

République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieure et de la Recherche Scientifique  
Université Abderrahmane Mira  
Faculté de la Technologie



Département d'Automatique, Télécommunication et d'Electronique

## Projet de Fin d'Etudes

Pour l'obtention du diplôme de Master

Filière : Electronique

Spécialité : Instrumentation

### Thème

Classification des défauts d'un entraînement électrique

Par

les outils de l'intelligence artificielle

**Préparé par :**

- CHENTOUFI Cherif-amazigh
- Mme MENDIL Nedjima épouse SLIMANI Mahmoud

**Encadré par :** Mr TAFININE Farid

**Présidé par :** Mme OUALI

**C-Promoteur :** ARROUL Ben Yamine

**Examiné par :** Mr TIGHZERT

Année universitaire : 2023/2024





## Dédicaces

*Je dédie ce projet de fin d'études à ma mère Sadelli Taklite, pour son amour inconditionnel, son soutien et ses sacrifices constants. À la mémoire de mon père Mendil Salah, qui demeure une source d'inspiration et de force, malgré son absence.*

*À mes frères et sœurs, pour leur encouragement constant et leur présence bienveillante.*

*À ma petite famille, mon mari SLIMANI Mahmoud et mes enfants (Mélissa, Marrissa, Adam et Manissa), merci pour votre patience, votre soutien et compréhension tout au long de ce parcours.*

*À ma grande famille, dont les valeurs et l'affection m'ont toujours guidée.*

*Je tiens également à exprimer ma profonde gratitude à mon binôme, pour son esprit de collaboration et son dévouement sans limite.*

*À mes amis, pour leur soutien moral et leurs encouragements.*

*MENDIL Nedjima épouse SLIMANI Mahmoud*

*Je dédie ce projet de fin d'études à ma famille, dont le soutien inconditionnel et l'amour m'ont toujours donné la force de poursuivre mes études. Un remerciement particulier à mon père, Nacer, et à ma mère, Leila, pour leurs sacrifices et leurs encouragements constants.*

*À mes petites sœurs, Thilleli, étudiante en première année Séance Technologie de l'Ingénierat, et Yara, élève au primaire, qui m'inspirent chaque jour par leur enthousiasme et leur soif de connaissance.*

*Je tiens également à exprimer ma gratitude envers mes amis et compagnons de chambre H404 (erreure), Saber, Mehdi, et Lounis, pour leur camaraderie et leur soutien moral tout au long de ce parcours. Un remerciement spécial à mon camarade Charaf, qui a quitté le territoire national pour le Canada, mais dont l'amitié et les conseils m'accompagnent toujours.*

*Je souhaite aussi exprimer ma profonde reconnaissance à mon binôme, Nadjema, ainsi qu'à mes amis de la section Électronique d'instrumentation : Mohand, Çalim, Fateh, Tahar et Mellissa, pour leur collaboration, leur dévouement et leur soutien tout au long de ce projet et de ces années d'études. Sans eux, ce travail n'aurait pas été le même.*

*Enfin, j'encourage tous les étudiants à ajouter des résumés en langue tamazight pour honorer notre riche héritage culturel. Ay ameggaz, teqqimleqjihen !*

*Merci à tous.*


*CHENTOUFI Cherif-Amazigh*



## Remerciements



- *Nous remercions tout d'abord le Dieu tout puissant de nous avoir guidés sur le chemin sur lequel nous nous trouvons aujourd'hui, et de nous avoir accordé le courage, la détermination et la volonté de mener à bien nos études, ainsi que ce projet.*
  
- *Nous exprimons notre profonde gratitude et remerciement envers :*  
*Notre encadreur, Mr Taffinine Farid, pour son soutien précieux et ses conseils avisés tout au long de ce projet de recherche. Sa patience et son expertise ont été essentielles à la réussite de ce mémoire.*
  
- *Notre co-encadreur pour son aide précieuse et ses conseils avisés.*
- *Les membres du jury pour leur expertise, leur temps et leurs précieux commentaires lors de l'évaluation*
  
- *Nos professeurs, pour leur temps et leur soutien constants dans le domaine. Leur enseignement a été précieux pour la réalisation de ce travail.*
  - *Tout le corps administratif pour leur accueil chaleureux.*
  
- *Notre famille et nos amis pour leur encouragement et leur soutien inestimables.*





# Introduction générale

La machine asynchrone, également connue sous le nom de moteur asynchrone, représente une pièce essentielle dans le domaine des entraînements électriques, jouent un rôle essentiel dans de nombreuses applications industrielles et commerciales en raison de leur efficacité et de leur robustesse. Cependant, comme toute technologie, elles sont sujettes à des défauts qui peuvent compromettre leur performance et leur durabilité. La détection précoce et précise de ces défauts est donc cruciale pour assurer un fonctionnement optimal et sécurisé des équipements.

Notre travail se concentre sur la classification des défauts d'une machine asynchrone en utilisant les techniques avancées de l'intelligence artificielle. Nous aborderons spécifiquement deux types de défauts courants : les défauts rotoriques et les défauts de roulement, en utilisant des méthodes basées sur des données acoustiques.

Le travail est structuré en cinq chapitres, chacun apportant une contribution significative à notre compréhension et à l'application pratique des méthodes étudiées :

Dans le premier chapitre on explore en détail les éléments essentiels constituant les machines asynchrones, ainsi que les défauts courants et leurs origines. Une attention particulière est accordée à l'émission acoustique comme méthode de détection des défauts.

Le deuxième chapitre offre un aperçu global sur l'intelligence artificielle, en mettant en avant les concepts fondamentaux et les techniques utilisées pour la classification des défauts. Il examine également l'évolution des méthodes d'IA et leur application dans le domaine de la maintenance industrielle.

Le troisième chapitre est dédié à l'application des techniques de réseaux de neurones simples et convolutionnels pour classifier les défauts rotoriques et de roulement à partir d'images acoustiques simulées. Chaque méthode est minutieusement analysée et commentée, offrant une évaluation approfondie de leur efficacité et de leur applicabilité.

