d'un environnement dynamique auquel l'algorithme est confronté. Le but est d'atteindre un objectif prédéterminé. C'est la méthode la plus populaire en robotique.

V. Historique d L'apprentissage profond

D'après Yann LeCun [40], « *L'apprentissage profond ou le Deep Learning permet aux modèles de calcul composé de plusieurs couches d'apprendre des représentations de données avec plusieurs niveaux d'abstraction* ». Autrement dit, c'est une technique d'apprentissage automatique qui fait apprendre l'ordinateur ce que l'être humain le fait naturellement (apprendre par l'exemple) [12]. d'où les algorithmes d'apprentissage profond ont attiré récemment beaucoup d'attention car ils abouti à des résultats qui étaient irréalisables auparavant dans différents domaines de traitement d'images tel que : le domaine de détection d'objets [16], reconnaissance de visage [18], détection précoce de différentes maladies [19,20,21 ,22 ,23,24], tout en profitant des données massives (bigdata) et de la capacité de calcul phénoménale notamment grâce aux GPU et CPU [25]. l'apprentissage profond est un modèle informatique très puissant car il est capable d'effectuer des tâches de classification directement à partir des images, du son ou texte, comme entrée du système sous forme de matrice, ce qui donne l'avantage principal de ces modèles qui est l'extraction automatique des données brutes [17] .

VI. Domaines d'application de l'apprentissage profond :

Un model issu d'un apprentissage profond peut servir dans des situations réelles telle que :

- Reconnaissance des visages;
- Identification selon les mouvements de la marche;
- lecture des chiffres et des textes manuscrits;
- Reconnaissance et analyses des discours;
- Traduction des langues;
- Contrôler les voitures autonomes;
- Les comportements des robots (position/map estimation) ;
- Bioinformatique ;
- E-commerce (détection de fraude) ;
- Analyses financière
- Médecine (diagnostic des maladies) ;
- Web (les réseaux sociaux) ;

Le tableau suivant montre quelques applications qui ont été proposées comme modèles de classification des images basée CNN.

Tableau 2.1 – Les domaines d’application des CNNs .

Référence	Domaine d’application
[15]	Classification des caractères manuscrits
[16]	Classification des vidéos à grande échelle
[17]	Analyse des images médicales
[18]	Classification des images hyperspectrales
[19]	Classification des images histologiques du cancer du sein
[20]	Identification des plantes
[21]	Classification à partir des images radiologiques
[22]	Reconnaissance de piétons
[23]	Reconnaissance de visages
[24]	Classification d’iris
[25]	Classification des véhicules

VII. Les réseaux de neurones convolutifs

L’appariation des réseaux de neurones convolutifs crée une évolution massive dans le domaine des réseaux de neurones, ce sont deux réseaux presque similaires car ils inspirent leur fonctionnement du comportement du cerveau.

Les réseaux de neurones convolutifs (CNNs) donnent des meilleurs résultats dans différents domaines surtout celui de la vision par ordinateur et notamment la classification des images étiquetées [26].

La principale motivation derrière l’émergence des CNNs dans les scénarios d’apprentissage profond été de surmonter les limites des réseaux de neurones traditionnels. Lorsqu’ils sont utilisés dans des domaines comme la classification d’images, les réseaux neuronaux traditionnels entièrement connectés souffrent de problème majeur d’extraction manuelle des caractéristiques, par contre les CNNs apportent de nouvelles idées permettant l’extraction automatique à travers plusieurs couches d’abstraction qui contribuent à améliorer l’efficacité des réseaux de neurones profonds [27].

Le réseau de neurones convolutif appelé aussi **CNN** (en anglais «Convolutional Neural Network») est une nouvelle architecture d’apprentissage profond inventée par LeCun et al. [24,25]. Elle est modélisé sous formes multicouches hiérarchique. Il se compose généralement de trois types de couches: la couche d’entrée (convolution layer), couche(s) cachée(s) (hidden layer) et la couche de sortie (fully connected layer). Ces couches sont organisées selon leurs fonctionnement en deux parties distinctes : la première partie est la phase d’extraction des caractéristiques et la deuxième partie est la phase de classification qui correspond à un modèle **MLP classique (Multi Layers Perceptron)**.

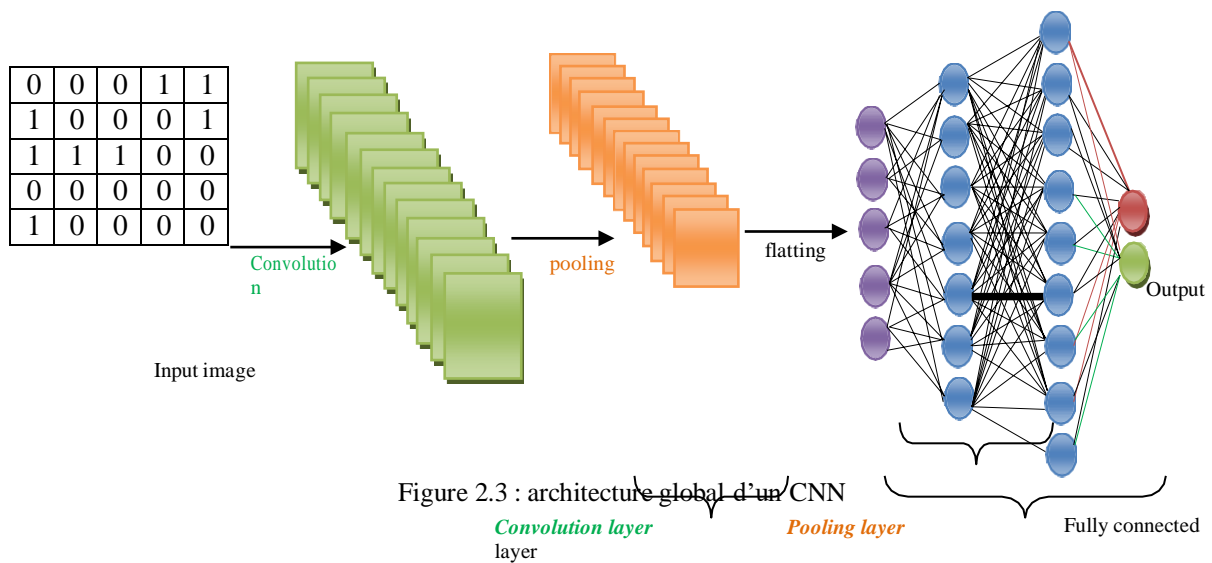


Figure 2.3 : architecture globale d'un CNN

1.1. La phase d'extraction des caractéristiques

La première phase d'un CNN est l'extraction des caractéristiques. C'est une combinaison entre deux couches (la couche convolution + la couche pooling). Son rôle est l'extraction automatique des caractéristiques les plus pertinentes des images. Une image 'I' est passée à travers une succession de filtres 'F' de taille impaire, créant des nouvelles images appelées cartes de convolutions, qui seront passées à la couche pooling pour minimiser leur taille et engendrer des cartes de caractéristiques de taille plus petite.

1.2. La phase de classification de modèle :

C'est la dernière phase de CNN ou plus précisément la couche entièrement connectée. Son rôle est de combiner les caractéristiques déjà extraites dans la première phase (la sortie de la partie d'extraction des caractéristiques) sous forme de vecteur où chacune de ces valeurs doit être reliée à un **neurone du réseau de neurone MLP** situé à la fin du CNN, qui permet de classer n'importe quelle images.

La **convolution** est un outil mathématique qui agit comme un **filtrage**, où le filtre est une matrice souvent carrée de taille ($n \times n \times q$) et généralement de taille inférieure aux tailles des images à classer ($n \leq m$) et q est le nombre de canaux qui peut être le même que r [28].

Le filtre a pour rôle d'extraire certaines caractéristiques d'une image d'entrée. Il va balayer successivement toute l'image. Au début de l'étape de **convolution**, le filtre sera positionné tout en haut à gauche de l'image puis il va se déplacer avec un pas choisi vers la droite et lorsqu'il arrivera au bout de l'image, il se décalera de même **pas** vers le bas et ainsi de suite jusqu'à ce que le **filtre** scanne la totalité de l'image.

Pour chaque position de l'image, les valeurs des deux matrices en superposition (filtre et image) sont multipliées. La valeur résultante est projetée dans une nouvelle matrice. Cette matrice représente une nouvelle image appelé carte de caractéristiques de taille $(m-n + 1)$. L'opération de convolution est présentée par l'équation suivante :

$$S = \sum_{k=0}^{M^F} \sum_{l=0}^{N^F} \sum_{i=0}^R \sum_{j=0}^C I_{(i+k,(j+l))} F_{(R+i-1),(C-j+1)} \quad (2.1)$$

Avec :

I : Matrice de pixels représentant l'image

F : Matrice de filtre de convolution

à appliquer sur l'image
S : résultante
de produite de convolution (feature
map)

R : nombre de ligne de la matrice filtre

C : Nombre de colonne de la matrice filtre

— $M' : \frac{M-R}{P} + 1$, avec M est le nombre de lignes d la matrice d'images et P le nombre de pas du filtre suivant la

ligne et colonne

$N' : \frac{N-R}{P} + 1$, avec N est le nombre de lignes d la matrice d'images

Chaque carte de caractéristiques est alors sous-échantillonnée de façon typique avec une couche « pooling » qui va **réduire sa dimension**.

Une fois que les étapes de convolutions sont réalisées, les caractéristiques acquises en sortie sont injectées sous forme d'un long vecteur comme données d'entrée dans un réseau neuronal classique qui nous a permet de classer n'importe quelle image.

Nous détaillons dans ce qui suit les couches de CNN :

Les différentes couches de CNN :

Un CNN est composé des couches suivantes :

- Couche de convolution,
- Couche pooling,
- Couche entièrement connectée,

La couche convolutive (CONV)

La couche convolutive (en anglais *convolution layer*), C'est la couche la plus importante d'un CNN car c'est elle qui fait l'extraction automatique des caractéristiques à travers le déroulement de l'apprentissage des fonctionnalités des modèles d'après les images qu'elle reçoit en entrée.

Elle effectue des opérations de convolution avec des filtres qui scannent l'entrée de n'importe quel modèle pour avoir des matrices des caractéristiques d'une taille plus petite en comparant à la taille des matrices d'entrée c'est-à-dire faire "glisser" des filtres de taille impaire (3×3 , 5×5 ...) sur l'image d'entrée et de calculer le produit de convolution entre le filtre et chaque portion de l'image balayée[28].

Pour chaque paire (image, filtre) on obtient une carte d'activation, ou *feature map*, qui nous montre où s'arrangent les *caractéristiques* dans l'image

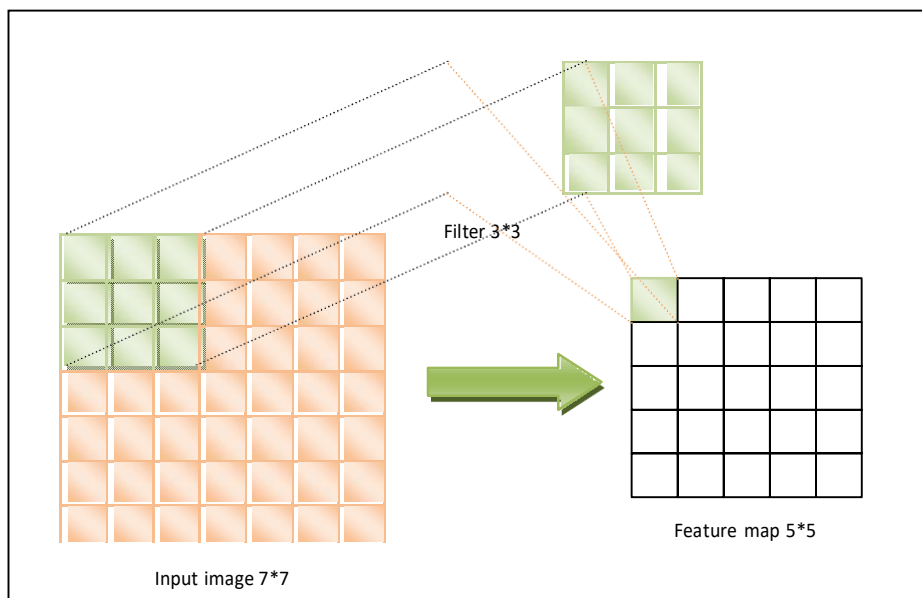


Figure 2.4 : La couche de convolution[28]

L'opération de convolution est caractérisée par deux principaux avantages :

- Permettre de diminuer le nombre de poids du réseau de neurone.
- Permettre l'identification des caractéristiques d'une manière automatique contrairement aux méthodes traditionnelles.

- **Les hyper-paramètres de la couche convolutive :**

Le but principal de la couche convolutive est de détecter les caractéristiques pertinentes dans des images ou dans des scènes : telles que des bords, des lignes, des taches de couleur et autres éléments visuels, où les filtres peuvent les détecter. Les hyper-paramètres de la couche convolutive, qui spécifient l'architecture de CNN [27], dont les plus essentiels sont :

- Nombre de filtres
- La profondeur
- Le pas ou le stride
- La marge ou le padding
- Les fonctions d'activation

- **Profondeur de filtre :** c'est le nombre de filtres appliqués à une image donnée, c'est-à-dire un filtre de taille $(F \times F \times C)$ qui effectue des convolutions sur une image d'entrée de taille $I \times I \times C$ produit un *feature map* de sortie de taille $S \times S \times 1$. Si on applique K filtres sur une image de taille $I \times I \times C$ on obtient un *feature map* de taille $S \times S \times K$ où K est le nombre de filtres ou bien sa profondeur.

Remarque : 'C', est le nombre de canaux varie selon la couleur de l'image.




Figure 2.5 : Profondeur d'un filtre[27]

- **Le pas ou la stride :** Dans le contexte d'une opération de convolution ou de pooling, le pas ou la stride 'S' d'une opération de convolution est un paramètre qui désigne le nombre de pixels de déplacement d'un filtre sur l'image d'entrée après chaque opération.

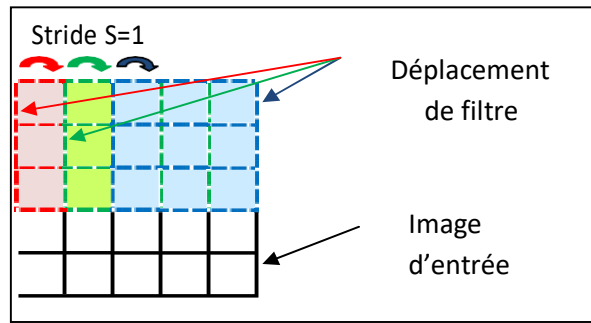


Figure 2.6 : Le stride d'un filtre [27]

- **La marge (à 0) ou zéro padding :** le zero padding est une technique qui consiste à ajouter des '0' à chaque côté des frontières de l'entrée. parfois, il est pratique de mettre ces zéros pour permettrele contrôle de la dimension spatiale du volume de sortie. Cette technique peut être réalisée manuellement, ou automatiquement.

- **Les fonctions d'activation**

La fonction d'activation (ou fonction de transfert) sert à convertir le résultat de la somme pondérée des entrées d'un neurone en une valeur de sortie, cette conversion s'effectue par un calcul de l'état du neurone en introduisant une non-linéarité dans le fonctionnement du neurone.

- **La fonction d'activation Relu**

Les CNNs ont la particularité d'introduire sur des fonctions non linéaires pour signaler une identification distincte des caractéristiques probables sur chaque couche cachée. Parmi ces fonctions, la fonction d'activation d'unité linéaire rectifiée «ReLU » en anglais Rectified Linear Units proposée en 2000 par Nair & Hinton, c'est une fonction mathématique qui s'applique en général après la couche de convolution : $f(x)=max(0,x)$ (2.2),

qui a pour but d' augmenter les propriétés non linéaires de réseau[68], qui va améliorer l'efficacité du traitement entre les couches de CNN. Cette fonction possède deux autres variantes **Leaky ReLU**, **ELU** le déroulement de **ReLU** sera présenter comme suit :




Figure 2.7 : Représentation de la fonction ReLU [28]

D'autres fonctions sont également utilisées pour augmenter la non-linéarité comme :

- La correction par tangente hyperbolique:

$$f(x) = \tanh(x) \quad (2.3)$$

et la tangente hyperbolique saturante :

$$f(x) = |\tanh(x)| \quad (2.4)$$




Figure 2.8 : Représentation de la fonction tangente hyperbolique

- **La correction par la fonction sigmoïde** : le choix de la fonction d'activation pour la couche de sortie doit correspondre à la fonction de coût qui est choisie en fonction de la tâche que le modèle entraîné à réaliser. Dans le cas de classification binaire, la fonction d'activation *sigmoïde* notée

$$F(x) = \frac{1}{1+e^{-x}} \quad (2.5)$$

est généralement adopté et ses valeurs sont pris sur l'intervalle $[0, 1]$ dans le cas où la prédiction suit une loi probabiliste [69]. La fonction sigmoïde donne souvent des meilleurs résultats de prédiction. Tant que x converge vers un grand nombre positif, la fonction *sigmoïde* tendra vers 1 .




Figure 2.9 : Représentation de la fonction sigmoïde [69]

- **La fonction softmax**: appelée aussi fonction logistique, elle est favorable dans les multi-classes, appliquée toujours à la fin de réseau, définie comme suit :

$$\text{Softmax} = \frac{e^{x_j}}{\sum_{j=1}^J e^{x_j}} \quad (2.6)$$

Son rôle est d'associer le vecteur de caractéristiques obtenu par la couche pooling à un vecteur de probabilité de somme 1.

- **La fonction d'activation Identity :**

Identity, c'est une fonction d'activation linéaire (**linear activation function**). Elle peut rendre un réseau neurone multicouches équivalent à un réseau neuronal mono-couche. Son équation est la suivante : $f(x) = x$ (2.7)




Figure 2.10 : La fonction d'activation Identity [69].

- **Les avantages de la fonction ReLu**

Malgré l'existence d'autres fonctions d'activation de la non-linéarité, La fonction ReLU est la plus répandue dans les CNNs grâce à ses avantages:

- Assure une optimisation facile par l'élimination des valeurs négatives et réduire le sur-apprentissage.
- Fonction très simple au calcul qui fournit des réponses optimales et qui permet la réduction des problèmes de disparition de gradient qui rend le réseau incapable d'optimiser ses paramètres [29].
- Renvoie, un gradient constant pour une entrée grande permettant ainsi d'apprendre plus rapidement (surtout pour les réseaux de grande profondeur).
- Soulève le problème de la sigmoïde et la tangente hyperbolique qui ont l'inconvénient de renvoyer des gradients très petits lorsque la valeur absolue de l'entrée est grande. Ce qui rend la mise à jour des paramètres de réseau difficile lors de la phase d'apprentissage.

La couche d'Agrégation (pooling) :

La couche pooling (en anglais pooling layer) c'est la deuxième couche de réseaux de neurone convolutif qui est considérée comme une spécificité de ces réseaux. Le pooling est une étape de sous-échantillonnage des cartes de caractéristiques générées par la couche de convolution tout en réduisant leurs dimensions mais en préservant leurs caractéristiques importantes avec un grand gain de temps de calcul[28].

Les deux types de pooling les plus populaires sont: le Max Pooling et l’Average pooling. Soit on extrait uniquement la valeur la plus élevée (**max pooling**) dans carte de caractéristique, soit on fait la moyenne des valeurs de la zone (**average pooling**), ces deux opérations seront bien détailler dans le tableau suivant :

Tableau 2.2: Présentation des types de pooling

Type	Max pooling	Average pooling																																								
Définition	consiste à sélectionner la valeur maximale sur une fenêtre de calcul.	permet de sélectionner la moyenne des valeurs sur une fenêtre de calcul.																																								
avantage	efficace lorsque on veut détecter des signaux forts	efficace lorsque on souhaite détecter des signaux faibles																																								
Exemple	<table style="margin-left: auto; margin-right: auto;"> <tr><td style="background-color: yellow;">5</td><td style="background-color: yellow;">3</td><td style="background-color: lightgreen;">8</td><td style="background-color: lightgreen;">1</td></tr> <tr><td style="background-color: pink;">22</td><td style="background-color: pink;">14</td><td style="background-color: lightblue;">9</td><td style="background-color: lightblue;">10</td></tr> <tr><td style="background-color: pink;">13</td><td style="background-color: pink;">54</td><td style="background-color: lightblue;">11</td><td style="background-color: lightblue;">4</td></tr> <tr><td>3</td><td>2</td><td>4</td><td>17</td></tr> </table> <p style="text-align: center;">↓ <i>Le max</i></p> <table style="margin-left: auto; margin-right: auto;"> <tr><td style="background-color: yellow;">22</td><td style="background-color: lightgreen;">10</td></tr> <tr><td style="background-color: pink;">54</td><td style="background-color: lightblue;">17</td></tr> </table>	5	3	8	1	22	14	9	10	13	54	11	4	3	2	4	17	22	10	54	17	<table style="margin-left: auto; margin-right: auto;"> <tr><td style="background-color: yellow;">5</td><td style="background-color: yellow;">3</td><td style="background-color: lightgreen;">8</td><td style="background-color: lightgreen;">1</td></tr> <tr><td style="background-color: pink;">22</td><td style="background-color: pink;">14</td><td style="background-color: lightblue;">9</td><td style="background-color: lightblue;">10</td></tr> <tr><td style="background-color: pink;">13</td><td style="background-color: pink;">54</td><td style="background-color: lightblue;">11</td><td style="background-color: lightblue;">4</td></tr> <tr><td>3</td><td>2</td><td>4</td><td>17</td></tr> </table> <p style="text-align: center;">↓ <i>La moyenne</i></p> <table style="margin-left: auto; margin-right: auto;"> <tr><td style="background-color: yellow;">11</td><td style="background-color: lightgreen;">7</td></tr> <tr><td style="background-color: pink;">18</td><td style="background-color: lightblue;">9</td></tr> </table>	5	3	8	1	22	14	9	10	13	54	11	4	3	2	4	17	11	7	18	9
5	3	8	1																																							
22	14	9	10																																							
13	54	11	4																																							
3	2	4	17																																							
22	10																																									
54	17																																									
5	3	8	1																																							
22	14	9	10																																							
13	54	11	4																																							
3	2	4	17																																							
11	7																																									
18	9																																									
Utilisation	C’est le plus utiliser dans la plus part architecteur du CNN	Utilisé dans l’architecture Le-Net																																								

La couche entièrement connectée :

En anglais (*fully connected layer*) c’est la dernière couche de CNN qui se situe après une succession de multiples couches de convolutions et pooling. Comme son nom l’indique elle est entièrement connectée à la sortie de la couche précédente qui génère les cartes des caractéristiques qui seront aplatis par la suite dans un vecteurs de caractéristiques où chacune de ces valeurs est totalement connecter par tous les neurones du réseau régulier de cette couche pour donner les prédictions désirées en sortie.