Dans le quatrième chapitre, nous abordons l'efficacité de la méthode KNN (K-Nearest Neighbours) avec deux approches : le KNN avec un nombre fixe de voisins et le KNN avec recherche en grille. Les résultats obtenus sont comparés et discutés pour déterminer la

méthode la plus adaptée à la classification des défauts dans le contexte des machines asynchrones.

Le dernier chapitre examine l'utilisation des SVM (Support Vector Machine) avec deux approches distinctes : le classifieur One vs One et le classifieur d'images HOG (Histogram of Oriented Gradients). Les performances de chaque approche sont évaluées à travers des simulations détaillées, fournissant des insights précieux pour leur déploiement efficace dans la détection avancée des défauts.


Enfin, on termine notre travail par une conclusion générale et des perspectives.

**I.1 Introduction**

Ce chapitre aborde les machines asynchrones en se concentrant sur leurs défauts et leur détection acoustique. Tout d’abord, nous examinerons les éléments constituant d’une machine asynchrone. Ensuite, nous analyserons ses principaux défauts, qu’ils soient d’ordre mécaniques ou électrique, en explorant leurs origines. Enfin, nous présenterons une méthode de détection des défauts par émission acoustique et expliquerons le processus pour obtenir des images acoustiques.

**I.2 Constitution de la machine asynchrone**

Dans cette partie, on donne quelques précisions sur les éléments de constituant la machine asynchrone (**figure I.1**). Cette description va nous permettre de comprendre de quelle façon le système est réalisé physiquement.



**Figure. I.1 : Vue éclatée d’un moteur asynchrone [1].**

Les machines asynchrones peuvent se décomposer, du point de vue mécanique, en trois parties distinctes [2] :

- **Le stator** : partie fixe de la machine où est connectée l'alimentation électrique ;
- **Le rotor** : partie tournante qui permet de mettre en rotation la charge mécanique ;
- **Les paliers**: partie mécanique qui permet la mise en rotation de l'arbre moteur.



### I.2.1 Stator

Il est constitué d'un enroulement bobiné réparti dans les encoches du circuit magnétique (**figure I.3**). Ce circuit magnétique est constitué d'un empilage de tôles dans lesquelles sont découpées des encoches parallèles à l'axe de la machine [3].



Figure I.3: Vu stator d'une machine asynchrone [4].

### I.2.2 Rotor

Les rotors de machines asynchrones peuvent être de deux types : bobinés (**figure I.4.a**) ou à cage d'écureuil (**figure I.4.b**). Les rotors bobinés sont construits de la même manière que le bobinage statorique (insertion des enroulements dans les encoches rotoriques). Les phases rotoriques sont alors disponibles grâce à un système de bagues balais positionné sur l'arbre de la machine. En ce qui concerne les rotors à cage d'écureuil, les enroulements sont constitués de barres en cuivre pour les gros moteurs ou en aluminium pour les petits moteurs. Ces barres sont court-circuitées à chaque extrémité par deux anneaux dits "de court-circuit", eux aussi fabriqués en cuivre ou en aluminium. On peut distinguer quatre types de rotor : à cage, à double cage, à double encoche et à bague [5].



a. Rotor à cage d'écureuil

b. Rotor bobiné

Figure I.4: Vu rotor d'une machine asynchrone [6].

### **I.2.2.1 Arbre**

C'est un organe de transmission du mouvement de rotation et sert de support au corps du rotor par un ou plusieurs paliers. L'arbre de la machine électrique supporte un circuit magnétique dont le rôle est similaire à celui du circuit magnétique statorique, l'arbre est en acier moulé ou forgé dont les caractéristiques mécaniques sont choisies après avoir déterminé les contraintes maximales qui apparaissent lors des efforts permanents ou accidentels auxquels il est soumis.

### **I.2.2.2 Cage d'écureuil**

La cage est constituée de barres conductrices, régulièrement réparties, court-circuitées à leurs extrémités par deux anneaux conducteurs, le tout forme une cage d'écureuil.

Les rotors à cage présentent, relativement aux rotors bobinés, les avantages suivants :

- Démarrage de la machine sans avoir recours à un rhéostat ;
- Une petite réactance de fuite, donc un meilleur facteur de puissance ;
- Un meilleur rendement, à condition que la résistance de la cage ne soit pas augmentée.

## **I.2.3 Les paliers**

Les paliers ont pour rôle de soutenir le rotor et assurent sa libre rotation. Ils sont constitués de deux composants : les roulements à billes et les flasques.

### **I.2.3.1 Les roulements**

Le roulement à billes est un organe de base dans la machine asynchrone qui joue le rôle d'interface mécanique entre le stator et le rotor. En plus, il représente l'élément de maintien de l'axe de la machine permettant de garantir une bonne rotation du rotor. La majorité des machines électriques utilisent les roulements à billes ou à rouleaux. Le roulement à billes est le plus utilisé dans le monde industriel parce qu'il a le meilleur rapport performance-prix. Le roulement est composé des éléments suivants (**figure. I.5**).

- Deux bagues concentriques en acier, appelées bague intérieure et bague extérieure, comportant des chemins de roulement (surfaces sur lesquelles "roulent" les corps roulants).
- Des corps roulants, billes ou rouleaux généralement en acier, permettant le mouvement des deux bagues avec un frottement minimal.

- Une cage séparant et guidant les corps roulants (en polyamide, tôle acier, laiton ou résine) [7].



Figure. I.5 : Roulement à billes [8].

### I.3 Principe de fonctionnement d'un moteur asynchrone (triphase)

Le moteur asynchrone triphasé est constitué d'une partie fixe le stator, logé dans une carcasse en acier trois enroulements ou bobinage sont raccordés à une plaque à borne permettant le branchement sur le réseau, et d'une partie mobile le rotor qui est soit à cage d'écurie ou de type rotor bobiné.