Figure 2.11 :La couche entièrement connectée [28]

Ajustement des hyperparamètres :

Le choix des paramètres d'un CNN joue un rôle important dans l'augmentation des performances de l'architecture des CNNs, en plus des paramètres habituelles d'un MLP standard (les règles pour les taux d'apprentissage et des constantes de régularisation), les CNNs possèdent autres hyperparamètres telle que le nombre de filtres, leur taille et la forme du pooling.

- **Nombre de filtres:** à mesure que la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres, tandis que les couches plus proches de la sortie peuvent en avoir plus.
- **Taille du filtre:** la forme du filtre varie considérablement dans la littérature. Ils sont généralement sélectionnés en fonction de l'ensemble de données. Les meilleurs résultats sur les images MNIST (28x28) sont généralement de l'ordre de 5x5 dans la première couche, tandis que les ensembles de données d'images naturelles (généralement des centaines de pixels) ont tendance à utiliser une couche de filtre de 12x12 ou même 15x15. Le défi consiste donc à trouver le bon niveau de granularité afin de créer une abstraction adaptée à chaque situation appropriée.
- **Forme du pooling :** Les valeurs typiques sont 2x2. Si le volume d'entrée est grand on peut utiliser un pooling 4x4 dans les premières couches. Toutefois, le choix de formes plus grandes va considérablement réduire la dimension du signal ce qui entraînera une perte de l'information.

VIII. Apprentissage profond et imagerie médicale

L'acquisition des images internes du corps humain peut être réalisée à travers différentes techniques telles que : les imageries par résonance magnétique (IRM), les ultrasons, les scanners, les tomographies d'émission monophonique, ...etc.

Aujourd'hui, les chercheurs utilisent les représentations numériques des parties du corps humain sous forme d'images ou son pour faire des diagnostics précoces des maladies. Ces diagnostics prennent beaucoup de temps aux médecins et ce sont très coûteux pour les patients. C'est pour cela, ils ont créé des systèmes automatiques d'analyses et de traitements d'images médicales .

Au départ, les opérations de classification et de segmentation ont été réalisées avec beaucoup de techniques d'apprentissage automatique (SVM, KNN, ...) mais malheureusement leurs réalisation reste encore difficile à cause de problème d'extraction manuelle des caractéristiques « *feature engenering* » .

L'émergence d'apprentissage profond fait la tendance par son utilisation dans l'analyse des images médicales vue les résultats remarquables réalisés dans différents domaines. Grâce à ses performances et sa capacité de la généralisation sur des données diverses et surtout sa possibilité de surmonter les problèmes des anciennes techniques celle d'automatiser la phase d'extraction des caractéristiques dites pertinentes.

C'est la raison pour laquelle, l'intérêt s'est attiré soudainement les méthodes d'apprentissage en profondeur plus que les méthodes d'apprentissage automatique traditionnelles.

IX. L'interprétation des images

L'interprétation des images dans l'apprentissage profond regroupe trois tâches essentielles : la classification, la localisation / détection et la segmentation, dans cette section nous allons analyser les architectures les plus connues de ces tâches :

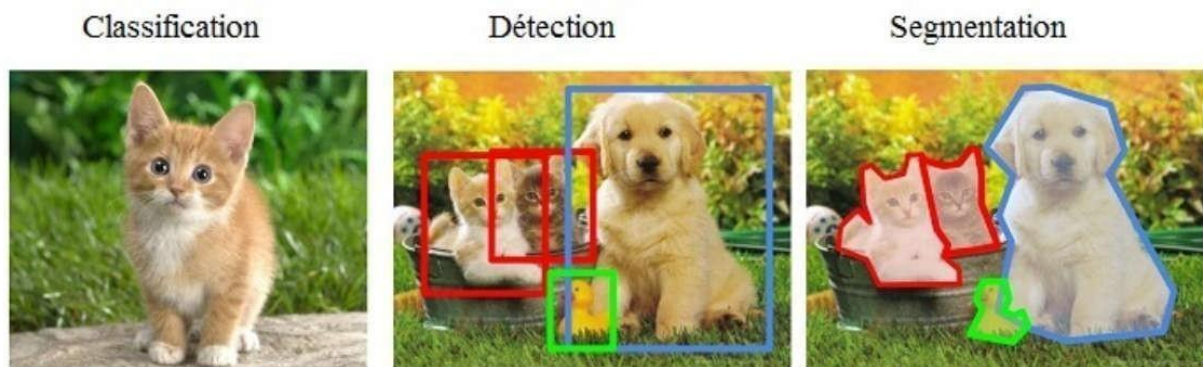


Figure 2.12 : Les trois tâches essentielles de l'interprétation d'images

1. La Classification

La classification automatique d'images est une application de la reconnaissance des formes. Elle s'agit d'attribuer une image à une classe à l'aide d'un système de classification automatisé afin de faciliter les études. Au fil des années et avec la révolution de la performance du matériel informatique, beaucoup d'approches ont été développées dans différents domaines d'activités tels que : le domaine militaire [30], domaine médical [31]; domaine d'agriculture [32], domaine de reconnaissance d'écriture manuscrite pour les chèques, les codes postaux [33], Classification d'écriture arabe [34].

▪ Les architectures de classification les plus connues

• LeNet:

LeNet est la première architecture de type CNN proposée par LeCun *et al* [24] en 1998 pour la classification supervisée. La figure 2.13 illustre la structure du réseau LeNet. Cette architecture est composée de 7 couches (3 couches de convolution, 2 couches de Avg-pooling et 2 couches

entièrement connectées). Avec une taille des filtres des couches de convolution de 5×5 et les entrées sont des images de taille 32×32 .

Les couches *convolution* et *pooling* sont composées d'un certain nombre de cartes de caractéristiques d'une taille définie. Plus qu'on rapproche de la sortie de ce réseau plus la taille des images est réduite par rapport aux premières couches. Dans cette architecture l'apprentissage est basé sur la rétropropagation. L'implémentation de cette architecture a été testée la première fois sur la base de MNIST de classification des chiffres manuscrits qui contient 60 000 images pour l'apprentissage et 10 000 images pour le test, où l'algorithme d'apprentissage profond LeNet a montré une efficacité remarquable en comparant par les anciennes architectures telles que SVM et KNN.

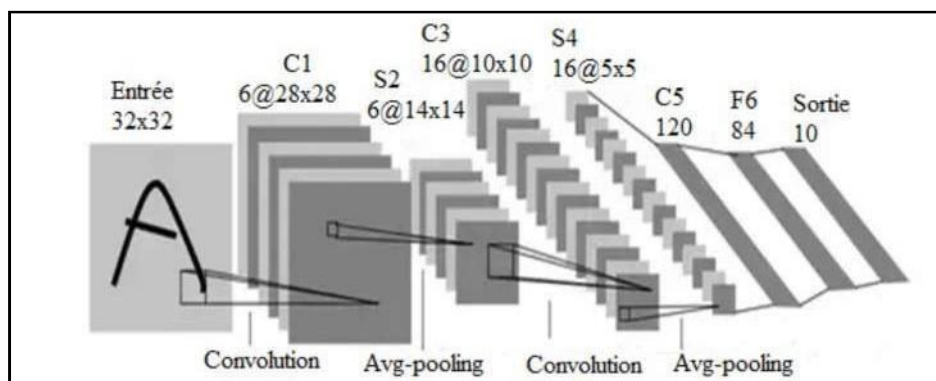


Figure 2.13 : L'architecture du réseau LeNet [24]

• AlexNet

L'apparition du réseau AlexNet [35] en 2012 était un point important dans l'historique d'apprentissage profond surtout après la compétition ImageNet de reconnaissance visuelle à grande échelle (ILSVRC). Dans cette compétition, **AlexNet** a été proposé avec un jeu de données de la base ImageNet composé de 1000 catégories, 1.2 million images d'apprentissage, 50 000 images de validation, et 150 000 images de test où il a obtenu le meilleur taux d'erreur. L'architecture de ce réseau (figure 2.14) est semblable à l'architecture LeNet mais plus profonde. AlexNet est composé de 5 couches de convolution et 3 couches entièrement connectées. La première couche de convolution utilise 96 filtres de taille 11×11 , mais les autres couches convolutives sont basées sur des filtres de taille 5×5 et 3×3 . La première, la deuxième et la cinquième couche de convolution sont suivies par des couches de max-pooling et les deux premières couches sont suivies par une opération de normalisation (local response normalisation (LRN)). La fonction LRN est implémentée pour améliorer la généralisation et la non linéarité du réseau, elle est appliquée sur les résultats de la fonction *d'activation ReLu*, dans le but d'accélérer

Cette proposition a permis d'améliorer la performance du réseau AlexNet par 1.7 % qui a encouragé les chercheurs à utiliser les techniques de visualisation dans l'ajustement des hyperparamètres.

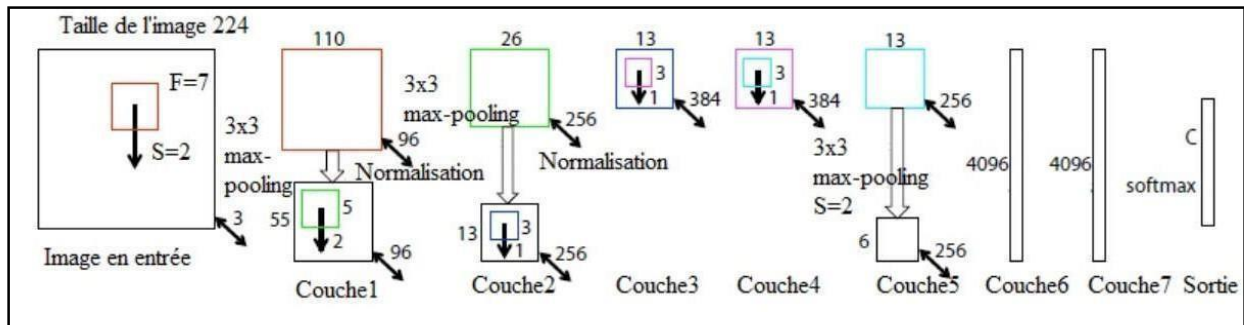


Figure 2.15 : l'architecture du réseau ZFNET [36]

•VGGNet

VGGNet [29], est un réseau convolutif proposé en 2014 avec une configuration profonde similaire à celle d'AlexNet où les couches de VGGNet peuvent varier de 16 à 19 couches. Cette architecture est basée sur la technique de stabilisation structurelle pour contrôler le nombre de ses paramètres afin de diminuer les risques de sur-apprentissage, aussi, le réseau VGGNet recommande de diminuer la taille des filtres afin de réduire le nombre des paramètres. Par exemple, l'utilisation de 2 couches de filtre 3x3 est meilleur que l'utilisation d'une seule couche de filtre 5x5 car en utilise moins de paramètres : Le nombre d'un paramètre est réduit de 28% $((25-18) / 25)$. C'est-à-dire :

Nombre de paramètres de 2 couches de filtre 3x3: $2 \times 3 \times 3 = 18$

Nombre de paramètres de 1 couche de filtre 5x5: $1 \times 5 \times 5 = 25$

En résumé, l'amélioration de la non-linéarité du réseau est réalisée grâce aux fonctions d'activation (ReLU) supplémentaires.

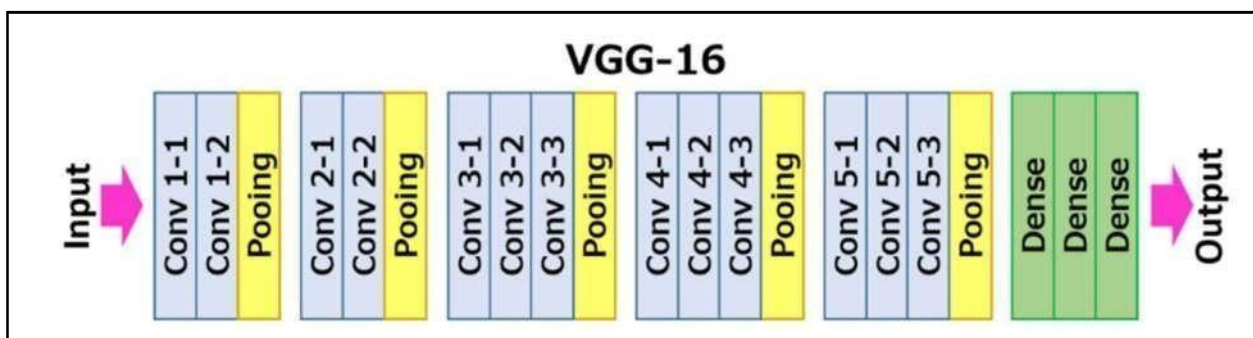


Figure 2.16 : l'architecture du réseau VGGNet [29]

•Inception

Les experts en apprentissage profond recommandent généralement d'augmenter la taille du réseau en fonction de la largeur (nombre de paramètres dans chaque couche) et de la profondeur (nombre

de couches) pour améliorer les performances du réseau. Depuis 2015, et pour éviter les grands problèmes des réseaux profonds qui sont le risque de sur-apprentissage et l'exigence de capacité de stockage et de calcul, beaucoup de recherches sont tournées vers les architectures partiellement connectées.

Le réseau Inception est un réseau neuronal convolutif utilisant les modules Inception. Ces modules permettent l'optimisation des couches convolutives classiques. Le module initial introduit des connexions partielles à l'intérieur de la couche convolutive pour réduire sa dimension. La Figure 2.17 illustre la structure du module Inception.

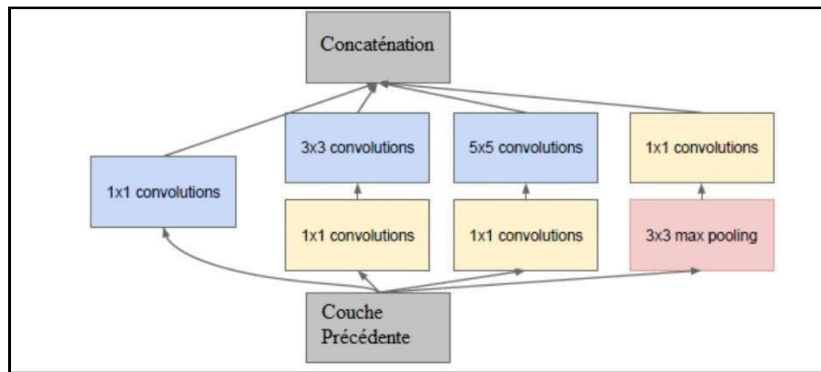


Figure 2.17 : La structure d'un module d'Inception

On peut voir que la structure de module d'Inception [80] Utilise des filtres de taille variable (1×1, 3×3 et 5×5) et applique-les sur la même couche convolutive pour éviter les problèmes d'alignement du patch. Ensuite, les cartes d'entités générées sont rassemblées pour former la couche convolutive suivante. Afin de résoudre le problème de l'augmentation rapide de la profondeur de la couche convolutive due à la cascade de cartes de caractéristiques, le filtre de la taille 1x1 a été introduit avant les filtres de taille 3x3 et 5x5. Ces filtres réduisent la profondeur de la couche convolutive avant d'appliquer d'autres filtres et améliorent la non-linéarité grâce à la fonction d'activation ReLu.




Figure 2.18: L' architecture du réseau Inception.

Toujours dans le cadre d'optimisation de la complexité de calcul Szegedy *et al.*, ont proposé en 2015 **InceptionV2** et **InceptionV3** [38], qui est des versions améliorées du réseau Inception.

- **ResNet**

He et al ont proposé en 2016 un réseau neuronal convolutif appelé ResNet [39] basé sur le bloc résiduel, ils visent à résoudre le problème de dégradation du gradient, qui survient généralement dans les réseaux très profonds. La précision de ces réseaux commence à atteindre la saturation, puis elle se dégrade rapidement en raison de la diminution de la valeur du gradient. Dans l'architecture ResNet, ils ont introduit des blocs résiduels sous forme de jonctions entre la sortie de la couche précédente et la sortie de la couche courante. La formule de ces jonctions est présentée par l'équation 2.4 pour réaliser l'addition, elle est suivie d'une projection linéaire Ws afin d'obtenir des dimensions équivalentes (x et $F(x)$).

$$y = F(x) + x \quad (2.4)$$

L'étude comparative de He *et al.*, d'un CNN avec et sans blocs résiduels montre que les réseaux les plus profonds de Res-Net sont les plus performants




Figure 2.19 – La structure des blocs résiduels [39]




Figure 2.20 : l' architecture du réseau ResNet (34 couches) [39]

- **DenseNet**

DenseNet[40] est un réseau de neurones convolutif proposé en 2017, basé sur des connexions denses entre les couches convolutives. Selon la Figure 2.21, il est constitué d'une collection de blocs denses liés par une couche de transition. Chaque bloc dense contient un ensemble de couches

convolutives, où chaque couche est connectée à toutes les autres couches qui la suivent à condition qu'elle appartienne au même bloc. Au contraire d'un CNN classique, chaque couche reçoit comme entrée la carte des caractéristiques de la couche qui la précède. Les connexions dans le bloc dense établissent un lien direct entre le gradient de la fonction de coût et les entrées originales. De plus, ils peuvent améliorer la régularisation, réduisant ainsi le sur-apprentissage et la dégradation de gradient.




Figure 2.21: L'architecture du réseau DenseNet [40]

D'après les exemples cités en haut, on peut dire que toutes les architectures appliquées sur la base d'images « ImageNet » ont réalisé des résultats remarquables grâce à sa richesse et sa taille. Nous avons vu une variété d'architectures profondes, dont l'objectif concurrentiel est de réduire le nombre total de paramètres et d'accélérer le temps d'exécution, bien sûr, pour réduire le taux d'erreur. La concurrence pour ces architectures a toujours été l'optimisation pour éliminer les problèmes de sur-apprentissage et de dégradation de gradient.

▪ Exemples des travaux de classification profonde

Voici quelques exemples des travaux réalisés pour la classification des images médicales basant sur différentes architectures des réseaux de neurones convolutifs :

Tableau 2.3 : Exemples des travaux de classification profonde

Référence	Type de Réseau	Type de diagnostic
[40]	Variante de GoogLeNet	Classification à haut débit des radiographies
[41]	CNN	Diagnostic d'Alzheimer
[42]	Variante de AlexNet	Classification de cancer du sein
[43]	CNN	La classification des tissus épithélial (EP) et stroma (ST)
[44]	CNN	Classification de cancer du sein
[45]	ChexNet	Classification des images de radiographie pulmonaire

▪ La Détection et localisation des objets

La détection consiste à localiser des éléments ou des organes à partir de la surface de l'image, ce qui est considéré comme difficile par rapport à la classification car il faut localiser des informations

plus précises. Habituellement, la zone d'intérêt sera entourée par un contour, cadre ou cercle, ou mieux encore, une courbe (bounding box). En imagerie médicale, cette opération de détection pose de grands défis pour les raisons suivantes: sa rapidité, la corrélation du cadre de contour et la détection de petits éléments.

Les architectures de détection les plus connues

- **R-CNN**

C'est le premier modèle d'apprentissage profond dédié pour la détection des objets, proposé en 2014 par Girshick et al [44]. Cette méthode est une combinaison entre les méthodes de proposition des régions (regions proposal) et les CNN. la structure R-CNN est composée de 3 modules: extraction des régions d'intérêt, extraction des caractéristiques et classification. Le premier module est basé sur l'algorithme de recherche sélective, qui fait la sélection de divers patches de l'image susceptibles de contenir des objets. Ensuite, ces régions sont ajustées pour obtenir une taille conforme à l'entrée de CNN. Le réseau R-CNN utilise aussi le modèle Alexnet [35] pré-entraîné précédemment sur la base ImageNet, et suivi par un fine-tuning sur la base d'apprentissage cible PASCAL. A la fin, ces vecteurs sont fournis à l'algorithme SVM pour finir la classification et mettre les objets dans des cadres grâce à l'algorithme bounding-box regressors.

Malgré que l'apparition de R-CNN a fait un grand changement dans le domaine de détection d'objet grâce à son efficacité de fonctionnement mais il a connu un échec en raison du manque d'optimisation du temps d'apprentissage et de test.