Ce qui permet au rotor de tourner c'est le principe des champs magnétiques tournant produit par des tensions alternatives. Trois enroulements sont disposés dans le stator à  $120^\circ$  les uns des autres, une fois alimentés trois champs magnétiques indépendants sont créés. Ces champs magnétiques sont déphasés dans le temps de par la nature même du courant triphasé la vitesse du champ magnétique sera toujours supérieure à celle du rotor, les deux vitesses ne peuvent être synchrones d'où le nom de moteur asynchrone. La vitesse d'un moteur en tours par secondes dépend de la fréquence du réseau qui alimente le stator en Hz (50Hz pour l'Europe) et du nombre de pôle du moteur, donc pour faire varier la vitesse d'un moteur il suffit de modifier la fréquence ou le nombre de pôle (**figure I.6**) [9].




Figure I.6 : Principe de fonctionnement d'un moteur asynchrone triphasé [10].

## I.4 Les défauts

### I.4.1 Définition

Un défaut est une déviation de la normalité du fonctionnement du système, de son unité de commande ou de son système d'instrumentation. Les imperfections peuvent se produire de manière aléatoire ou progressive, en raison du vieillissement ou de l'usure. Les imperfections se manifestent dans diverses parties du système.

### I.4.2 Classification des défauts affectant le moteur asynchrone

Bien que les machines asynchrones (à cage d'écureuil) soient réputées robustes, elle peut parfois être affectée par divers défauts. Il est possible que ces défauts soient d'origine électrique ou mécanique. Le défaut peut être causé par un petit problème lors de la fabrication, tout comme une utilisation non conforme de la machine. Parfois, il est également possible d'accuser le milieu dans lequel la machine est employée (milieux corrosifs et/ou chimiques néfastes). [11]

Les défauts de la machine asynchrone peuvent être soit d'origine interne ou externe. La (figure I.7) résume ces origines [12] :