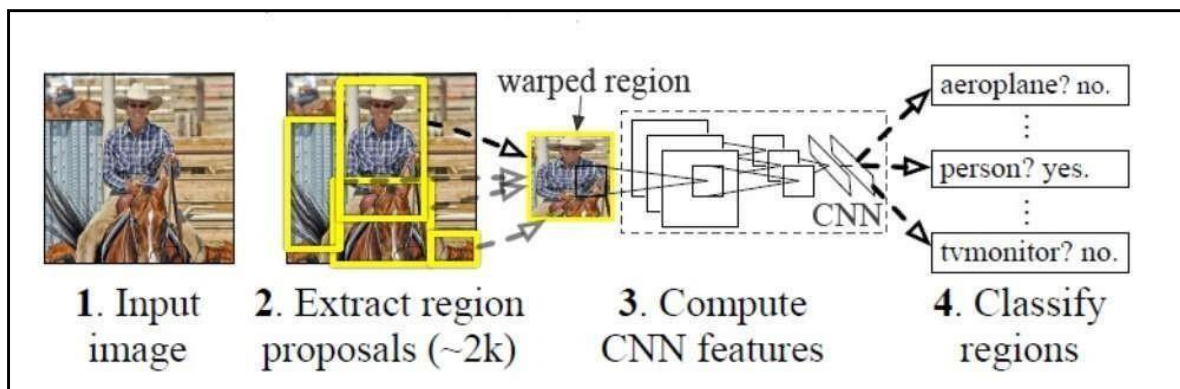


Figure 2.22 – L'architecture de Régions avec réseaux de neurones convolutif (R-CNN) [45]

- **Fast R-CNN**

Afin de surmonter les problèmes d'optimisation du temps d'apprentissage et de test dans la version R-CNN, Girshick a proposé la version améliorée Fast R-CNN [41]. Le principe général du réseau Fast R-CNN est de transmettre l'image d'entrée au réseau CNN pour concevoir la carte des caractéristiques en sortie (l'extraction des caractéristiques et la classification de bout en bout sont effectuées par un seul algorithme). Ensuite, identifiez les zones suggérées dans ces cartes et

redimensionne-les via la couche de fusion RoI-pooling. Ensuite, le vecteur généré passe à travers les couches entièrement connectées. Enfin, l'étape de classification amène à régler le cadre de sélection par le bounding-box regressor en utilisant softmax pour réajuster le cadre de sélection. On peut dire que Faster-RCNN est rapide en phase de test, car l'étape de classification est presque en temps réel, il est donc plus facile à entraîner, plus précis et plus rapide.

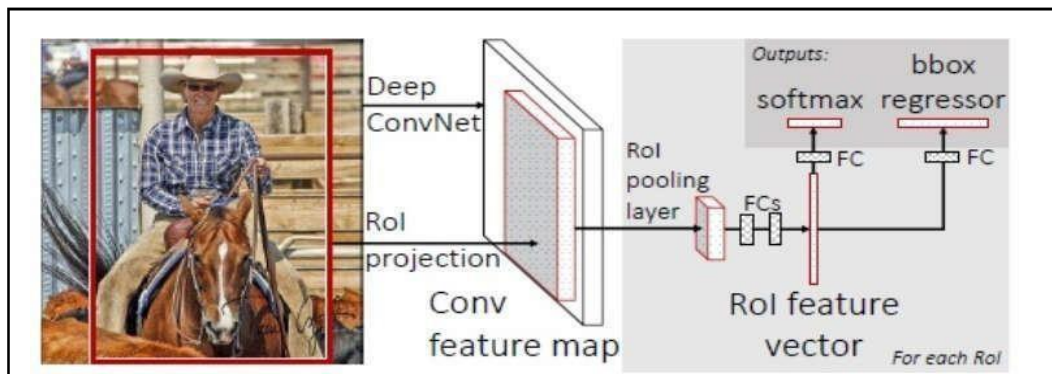


Figure 2.23 – l' architecture du réseau Fast R-CNN [41].

- YOLO (en anglais You Only Look Once)

YOLO [42], c'est un autre algorithme de détection d'objet, en comparant par d'autres architectures mentionnées précédemment, cette méthode présente des comportements différents. Ce niveau de détection est un simple problème de régression dans lequel la prédiction de catégorie et la sélection d'objets sont effectuées en parallèle.

Le principal avantage de l'apprentissage et de la prédiction depuis l'image entière et que le taux de faux positifs soit minimale. Le fonctionnement de YOLO commence par diviser l'image d'origine en grilles $S \times S$, où chaque grille prédit B images sélectionnées et la probabilité que l'objet appartienne à une catégorie différente C. Le cadre sélectionné est caractérisé par 5 paramètres: 4 coordonnées (x, y, h, w) et le score de confiance P, qui est la probabilité d'appartenance de l'objet au cadre et sa précision. En raison qu'il traite 25 images par seconde YOLO est très efficace.

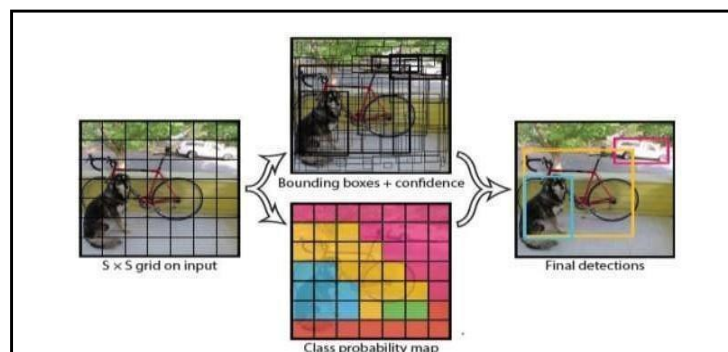


Figure 2.24 – L' architecture de détection des objets par YOLO[42].

Le but principal des différentes architectures proposées pour la détection d'images est de fournir une structure permettant la détection d'objets en temps réel. Par exemple, YOLO a pu accélérer le temps de détection en intégrant la phase générée par RoI dans le réseau.

Exemples des travaux de détection

Dans le tableau suivant nous citons quelque travaux de détection dans des images médicales se basant sur les réseaux de neurones convolutifs :

Tableau 2.4 : Exemples des travaux de détection profonde

<i>Référence</i>	<i>Type de Réseau</i>	<i>Type de diagnostic</i>
[42]	R-CNN	La détection des lésions malignes ou bénignes
[43]	Variante de Faster R-CNN	La détection des nodules pulmonaires
[44]	CNN	La détection des points de repère sur la surface du fémur distal
[45]	CNN	La détection des microsaignements cérébraux
[46]	CNN	La détection des noyaux

2. La Segmentation

La segmentation est une tâche de base dans les applications de diagnostic assisté par ordinateur car le diagnostic des pathologies représente des situations vraiment critiques où le résultat de la segmentation peut remplacer l'avis de médecin dont l'erreur ne sera jamais autorisée.

La segmentation sémantique est une brique essentielle dans la compréhension d'une scène. Elle sert à classifier l'ensemble de pixels d'une image en attribuant une classe à chaque pixel. Avec l'apparition des techniques d'apprentissage profond, les CNN peuvent jouer le rôle des classifieurs de pixels. Dans ce cas le réseau prend en entrée des parties de l'image et classifie le pixel de centre, cela est répétée pour tous les pixels de l'image, où chacun est considéré comme le centre du segment déduit. Le problème de cette répétition et qu'elle consomme un temps énorme ce qui limite utilisation des CNN dans les applications qui travaillent en temps réel. De ce fait, la création d'autres architectures de segmentation plus robustes est nécessaire.

X.3.1. Les architectures de segmentation les plus connues

- **Fully convolutional networks(FCN)**

C'est un réseau très efficace pour la segmentation sémantique de nombreux types d'images : multimédia [43], aériennes [44], ou médicales [45]. Le réseau FCN [46] est une architecture de bout en bout dédié pour la segmentation, il est capable de réaliser la phase de segmentation en un seul passage contrairement à un CNN. Ce réseau est composé de deux principales phases: le sous-échantillonnage et le ré-échantillonnage. Une fois les informations sémantiques et contextuelles sont captées dans la phase de sous-échantillonnage, elles seront ré-échantillonnées pour rétablir les informations spatiales. Les réseaux FCN n'utilisent pas les couches entièrement connectées pour ne

pas fixer la taille des entrées et gérer les entrées de taille variante. Ainsi que les couches entièrement connectées sont remplacées par des couches de convolution pour produire des cartes spatiales. Qui seront passées à des couches de déconvolution pour restaurer la taille en entrée et produire des sorties classifiées par pixel.

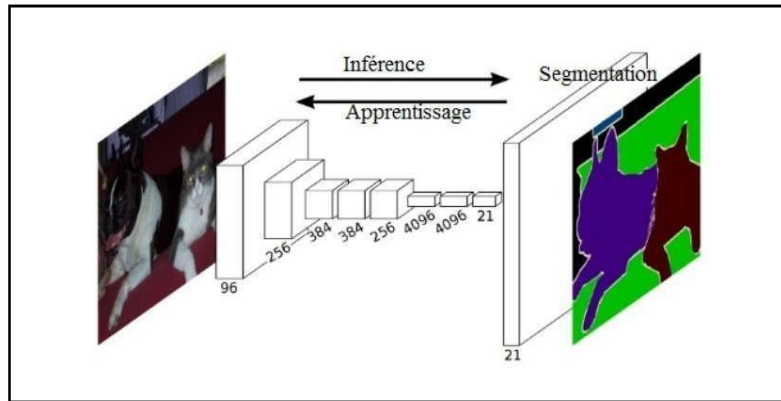


Figure 2.25: L'architecture du réseau fully convolutional network [46].

- **Les architectures Encodeur-décodeur**

La majorité des réseaux de convolution sont utilisés dans les tâches de classification des images, où la sortie est une prédiction. Néanmoins, cette sortie peut être un objet localisé ou une forme segmentée utilisant d'autres variantes des réseaux de l'apprentissage profond. Récemment, de nombreuses études sont basées sur les architectures *Encodeur-décodeur* pour améliorer leurs systèmes d'aide au diagnostic médical.

La croissance de l'utilisation des approches encodeur-décodeur a également été considérable pour segmenter les images médicales de différentes maladies telles que: les images biomédicale [43], les vaisseaux sanguins intracrâniens, vaisseaux rétiniens, contours de cellules et poumon [47], les lésions cutanées du psoriasis [44], les tumeurs cérébrales [45,46], les lésions cutanées dans les images de dermatoscopie [48], les images radiologiques médicales [49].

Le plus connu dans la segmentation des images médicales dont l'architecture encodeur-décodeur est 'U-Net', qui sera l'axe de notre deuxième contribution.

- *U-Net*

U-Net est le premier réseau de genre encodeur-décodeur dédié pour la segmentation, il a été créé par Ronneberger et al [43] sous forme de la lettre ‘U’, qui se déroule facilement avec une succession des couches, une fois on met une image à l’entrée du U-Net on obtient l’image segmentée à la sortie.

“U-Net” est une architecture qui contient deux chemins symétriques: un chemin de contraction (côté gauche) suivi par un chemin expansif (côté droit), d’où le chemin de contraction suit parfaitement la même architecture d’un CNN.

Le U-Net se compose de 5 niveaux, chaque image couleur de taille $(x \times x \times 3)$ à l’entrée du premier niveau va approfondir à travers les autres niveaux à gauche et suit la forme ‘U’ jusqu’à la sortie de U-Net à droite. Cette architecture sera bien détaillée dans la contribution 2.




Figure 2.26 :L' architecture du réseau U-Net [43].

- *SegNet*

SegNet[108] est un autre modèle encodeur-décodeur proposé en 2017. Conçu pour la segmentation sémantique par pixels. Son architecture totalement convolutive est inspirée du modèle VGG-16, où l'encodeur comprend typologiquement 13 couches convolutives du VGG16 qui produit des cartes d'activation qui sont par la suite sur-échantillonnées et projetées dans l'espace sémantique par le décodeur dont le rôle est de mapper les cartes de caractéristiques de basse résolution de codeurs avec les cartes de caractéristiques de résolution d'entrée totale.

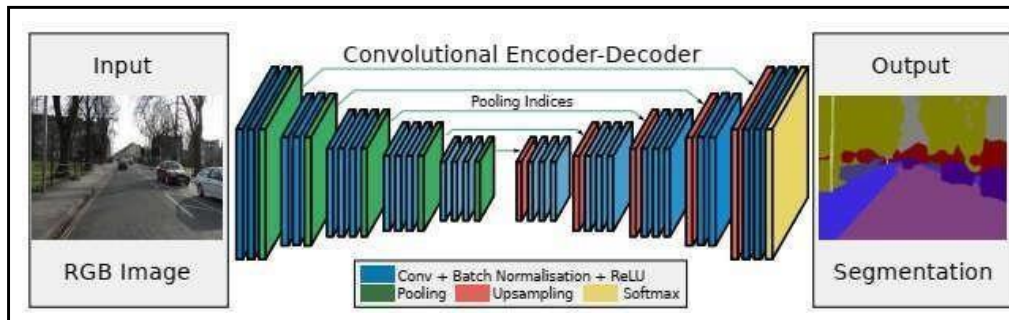


Figure 2.27 : L' architecture du réseau Seg-Net [45].

L'intérêt majeur de proposer des architectures dédiées pour la segmentation sémantique, est de segmenter les objets en temps réel comme le réseau FCN, Qui peut effectuer la segmentation dans la phase de prédiction en un seul passage. Aussi l'appariation des architectures encodeur -décodeur (U-Net, Seg-Net...) a révolutionné ce domaine car ces réseaux assurent une segmentation plus précise avec moins d'images d'entraînement. Par exemple U-net est capable de segmenter une image 512 * 512 en moins d'une seconde sur un GPU.

segmentation profonde

X. Conclusion :

Dans ce chapitre, nous avons clarifiés principaux concepts de l'intelligence artificielle. Nous avons parlé des réseaux de neurones, du biologique à l'artificiel en passant par le formel. Nous avons définie domaine d'apprentissage automatique en survolant ses techniques.

Ensuite, nous avons passé à l'apprentissage profond qui est la tendance de l'Intelligence Artificielle ces dernière années et qui fourni des algorithmes puissants notamment dans le domaine médical, raison pour laquelle nous avons illustré ses domaines d'application.

Ensuite, nous avons détaillé la structure générale d'un réseau CNN qui est l'architecture de base de l'apprentissage profond et nous sommes concentrés sur la manière d'ajustement des hyperparamètres de ce dernier. A la fin, nous avons défini l'interprétation des images médicales qui englobe trois tâches essentielle (Classification, détection, segmentation) où nous avons analysé quelques architectures connues en classification, en détection des objets et en segmentation accompagné d'un état de l'art de ces dernières.

CHAPITRE III

Modèle proposé pour la détection des défauts mécanique des roulements

III-1-Introduction

Dans les algorithmes traditionnels de machine Learning, la notion de features (caractéristiques) en vision sont utilisées pour faire de la classification d'images. Ces méthodes consistent à extraire les features de chaque image du jeu de données manuellement par un expert, puis à entraîner un classifieur sur ces features. Ces techniques d'apprentissage supervisé peuvent fournir de très bons résultats, et leur performance dépend fortement de la qualité des features préalablement trouvées.

III-2- Modèle proposé :

La figure suivante démontre les phases constituant notre modèle proposé :

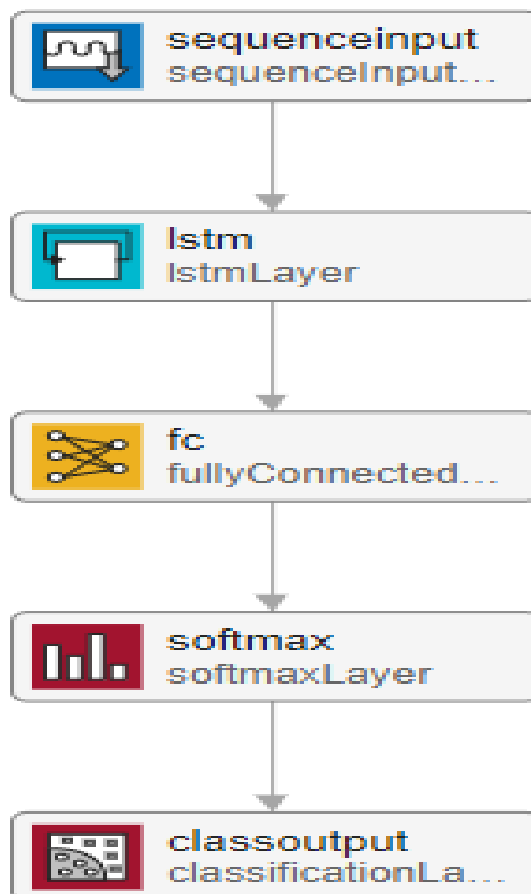


Figure 3-1 : processus d'apprentissage

III-3-Définition CNN

Quelle est la différence entre un réseau de neurones et un réseau de neurones convolutif ?

Les réseaux de neurones convolutifs désignent une sous-catégorie de réseaux de neurones.

Cependant, les CNN sont spécialement conçus pour traiter des images en entrée. Leur architecture est alors plus spécifique : elle est composée de deux blocs principaux.

- 1- Le premier bloc fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un **extracteur de features**. Pour cela, en appliquant des opérations de filtrage par convolution. La première couche filtre l'image avec plusieurs noyaux de convolution, et renvoie des "*feature maps*", qui sont ensuite normalisées (avec une fonction d'activation) et/ou redimensionnées. Ce procédé peut être réitéré plusieurs fois : on filtre les *feature maps* obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles *feature 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.
- 2- Le second bloc : Les valeurs du vecteur en entrée sont transformées (avec plusieurs combinaisons linéaires et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie. Ce dernier vecteur contient autant d'éléments qu'il y a de classes : l'élément i représente la probabilité que l'image appartienne à la classe i

Comme pour les réseaux de neurones ordinaires, les paramètres des couches sont déterminés par rétropropagation du gradient : l'entropie croisée est minimisée lors de la phase d'entraînement. Mais dans le cas des CNN, ces paramètres désignent en particulier les *features* des images. Voir maintenant les différents types de couches d'un CNN.

Il existe quatre types de couches pour un réseau de neurones convolutif : la couche de **convolution**, la couche de **pooling**, la couche de **correction ReLU** et la couche **fully-connected**.

III-4 Description de la base de données utilisée

Nous avons utilisé la base de données *The Case Western Reserve University*[48]. L'équipement d'essai se compose d'un moteur de 2 CV, d'un capteur de couple et d'un dynamomètre, comme le montre la figure suivante :




Figure 3-2. Plateforme expérimentale pour l'acquisition de signaux de vibration à partir de roulements à billes.

Les accéléromètres sont placés de manière à recueillir plusieurs signaux d'accélération pour différents types de défauts. Les roulements utilisés dans ce travail sont des roulements à billes de type SKF 6205. Des défauts de bague intérieure (IR), de bague extérieure (OR) et de bille (BD) sont introduits dans les roulements par usinage par décharge électrique (EDM). Le défaut est un trou circulaire, sa taille est donc définie par son diamètre. Les diamètres des défauts sont de 0,007, 0,014, 0,021 et 0,028 pouces, ce qui correspond respectivement à des défauts naissants, modérés, graves et très graves. Les données du signal de vibration sont collectées sous les charges 0, 1, 2 et 3 hp, correspondant aux vitesses 1797, 1772, 1750 et 1730 tr/min, respectivement, et enregistrées à un taux d'échantillonnage de 12 KHz. Seize classes sont sélectionnées pour chaque charge, chaque classe définissant un état de santé du roulement utilisé dans les expériences, comme décrit dans le tableau suivant. Dans notre travail, nous avons pris les classes 1, 5, 13, 14, 15, et 16.

Class label	Diamètre du défaut(Inch)	Emplacement du défaut
1	0	None
2	0.007	Outer race (at 6:00)
3	0.014	Outer race (at 6:00)
4	0.021	Outer race (at 6:00)
5	0.007	Inner race
6	0.014	Inner race
7	0.021	Inner race
8	0.007	Ball
9	0.014	Ball
10	0.021	Ball
11	0.007	Outer race (at 3:00)
12	0.007	Outer race (at 12:00)
13	0.021	Outer race (at 3:00)
14	0.021	Outer race (at 12:00)
15	0.028	Inner race
16	0.028	Ball

Tableau 3-1 : Ensemble de données sur les défauts de roulements

III-5-La couche LSTM :

C'est l'acronyme de Long et Short time Memory, LSTM est utile pour l'apprentissage machine en profondeur. Dans LSTM, vous trouverez la connexion du retour d'information. LSTM peut traiter aussi bien des données isolées qu'une séquence, comme une vidéo complète. Cette application est destinée à la reconnaissance vocale et à la reconnaissance de l'écriture manuscrite. Elle permet d'éviter les problèmes liés à une dépendance à long terme. Leur utilisation la plus courante consiste à développer le processus d'apprentissage de problèmes énormes.

La mémoire à court et long terme est également un réseau neuronal récurrent, mais il est différent des autres réseaux. Les autres réseaux répètent le module chaque fois que l'entrée reçoit de nouvelles informations. Cependant, le LSTM se souvient du problème pendant plus longtemps et possède une structure en chaîne pour répéter le module. Ils interagissent selon une méthode spéciale et contiennent quatre couches de réseau neuronal.

III-6-Fonctionnement de LSTM

Le processus de transfert des données est le même que celui des réseaux neuronaux récurrents standard. Cependant, l'opération de propagation de l'information est différente. Lorsque l'information passe à travers, l'opération décide quelle information doit être traitée plus avant et de quelle information elle doit se défaire. L'opération principale consiste en des cellules et des portes. L'état de la cellule fonctionne comme une voie de transfert de l'information. Vous pouvez considérer les cellules comme une mémoire.

III-7-Les portes LSTM

Il existe plusieurs portes dans le processus LSTM. Lorsque l'état de la cellule est porteur de l'information, ces portes aident le nouveau flux d'information. Les portes indiquent les données qu'il est utile de conserver et celles qui ne le sont pas, ce qui permet de les jeter. Ainsi, seules les données pertinentes passent par la chaîne de séquence pour faciliter la prédiction. Les portes contiennent diverses activations appelées sigmoïdes, qui contiennent certaines valeurs. Ces valeurs vont de zéros à un. Ces valeurs aident à oublier et à conserver les informations. Si les données se multiplient par un, leur valeur reste la même. Par contre, si les données se multiplient par zéro, la valeur devient zéro et disparaît. Il existe trois types de portes :

1-Porte d'oubli

La première porte que nous comprendrons est la porte de l'oubli. La fonction de cette porte est de décider de garder ou d'oublier l'information. Seules les informations provenant de couches précédemment cachées et l'entrée actuelle restent avec la fonction sigmoïde. Toute valeur plus proche de un restera, et toute valeur plus proche de zéro disparaîtra.

2-Porte d'entrée

La porte d'entrée aide à mettre à jour l'état de la cellule. L'entrée actuelle et les informations sur l'état précédent passent par la fonction sigmoïde, qui actualise la valeur en la multipliant par zéro et un. De même, pour la régulation du réseau, les données passent également par la fonction tanh. Maintenant, la sortie de sigmoïde se multiplie par la sortie de tanh. La sortie de sigmoïde identifiera les informations précieuses à retenir de la sortie de tanh.