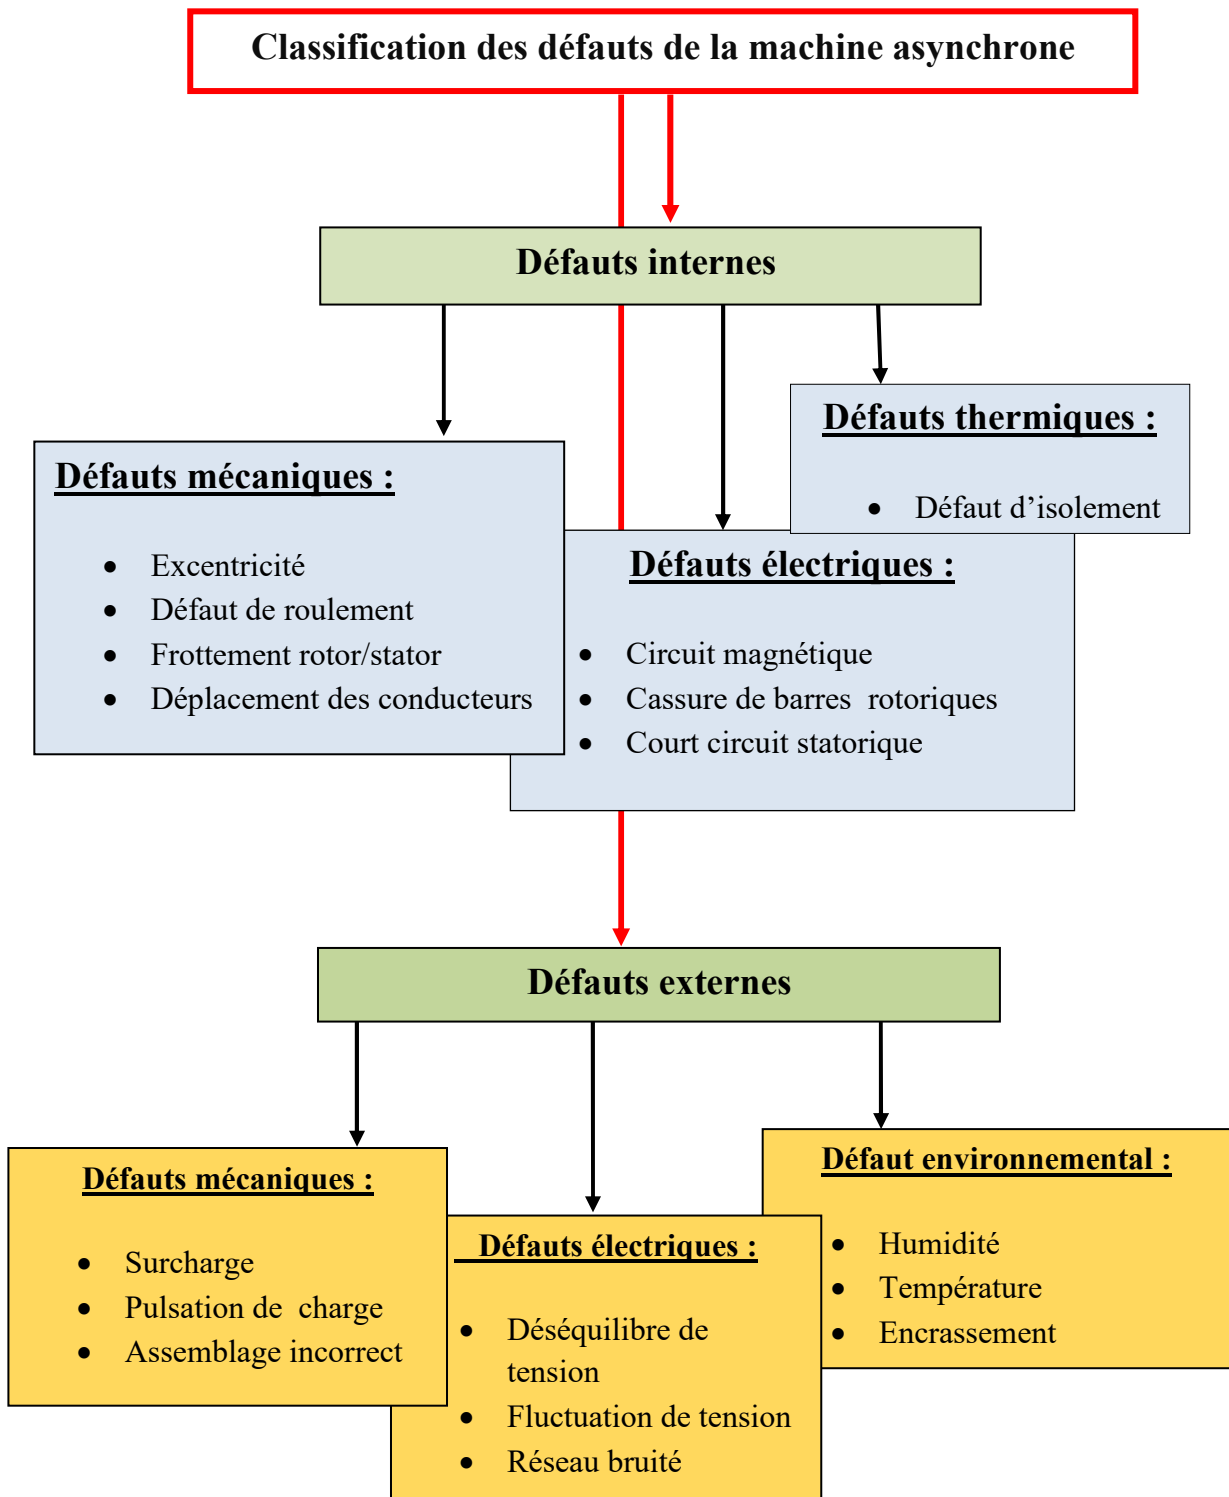


Figure I.7 : Classification des différents défauts affectant le moteur asynchrone [12].

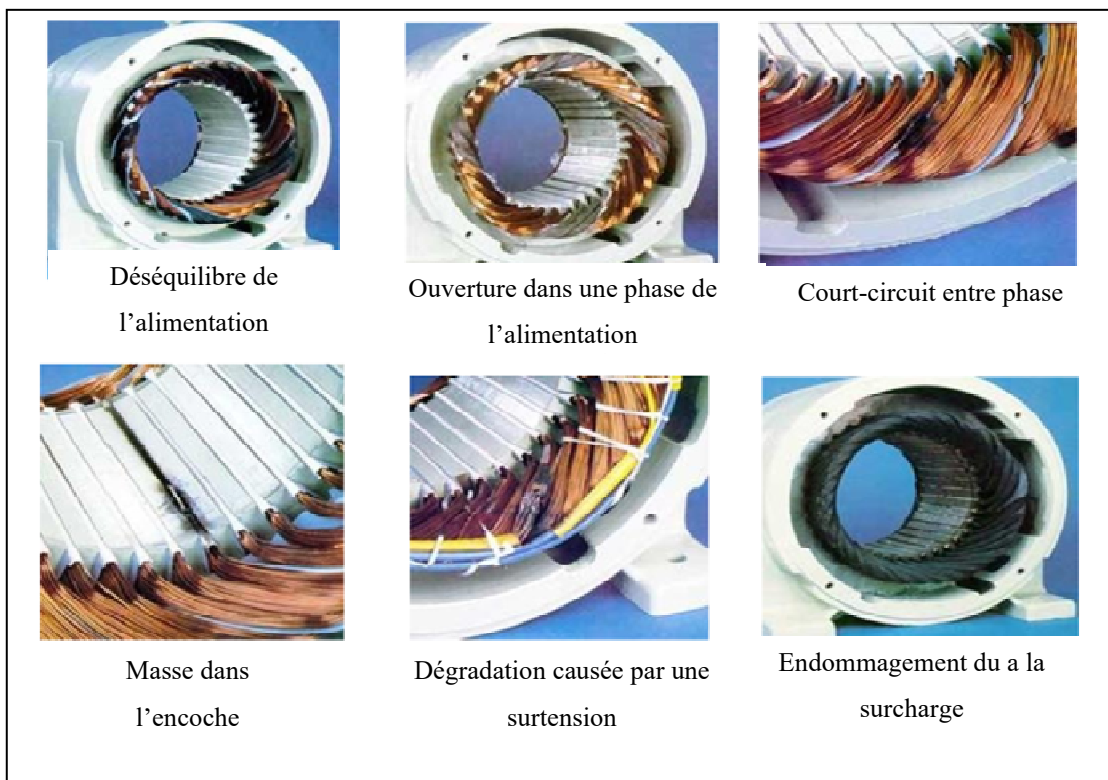
### I.4.2.1 Défaits d'ordre électrique

Les défauts électriques, soit sur le stator, soit sur le rotor, peuvent être de natures différentes ou avoir plusieurs causes différentes.

#### I.4.2.1.1 Défaits statoriques

L'apparition d'un défaut au niveau du stator de la machine asynchrone peut avoir des origines diverses (**Figure I.8**). Nous pouvons citer :


- ✓ Déséquilibre de l'alimentation.
- ✓ Ouverture dans une phase de l'alimentation.
- ✓ Court-circuit entre phase.
- ✓ Masse dans l'encoche.
- ✓ Dégradation causée par une surtension.
- ✓ Endommagement du a la surcharge.



**Figure.I.8 : Différents défauts statoriques de la machine asynchrone [3].**

### I.4.2.1.2 Défaits de rotor

Lorsqu'il s'agit d'un rotor à cage, les problèmes peuvent se limiter aux ruptures des barres ou aux parties d'anneau de court-circuit (**Figure I.9**).



**Figure. I.9.** Défaits des cassures des barres ou à des portions d'anneau de court-circuit [13].

Parmi les causes de ces ruptures de barres ou de bagues en court-circuit, on peut citer une surcharge mécanique (démarrages fréquents), une surchauffe locale excessive, voire un défaut de fabrication (bulles d'air ou soudures de mauvaise qualité). Les courants et le couple électromagnétique seront affectés par ce défaut, d'autant plus que l'inertie est élevée (vitesse constante). Lorsque l'inertie du variateur diminue, il y a des variations dans la vitesse mécanique et les amplitudes du courant vers le stator.