3-État de la cellule

Maintenant, les informations dont nous disposons nous aideront à calculer l'état de la cellule. La valeur de l'état de la cellule peut baisser si la valeur multipliée est proche de zéro après avoir multiplié le vecteur d'oubli et l'état de la cellule précédent. Maintenant, nous pouvons trouver le nouvel état de la cellule en ajoutant la sortie de la porte d'entrée point par point.

4-Porte de sortie

Le prochain état caché est défini dans la porte de sortie. Pour trouver les informations de l'état caché, nous devons multiplier la sortie sigmoïde par la sortie tanh. Vous pouvez prédire les informations suivantes à partir d'un état caché. Maintenant, le nouvel état caché et le nouvel état de la cellule passeront à l'étape suivante.

III-8-La couche entièrement connectée (Fully connected layer)

Appelée aussi couche dense ou affinée Couche d'un réseau neuronal artificiel dans laquelle tous les nœuds contenus se connectent à tous les nœuds de la couche suivante. Les couches entièrement connectées sont couramment utilisées dans les réseaux de neurones convolutifs CNN et les réseaux de neurones récurrents. Ces couches sont placées en fin d'architecture de CNN et sont entièrement connectées à tous les neurones de sorties (d'où le terme fully-connected). Après avoir reçu un vecteur en entrée, la couche FC applique successivement une combinaison linéaire puis une fonction d'activation dans le but final de classifier l'input image (voir schéma suivant). Elle renvoie enfin en sortie un vecteur de taille d correspondant au nombre de classes dans lequel chaque composante représente la probabilité pour l'input image d'appartenir à une classe.

III-8-La fonction softmax :

En mathématiques, la fonction softmax, ou fonction exponentielle normalisée, est une généralisation de la fonction logistique qui prend en entrée un vecteur

En théorie des probabilités, la sortie de la fonction softmax peut être utilisée pour représenter une loi catégorielle – c'est-à-dire une loi de probabilité sur K différents résultats possibles.

1-A quoi sert la fonction Softmax ?

La fonction mathématique softmax peut être utilisée en machine learning pour convertir un score en probabilité dans un contexte de classification multi-classe.

Ainsi, si dans un contexte de classification d'objets nous obtenons :

- Un score de 1200 pour la probabilité que l'objet soit une pomme.
- Un score de 600 pour la probabilité que l'objet soit une orange.
- Un score de 200 pour la probabilité que l'objet soit une poire.
- Un score nul pour les autres probabilités.

L'application de la fonction softmax permettra de générer un score de probabilité normalisé, dont la somme totale des probabilités sera égale à 100%, soit 1.

Les résultats de la fonction softmax nous donneront :

- pomme: 0.6
- orange : 0.3
- poire : 0.1

La fonction d'activation softmax est un élément important dans la conception d'un réseau de neurones. A l'origine, la fonction d'activation a pour rôle de casser la linéarité entre deux couches successives et de remettre les valeurs d'une couche dans un intervalle donné. Le second cas d'usage concerne davantage la fonction softmax, car le cadre d'utilisation de cette fonction est celui du problème de classification multi-classe.

Nous pouvons également revenir aux origines du nom de softmax. Il s'agit en réalité d'une approximation de la fonction Argmax en une fonction lisse. Plus précisément, softmax est une approximation dérivable de la version One-Hot-Encoded de Argmax, autrement dit, la fonction softmax permet de calculer Argmax de manière "soft".

La fonction softmax est également connue pour être utilisée dans diverses méthodes de classification en classes multiples, par exemple dans le cas de réseaux de neurones artificiels.

III-9 -Conclusion :

Dans ce chapitre, nous avons présenté notre modèle LSTM pour la détection des défauts mécaniques des roulements. Nous avons discuté en détail de l'architecture et du fonctionnement de notre modèle, mettant en évidence ses capacités à identifier et classifier les différents types de défauts. Dans le prochain chapitre, nous allons mettre en avant les résultats obtenus grâce à notre modèle. Nous présenterons les performances de notre approche de détection des défauts mécaniques, en examinant les métriques de précision, de rappel et de F-mesure. De plus, nous comparerons nos résultats avec d'autres méthodes existantes dans la littérature, afin de démontrer l'efficacité et l'efficacité de notre modèle.

Nous détaillerons également les cas d'étude utilisés pour évaluer notre modèle, en décrivant les caractéristiques des jeux de données et en fournissant des exemples concrets des défauts détectés. Ces résultats seront accompagnés d'une analyse approfondie et d'une interprétation des performances de notre modèle

CHAPITR IV

Résultats et discussions

I-Introduction :

Dans ce chapitre nous allons présenter nos résultats expérimentaux ont une fonction de réglementation visant à garantir la qualité . Dans d'autres ils remplissent une fonction purement didactique et servent de cadre au processus d'enseignements et d'apprentissages

Les résultats de l'apprentissage portent également différents noms .Les termes (compétences) et (résultats de l'apprentissage)

II-Interface d'apprentissage :

Le tableau suivant résume les présentations de notre système proposé :

Paramètre	Valeur
miniBatchSize	150
Fréquence de validation	50
Learning Rate	0.001
Nombre d'Epochs	100
Option d'apprentissage	adam
Données pour apprentissage	70%
Données pour validation	10%
Données pour test	20%

4-1Tableau Paramètres du système

Dans la figure suivante, nous allons illustrer notre interface d'apprentissage et de décision. Nos expériences ont été mené à travers le langage de programmation Matlab sous un PC de type GPU de RAM 8 Go.

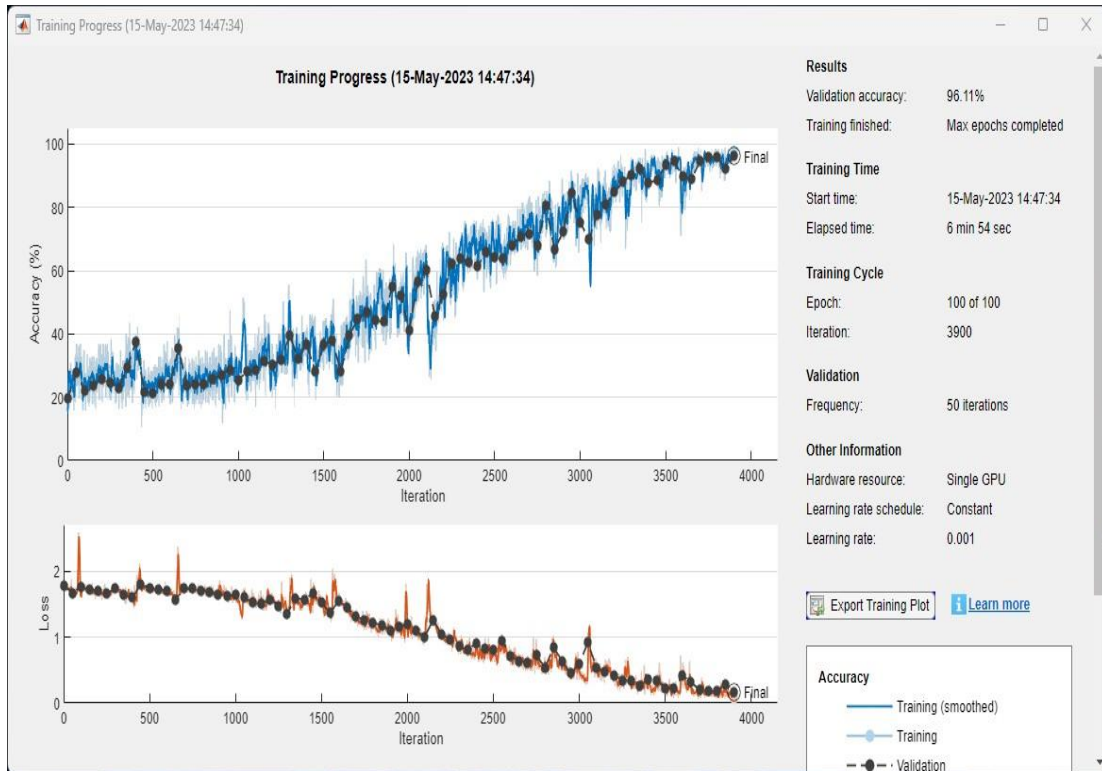


Figure 4-1 interface d'apprentissage et de décision

La figure suivante présente notre matrice de confusion obtenue. Cette matrice nous permet de connaître les interactions entre les classes de notre base de données




Figure
Figure
4-1

interface d'apprentissage et de décision

Matrice de Figure 4-2 confusion de notre système

III-Analyse des résultats obtenus :

Les résultats de cette étude sont particulièrement prometteurs, avec une précision de 96,11 % dans la détection des défauts de roulement. Cette précision élevée démontre l'efficacité de l'approche basée sur les réseaux LSTM pour cette tâche critique.

La haute précision obtenue indique que le modèle LSTM est capable de reconnaître et de distinguer les signatures vibratoires spécifiques associées aux différents types de défauts de roulement. Cela permet aux opérateurs de détecter rapidement les anomalies et de prendre les mesures nécessaires pour prévenir les défaillances potentielles, réduisant ainsi les temps d'arrêt coûteux et les réparations onéreuses.

Une précision de 96,11 % signifie que seulement environ 3,89 % des défauts de roulement passeraient inaperçus. Bien que cela représente une précision élevée, il est important de noter que l'objectif ultime est d'améliorer continuellement cette précision en utilisant des ensembles de données plus larges et plus diversifiés, ainsi qu'en affinant les paramètres du modèle.

Il convient également de mentionner que la précision n'est qu'un aspect de l'évaluation des performances d'un modèle de détection des défauts de roulement. D'autres mesures, telles que le rappel (capacité à détecter les véritables défauts) et la précision moyenne (capacité à éviter les faux positifs), doivent également être prises en compte pour avoir une vue d'ensemble plus complète des performances du modèle.

En outre, il est important de noter que la précision de 96,11 % peut varier en fonction des conditions de fonctionnement réelles, des types de machines et des environnements industriels spécifiques. Des tests supplémentaires sur une plus grande variété de cas d'utilisation et de scénarios réels sont nécessaires pour valider davantage la robustesse et la généralisation du modèle LSTM dans différents contextes.

IV-Conclusion :

En conclusion, les résultats obtenus avec une précision de 96,11 % dans la détection des défauts de roulement grâce à l'utilisation de LSTM sont très encourageants. Cette approche offre de nombreux avantages, tels que la capacité à apprendre des motifs complexes et à traiter des séquences de longue durée. Cependant, des recherches continues et des tests supplémentaires sont nécessaires pour affiner le modèle, améliorer sa précision dans diverses conditions réelles et favoriser son adoption plus large dans l'industrie.

Conclusion générale :

Ce mémoire a exploré l'utilisation des réseaux de neurones récurrents à mémoire à court terme (LSTM) pour la détection des défauts de roulement avec une précision impressionnante de 96,11 %. Les résultats obtenus démontrent l'efficacité de cette approche dans la reconnaissance des signatures vibratoires spécifiques associées aux différents types de défauts de roulement.