Le défaut de rupture de section d'anneau est aussi courant que les ruptures de barre. Effectivement, ces ruptures peuvent être provoquées par des bulles dans la coulée ou par des dilatations différentes entre les barreaux et les anneaux, d'autant plus que les anneaux de court-circuit sont plus sensibles aux courants que les barreaux du rotor. En raison de cette situation, une dimension incorrecte des bagues, une détérioration des conditions de fonctionnement ou une surcharge de couple, entraînant ainsi une surcharge de courant, peuvent entraîner leur rupture.

Un défaut de rupture de barre ne provoquera pas l'arrêt de la machine car le courant qui parcourt la barre cassée est réparti sur les barres adjacentes. Ainsi, ces barres sont alors surchargées, ce qui peut les casser et un grand nombre de barres cassées provoque un arrêt.

### I.4.2.2 Défaits mécaniques


#### I.4.2.2.1 Défaits de roulement

La principale origine des pannes des machines est liée aux défauts des roulements à billes (**figure I.10**), qui peuvent être causés par différentes causes telles que la contamination du

lubrifiant, une charge excessive, mauvaise : installation, assemblage ou utilisation et entretien. A l'interface entre le rotor et le stator, le roulement à billes présente aussi un vieillissement relativement rapide.

En général, les défauts de roulements provoquent divers effets mécaniques dans les machines, tels qu'une augmentation du bruit et l'émergence de vibrations.

Les défauts de roulements ont également été démontrés comme entraînant des fluctuations dans le couple de charge de la machine asynchrone.



**Figure .I.10 Différentes défaillances des roulements à billes [14].**

#### **I.4.2.2.2 Défauts d'excentricité**

Le décentrement du rotor peut parfois entraîner des oscillations de couple (décalage entre le centre de rotation de l'arbre et le centre du rotor). On désigne ce phénomène sous le nom d'excentricité et peut être causé par un positionnement incorrect des paliers lors de l'assemblage, un problème de roulement (usure), un problème de charge ou un problème de fabrication (usinage). Il existe trois types d'excentricité (**Figure: I.11**) :

- **L'excentricité statique** : est généralement due à un désalignement de l'axe de rotation du rotor par rapport à l'axe du stator ;
- **L'excentricité dynamique** : se manifeste lorsque le centre de rotation du rotor différent du centre géométrique du stator mais, de plus le centre de rotor tourne autour du centre géométrique de ce stator. Ce type d'excentricité est causé par une déformation du cylindre rotorique ou statorique.
- **L'excentricité mixte** : représente la somme des deux cas statique et dynamique [15].






Figure I.11 : Les trois types d'excentricité [16]

## I.5 L'émission acoustique (EA)

### I.5.1 Définition et principe

- L'émission acoustique (AE) est le son émis sous forme d'onde élastique par un solide lorsqu'il est déformé ou frappé. L'utilisation de capteurs AE pour détecter ces ondes élastiques et pour tester de manière non destructive les matériaux est appelée la méthode AE.
- Bien avant la défaillance, de minuscules déformations et de minuscules fissures apparaissent et se propagent dans les matériaux.
- En captant les tendances de l'AE, la méthode AE peut détecter et prévoir les défauts et les défaillances des matériaux et des structures (**Figure I. 12**).

L'EA permet de relever plusieurs phénomènes : la propagation de fissures, la corrosion et les frottements (éléments tournants, les roulements)...etc [17].

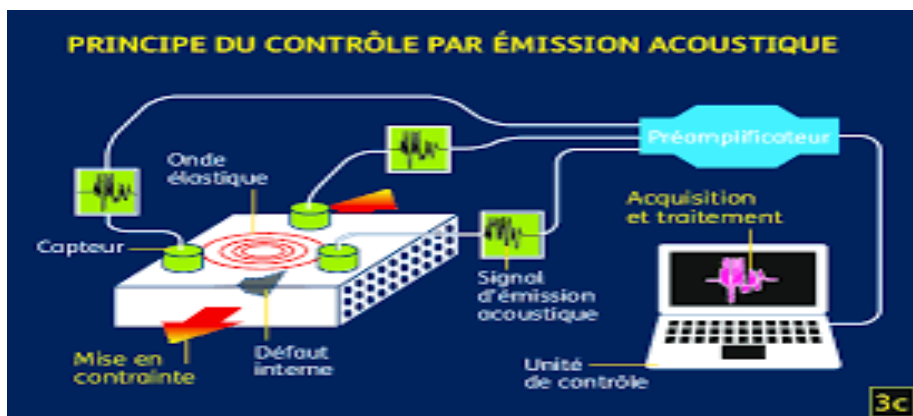


Figure I.12 : Principe du contrôle par émission acoustique [18].

### I.5.2 Les deux types d'émission acoustique

On distingue deux types de signaux d'émission acoustique, l'émission continue et l'émission discrète (**figure I.13**). Ces deux types sont la conséquence des paramètres d'acquisition et correspondent à un choix de l'opérateur.




Figure I. 13 : Représentation d'une émission continue et d'une émission discrète [17].

#### I.5.2.a Emission acoustique continu

Les salves ne peuvent être séparées les unes des autres, ce qui entraîne une **émission continue** ou pseudo-continue (**Figure I. 13.a**). Cette forme de bruit de fond qui englobe le signal émis par le défaut de l'élément contrôlé.

#### I.5.2.b Emission acoustique discontinue

L'émission acoustique est dite discontinue ou discrète (**figure I.13.b**) lorsque les salves peuvent être séparées les unes des autres par observation ou traitement de signal.

- ☞ Ce type d'émission acoustique est observé dans les structures métalliques au delà de la limite élastique [17].

### I.5.3 Caractéristique d'une salve

Emission discrète appelée salve est un signal oscillatoire qui se caractérise par une montée rapide de l'amplitude des oscillations à partir d'un niveau de référence initial. Ce niveau de référence correspond généralement au niveau du bruit de fond. La salve se définit par une décroissance plus lente et qui tend vers le niveau initial (**figure I.14**).

La salve est la plus utilisée en industrie car elle permet de faire apparaître plus facilement les caractéristiques des évènements sans prendre en compte le bruit de fond. Elle est liée à un évènement d'endommagement dans le matériau ou au sein de la machine tournante. Ainsi pour identifier précisément le type d'évènement physique au sein du matériau, il faut analyser les paramètres qui caractérisent la salve.

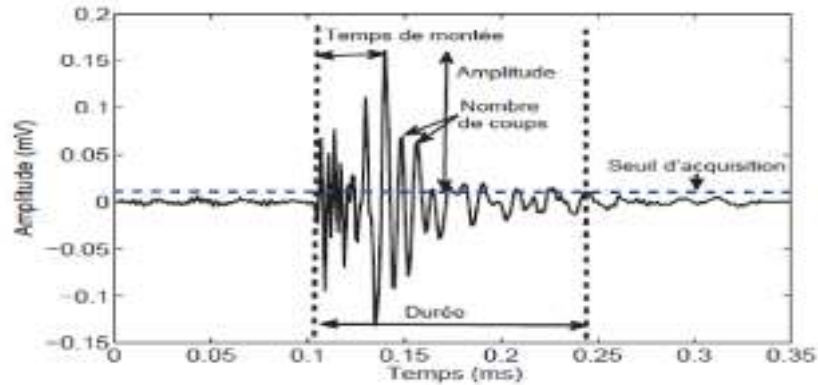


Figure I.14 : Schéma d'une salve [18].

Elle est bornée par la première et dernière arche dépassant le seuil. Les caractéristiques qui permettent de définir un problème sont les suivants :

- ✓ **L'amplitude (mV)** : amplitude maximale du signal pendant la durée de la salve.
- ✓ **L'énergie (E)** : intégrale du carré de l'amplitude de la salve sur toute la durée du signal.
- ✓ **Nombre de coups** : nombre d'alternances dépassant le seuil.
- ✓ **Durée (micro sec)** : temps séparant le premier et le dernier dépassement de seuil dans chaque salve.
- ✓ **Temps de montée (micro sec)** : intervalle de temps entre le premier dépassement de seuil et l'instant où l'amplitude est atteinte.
- ✓ **Fréquence moyenne (kHz)** : nombre de coups de la salve divisé par la durée [19].

## I.6 Le capteur acoustique

### I.6.1 Définition et Principe

Un capteur acoustique est un dispositif qui détecte les ondes sonores ou les vibrations acoustiques et les convertit en signaux électriques [20].

Le capteur acoustique est équipé d'un élément sensible aux ondes sonores, souvent appelé transducteur ou microphone. Cet élément peut être un diaphragme ou tout autre composant qui peut vibrer en réponse aux ondes sonores présentes dans l'environnement.

## I.6.2 Les différentes topologies de capteur acoustique


### I.6.2.1 Capteurs de type électromagnétique

#### I.6.2.1.a Le microphone à ruban


Le microphone à ruban convertit une variation de pression sonore en signal électrique par exploitation de la résultante du phénomène d'induction magnétique (loi de Lenz). Il est composé d'un ruban métallique souple situé entre les deux pôles d'un aimant. Le ruban tient lieu à la fois de diaphragme et de bobine. L'oscillation de ce ruban soumis à la pression acoustique génère le signal (**figure I.15.a**).

#### I.6.2.1.b microphone à bobine mobile

Le microphone à bobine mobile (**figure I.15.b**) exploite également le phénomène issu de la loi de Lenz. Dans un capteur de ce type, la membrane est solidaire d'une bobine mobile qui se déplace dans l'entrefer d'un aimant permanent puissant.



a : Schéma d'un microphone à ruban



b : Schéma d'un microphone à bobine mobile

Figure I.15 : Capteurs de type électromagnétique [21].

### I.6.2.2 Capteurs de type piézo-électrique

Dans certains matériaux comme le quartz, une déformation mécanique entraîne la création de charges électriques en surface donc la génération d'une force électromotrice proportionnelle à la déformation mécanique. Lorsqu'une couche de métal est déposée sur ce type de matériau, cela donne la possibilité de mesurer une tension. Ces matériaux sont dits piézoélectriques (**figure I.16**).




Figure I.16 : Schéma de fonctionnement d'un transducteur piézoélectrique [21].

### I.6.2.3 Capteurs de type électrostatique

La capacité d'un condensateur est inversement proportionnelle à la distance entre les armatures ainsi une vibration de la membrane qui modifie cette distance va aussi modifier la capacité d' où l'apparition d'une intensité modulée au bornes du condensateur.

## I.7 Acquisition du signal (Chaîne d'acquisition)

La chaîne d'acquisition (figure I.17) joue un rôle crucial dans toutes les méthodes. Elle offre la possibilité de convertir un phénomène physique (comme la production d'ondes élastiques) en un signal utilisable grâce au capteur. Il s'agit d'améliorer le signal émis en un signal modifié afin de mettre en valeur ses caractéristiques.