L'utilisation de LSTM présente plusieurs avantages significatifs, tels que la capacité à apprendre des motifs complexes et à traiter des séquences de longue durée, ce qui en fait une méthode prometteuse pour la détection précoce des défauts de roulement.

Cependant, il convient de souligner que la précision élevée obtenue n'est qu'une étape dans le développement de techniques de détection des défauts de roulement plus robustes et fiables. Des recherches supplémentaires sont nécessaires pour étendre la validité des résultats dans différents contextes industriels, en prenant en compte des variations dans les conditions de fonctionnement réelles et en évaluant les performances du modèle sur des ensembles de données plus vastes et diversifiés.

Il est également important de continuer à améliorer les méthodes de prétraitement des données, d'optimiser les paramètres du modèle LSTM et d'explorer d'autres architectures de réseaux neuronaux pour une détection plus précise et une meilleure généralisation.

En définitive, l'utilisation de LSTM pour la détection des défauts de roulement ouvre de nouvelles perspectives pour l'industrie en matière de maintenance prédictive et de réduction des temps d'arrêt coûteux. Ce mémoire a mis en évidence les possibilités offertes par cette approche et a jeté les bases pour de futures recherches visant à améliorer la fiabilité et l'efficacité des systèmes de détection des défauts de roulement. En combinant les avancées technologiques avec des ensembles de données plus vastes et des tests sur le terrain, il est possible de faire progresser davantage cette méthodologie et de l'intégrer dans les pratiques industrielles pour une maintenance proactive et une meilleure gestion des actifs.

Bibliographie

1-Starr, A. (1997). A Structured Approach to the Selection of Condition Based Maintenance. 5th International Conference on FACTORY 2000 – The Technology Exploitation Process, Cambridge, UK.

2-Dekhane, A., Djellal, A., Boutebbakh, F., & Lakel, R. (2020, March). Cooling Fan Combined Fault Vibration Analysis Using Convolutional Neural Network Classifier. In *Proceedings of the 3rd International Conference on Networking, Information Systems & Security* (pp. 1-6).

3-Høyland, A. & Rausand, M. (1994). System Reliability Theory – Models and Statistical Methods. USA: John Wiley & Sons, Inc.

4-Bergman, B. & Klefsjö, B. (1996). Tillförlitlighet (In Swedish). Luleå University of Technology, Luleå, Sweden

5-Saliou Diouf « contribution au diagnostic industriel de défauts de roulement et balourd par techniques neuronales » l'université Paris XII Val de Marne-Créteil-2007

6-Saïd, D. (2015). *Etude et optimisation de la transformée en ondelettes pour la détection des défauts dans les roulements* (Doctoral dissertation, University of Souk Ahras).

7-revue mesures 754 avril 2003 « les roulements, des composants à surveille de prés ».

8--SKF : fournisseur de produits et de solutions sur les marchés des roulements, des systèmes de lubrification, de la mécatronique, de l'étanchéité et des services. <http://www.skf.com/>.

9-«Contribution au diagnostic de machines électromécaniques exploitation des signaux électriques et de la vitesse instantanée». Thèse de Doctorat 10 Mars 2009. [Alain Boulenger, Christian Pachaud] «Analyse vibratoire en maintenance».

10-Mahgoun Hafida : « Analyse non stationnaire de signaux vibratoire dans la surveillance des machines et la prévention des défaillances » Thèse de l'université Ferhat Abbas Sétif. 2013.

11-BOUZAOUIT Azzedine « INFLUENCE DE LA VIBRATION SUR LA DUREE DE

12-L.Burhenne, S.Wood, C.S.A.Feig, D.B.Kopans, K. F .O'Shaughnessy, E. A.Sickles, , L. Tabar, C. J.Vyborny, & R.

A. Castellino, "Potential contribution of computer-aided detection to the sensitivity of screening

mammography. *Radiology*”, 215 (2), 554-562. 2000.

13-G. Idiou, thèse de magistère, :« régression et modélisation par les réseaux de neurones », université Mentouri –constantine, 2009.

14-G. Rejala, A. Ravi, S.Churiwala : “An Introduction to Machine Learning”, Springer Nature Switzerland AG, 2019.

15-N.Guerroumi : thèse « Segmentation automatique par apprentissage profond de la colonne vertébrale scoliotique à partir d’images de résonance magnétique », école de technologie supérieure université du Québec, Montréal, 2019.

16-A. L. Samuel: “Some studies in machine learning using the game of checkers. *IBM Journal of research and development*”, 44(1.2): 206–226, 2000.

17-R. S. Michalski, J. G. Carbonell and T. M. Mitchell; “An artificial intelligence approach”, Springer Science & Business Media, 2013.

18-A. Alotaibi, A. Mahmood, “Deep face liveness detection based on nonlinear diffusion using convolution neural network”, Springer-Verlag London, pp.1-8, 2016.

19-R. Bock, J. Meier, L. G. Nyúl, J. Hornegger, G. Michelson: “Glaucoma risk index: Automated glaucoma detection from color fundus images”, *Medical Image Analysis*, vol. 14 ,pp. 471–481, 2010

20- H. Pratta, F. Coenenb, D. M Broadbentc, S.P Hardinga and Y. Zhenga , “Convolutional Neural Networks for Diabetic Retinopathy, ”, Elsevier PCS (MIUA), United Kingdom, vol.90, pp.200-205, 2016.

21-D. Doshi, A. Shenoy, D. Sidhpura and P. Gharpure, “ Diabetic Retinopathy Detection using Deep Convolutional Neural Networks, ” *IEEE CAST. India*, pp.261-266, 2016.

22-K. Xu , D. Feng, and H. Mi, “Deep Convolutional Neural Network-Based Early Automated Detection of Diabetic Retinopathy Using Fundus Image ”, *Molecules MDPI .J. China*, vol.22 ,pp. 17, 2017

23-R. Touahri, N. Azizi, .N.E. Hammami , M .Aldwairi , F. Benaida: “Automated Breast Tumor Diagnosis Using Local Binary Patterns (LBP) Based on Deep Learning Classification”, 2019 International Conference on Computer and Information Sciences (ICCIS), pp.1-5, 2019.

24-Y. LeCun, L. Bottou, Y. Bengio, P. Haffner: “Gradient-based learning applied to document recognition”, *Proc. IEEE* , vol.86, pp.2278– 2324, 1998.

Y. Le Cun, , B. Boser, J.S. Denker, D. Henderson, R.E .Howard, W. Hubbard , L.D. Jackel, “Handwritten digit recognition with a back propagation network. In: *Advances in Neural Information Processing Systems*”, Morgan Kaufmann Publishers Inc. San Francisco, pp. 396–404, 1990

25-V. Dumoulin, and F. Visin, : “A guide to convolution arithmetic for deep, learning”. preprint arXiv:1603.07285. 2016.

- 26-J.Wu ,: “Introduction to Convolutional Neural Networks”, LAMDA Group National Key Lab for Novel Software Technology, China,vol.1, pp. 1-31. 2017
- 27-J. Heaton : “Deep Learning and Neural Networks”, vol:3, 2015
- 28-I. Goodfellow, Y. Bengio, A. Courville: ‘deep learning’, 2016
- 29-R. O. Duda, P. E. Hart and D. G. Stork: “Pattern classification”. Wiley-interscience, 2000.
- 30-C. Desir, « Classification Automatique d’Images, Application à l’Imagerie du Poumon Profond », université de Rouen, 2013.
- 31-M.M. Jadoon, Q. Zhang, I. U. Haq, S.I Butt, A. Jadoon, “Three-Class Mammogram Classification Based on Descriptive CNN Features”, BioMed Research International, pp.11, 2017.
- 32-M. Rodriguez-Damian, E. Cernadas, A.Formella, and P. Otero: “Pollen classification using brightness-based and shape-based descriptors”. In *ICPR (2)*, pp. 212–215, 2004.
- 33-Y.LeCun, B.Boser, J. Denker , D.Henderson, R.Howard, , W. Hubbard, and L. Jackel, “Backpropagation applied to handwritten zip code recognition”, *Neural computation*, vol.4), pp.541–551, 1989.
- 34-J. Alkhateeb, thèse de doctorat, «Word Based Off-line Handwritten Arabic Classification and Recognition»,School of Computing, Informatics and Media, University of Bradford, 2010.
- 35-A. Krizhevsky, I. Sutskever et G. E. Hinton : “*Imagenet classification with deep convolutional neural networks*”, In Advances in neural information processing systems, pp. 1097–1105, 2012.
- M. D.Zeiler et R. Fergus : “*Visualizing and understanding convolutional networks*”, In European conference on computer vision Springer, pp. 818–833., 2014
- 36-C. Szegedy, W.Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V.Vanhoucke et A. Rabinovich. : “*Going deeper with convolutions*”, In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1–9, 2015.
- 37-C. Szegedy, V.Vanhoucke, S. Ioffe,J. Shlens et Z.Wojna.: “*Rethinking the inception architecture for computer vision*”, In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 2818–2826, 2016.
- 38-K. He, X. Zhang, S. Ren et J. Sun, “*Deep residual learning for image recognition*”, In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770–778, 2016.
- 39-G. Huang, Z. Liu, L. Van Der Maaten et K. Q Weinberger. "*Densely connected convolutional networks*", In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 4700–4708, 2017.
- 40-R. Girshick, "*Fast r-cnn*. In Proceedings of the IEEE international conference on computer vision", pp.1440–1448, 2015.

J. Redmon, S. Divvala, R. Girshick et A. Farhadi. "*You only look once : Unified, real-time object detection*", In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 779–788, 2016

41-O. Ronneberger, P. Fischer, T. Brox: "U-Net: Convolutional Networks for Biomedical Image Segmentation " ,

Medical Image Computing and Computer-Assisted Intervention – MICCAI, vol.9351, pp.234-241, 2015

42-J. Ni, J. Wu , J. Tong , Z.Chen , J. Zhao,' GC-Net: Global context network for medical image segmentation', Computer Methods and Programs in Biomedicine, pp.1-10, 2019.

43-M.Dash, N.D. Londhe, S. Ghosh, A.Semwal , R. S. Sonawane ,” PsLSNet: Automated psoriasis skin lesion segmentation using modified U-Net-based fully convolutional network”, Biomedical Signal Processing and Control, vol.52, pp. 226–237, 2019.

44-S. Alqazzaz, X. Sun, X. Yang, L. Noke: “Automated brain tumor segmentation on multi-modal MR image using SegNet”, Computational Visual Media, Vol. 5, pp. 209–219, 2019.

45-P. Kumar , P.Nagar, C. Arora , A. Gupta: “U-segnet: fully convolutional neural network based automated brain tissue segmentation tool”, pp.1-5, 2018.

46-M.A. Al-masni, M.A. Al-antari, M.Choi , S.Han , T.Kim: “Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks”, Computer Methods and Programs in Biomedicine , vol.162, pp.221–231, 2018.

47-J.Bullock, C. Cuesta-L´azaro, A. Quera-Bofarull, “XNet: A convolutional neural network (CNN) implementation for medical X-Ray image segmentation suitable for small datasets”, SPIE Medical Imaging, vol. 10953, pp.1-11, 2018.

48-[ref]<https://engineering.case.edu/bearingdatacenter/download-data-file>