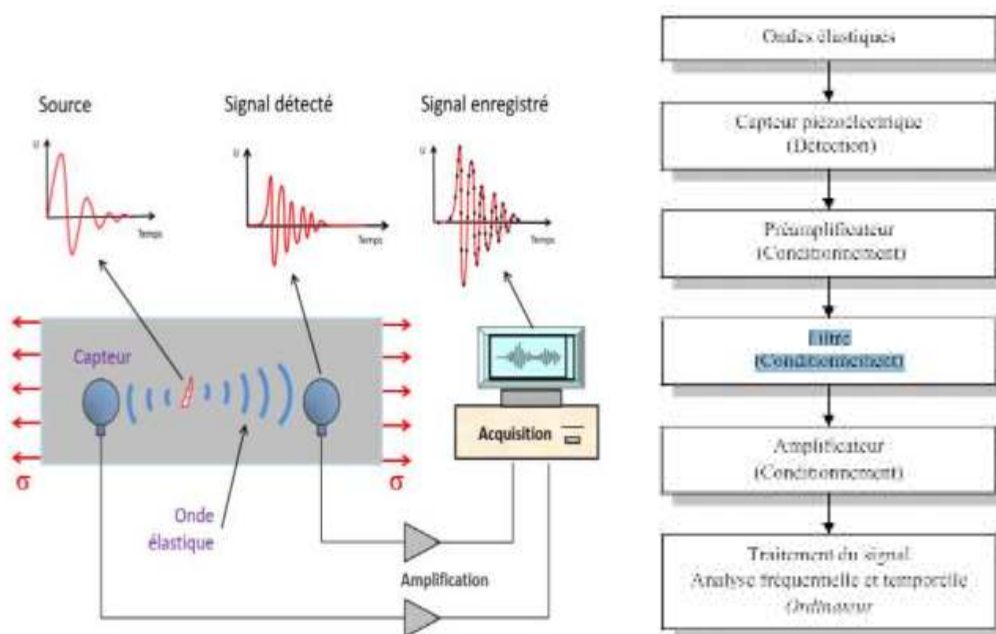


Figure I.17 : La chaîne d'acquisition [22]

La partie conditionnement regroupe le préamplificateur, le filtre et l'amplificateur. Le préamplificateur se trouve à proximité du capteur. Dans certains cas, il peut être intégré au capteur. Son but est d'effectuer une première amplification du signal et de convertir les ondes élastiques en un signal électrique. Le filtre permet d'améliorer le signal relevé en le dissociant du bruit relevé lors de la mesure. Un filtre passe-haut va permettre d'éliminer les bruits de fonctionnement de l'installation sur lesquels une mesure en service est effectuée. L'amplificateur permet de préparer le signal pour qu'il puisse être traité par la suite [17].

## I.8 Convertir les signaux acoustiques en image acoustique

Les images acoustiques sont produites à partir des signaux acoustiques (**figure I.18**) par des techniques de traitement du signal. Voici comment cela fonctionne généralement :

### I.8.1 Traitement du Signal Acoustique

Les signaux acoustiques captés par les capteurs sont traités à l'aide de techniques de traitement du signal telles que la transformée de Fourier, qui permet de décomposer le signal en ses composantes fréquentielles.

### I.8.2 Génération des Images Acoustiques

Une fois que les caractéristiques du signal sont extraites, elles peuvent être utilisées pour générer des représentations visuelles comme les spectrogrammes, qui montrent l'évolution des fréquences au fil du temps. Ces spectrogrammes peuvent être considérés comme des "images acoustiques".

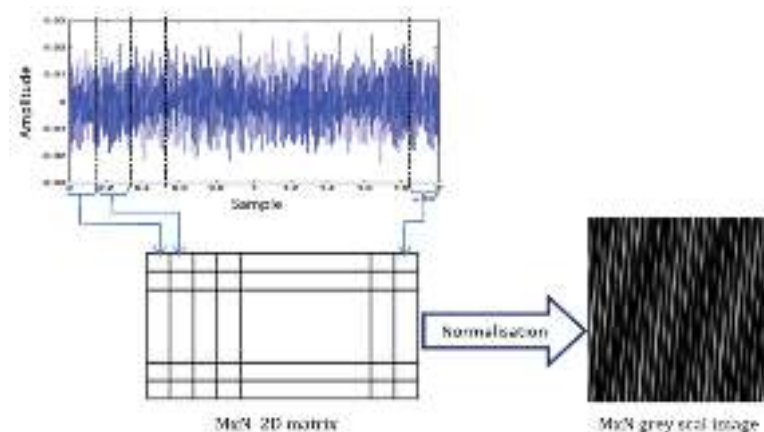


Figure I.18 : Conversion process from 1D acoustic signal to 2D grey-scale image [23].

**I.9 Conclusion**

Dans ce premier chapitre, nous avons abordé quelques rappels concernant la machine asynchrone et les composants qu'elle contient. Nous avons examiné attentivement le stator, le rotor et les roulements en identifiant les principaux défauts fréquemment observés et leurs causes, que ce soit lors de la fabrication ou de l'utilisation. Finalement, une explication a été fournie sur l'une des méthodes employées pour repérer ces défauts, à savoir l'émission acoustique (EA), ainsi qu'une vue d'ensemble des étapes généralement utilisées pour obtenir une image acoustique à partir d'un signal acoustique (sonore).

Une fois que les images acoustiques ont été obtenues, il est possible d'introduire les techniques de l'intelligence artificielle pour une bonne reconnaissance des défauts.

**BIBLIOGRAPHIE**

- [1] : Yagoub Ali & Otmane Houari : Surveillance et diagnostic d'un moteur électrique asynchrone triphasé dans le cadre d'une maintenance conditionnelle, Diplôme de Master, université Ibn Khaldoun de Tiaret, 2020,2021.
- [2] : Gazzam Abdelhak et Safsafa Chouaib : Diagnostic des défauts rotorique des machines asynchrones à cage par différentes techniques de traitement de signal : Mémoire de Master, universite Amar Telidji de Laghouat, 2018.
- [3] : Al-Mushiaa Mohammed Mansoor et Aoukli Zakaria : Technique de diagnostic des défauts dans les systèmes électriques par les réseaux de neurones (machine asynchrone) : Mémoire de Master, université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj, Juin 2022.
- [4] : Boukhari Bylia Amini Taous: Calcul des pertes fers dans la machine asynchrone: Mémoire Master, universite Mouloud mammeri de Tizi-Ouzou,.
- [5] : Bouaoun Oudai Chouia Abdeljalil : Contribution au Diagnostic des défauts de la cassure des barres rotoriques dans les systèmes électromécaniques : Application aux Moteurs à Induction : Master Acadimic , université d'Echahid Mohamed Lakhdar Ammara d'El Oued, 2020.
- [6] : Julien Vaïssette : Moteur asynchrone : tout (vraiment tout) ce que vous devez savoir sur le moteur du futur,2023, [julien@construire-sa-moto-electrique.org](mailto:julien@construire-sa-moto-electrique.org).
- [7] : Yassa Nacera: Détection des défauts dans les systèmes de conversion d'énergie polyphasés, Thèse Doctorat, université Tizi Ouzou, 2018.
- [8] : [www.west-cs.com.br](http://www.west-cs.com.br) . Consulté le 4 Mai 202.
- [9] : <https://www.abcclim.net/moteur-asynchrone-triphase.html>. Consulté le 4 Mai 2024
- [10] : [http: Wiki du BTS Electrotechnique - SA - Principe du moteur asynchrone.sa.ge.sts.free.fr](http://Wiki du BTS Electrotechnique - SA - Principe du moteur asynchrone.sa.ge.sts.free.fr). Consulté le 8Mai 2024.



[11] : Mendaz Kheira : Adaptation des commandes floues et Neuro-floue aux actionnaires asynchrones en mode dégradé : application au transport ferroviaire, Thèse Doctorat, université Djillali Liabes de Sidi-Bel-Abbes.

[12] : Ayad Haroune : Diagnostic des defaillances de la machineasynchrone, Diplôme Master, Université Badji Mokhtar – Annaba, 2020.

[13] : Y. Azzoug, A. Menacer, T.Ameid et H. Cherif : Etude Expérimentale du Diagnostic des Défauts Statoriques et Rotoriques de la Machine à Induction en Boucle Ouverte en utilisant la Transformé de Fourier, Université de Biskra, Algérie.

[14] : Comparaison entre la Technique Vibratoire et la Technique des Courants Statoriques : Application au Diagnostic des Roulements à Billes. <https://www.semanticscholar.org/author/Mohamed-Boudiaf-Koura/2075526242>. Consulté le 15 Mai 2024.

[15] : B. BESSAM : Analyse et détection de défauts dans la machine asynchrone sur la base de techniques intelligentes, Biskra: thèse de Doctorat, Université Mohamed Khidr, 2016.

[16] : Tahar Achour : Diagnostic de défauts électriques et mécaniques de la machine 'asynchrone a simple cage d'ecureuil : Etude expérimentale : Diplôme d'ingénieur, Ecole Nationale Polytechnique, Juin 2008.

[17] : Christophe Migeon : Émission acoustique et analyse vibratoire pour l'étude des défauts de roulements pour différents régimes moteurs. Mécanique [physics.med-ph]. 2011. ffdumas-01157531

[18] : DRIS El Yamine : Algorithmes Adaptatifs Appliqués à la Localisation et au Suivi de l'Evolution des Sources d'Emission Acoustique (EA) : Magister en Electronique(ENP), Ecole Nationale Polytechnique, 2021.

[19] : Hanane Nechad : Evaluation de l'endommagement et de la rupture de matériaux hétérogènes par ultrasons et émission acoustique : Estimation de la durée de vie restante : Thèse de Doctorat, Ecole doctorale Matériaux de Lyon, Juillet 2004.

[20] : Najah Hamamed : Capteurs acoustiques pour la détection de fuites dans les réseaux de distribution d'eau et l'évaluation non destructive des structures : conception, optimisation et étude comparative : Thèse de Doctorat, l'université du Mans, 2023.

[21] : Jacques Jouhaneau : Techniques de l'ingénieur : "Microphones" et "Introduction à l'électroacoustique" par. [https://fr.wikiversity.org/wiki/Capteur/Capteurs\\_acoustiques](https://fr.wikiversity.org/wiki/Capteur/Capteurs_acoustiques).

[22] : Zeina El-Hajj hamam : Simulation numérique et analyse de l'émission acoustique due à la rupture de fibre et à la décohésion à l'interface fibre/matrice dans un microcomposite : Thèse de Doctorat, Université de Lyon, 2020.

[23] : Fatiha Behloul . Farid Taffine . Orhan Yaman : Induction Motor Fault Diagnosis with Local Ternary Pattern and AI Approaches : original research article, 27 September 2023, <https://doi.org/10.1007/s11668-023-01794-6>.

## **II.1 Introduction**

Dans ce chapitre, nous illustrons le domaine fascinant de l'intelligence artificielle (IA). Nous débuterons par explorer son évolution historique et définir ses principes fondamentaux, tout en mettant en évidence ses diverses branches spécialisées. Ensuite, nous étudierons les différents types d'apprentissage ainsi que les différents types de réseaux de neurones connus. Enfin, nous soulignerons l'importance cruciale de l'IA dans la classification des défauts des systèmes d'entraînement électrique, notamment dans le contexte des machines électriques.

## **II.2 L'histoire de l'intelligence artificielle**

L'histoire de l'intelligence artificielle débute en 1943, avec la publication de l'article « A Logical Calculus of Ideas Immanent in Nervous Activity. » par Warren McCulloch et Walter Pitts. Dans ce document, les scientifiques présentent le premier modèle mathématique pour la création d'un réseau de neurones.

En 1950, Snarc, le premier ordinateur à réseau de neurones, sera créé par deux étudiants de Harvard : Marvin Minsky et Dean Edmonds. La même année, Alan Turing publie le Turing Test qui sert encore pour évaluer les IA. De ce test découlent les fondations de l'intelligence artificielle, de sa vision et de ses objectifs : répliquer ou simuler l'intelligence humaine dans les machines.

Mais ce n'est qu'en 1956, que le terme d'intelligence artificielle sera prononcé pour la première fois, durant la conférence « Dartmouth Summer Research Project on Artificial Intelligence. » de John McCarthy. Lors de cet événement, les chercheurs présentent les objectifs et la vision de l'IA. Beaucoup considèrent cette conférence comme la véritable naissance de l'intelligence artificielle telle qu'elle est connue.

Plusieurs années s'écoulent et les travaux sur l'intelligence artificielle continuent. En 1959, Arthur Samuel invente le terme de Machine Learning en travaillant chez IBM. En 1989, le français Yann Lecun met au point le premier réseau de neurones capable de reconnaître des chiffres écrits à la main, cette invention sera à l'origine du développement du deep learning.

Et c'est dix ans plus tard, en 1997, qu'un événement majeur marque l'histoire de l'IA. Le système Deep Blue d'IBM triomphe du champion du monde d'échecs Gary Kasparov. Pour la première fois, la machine a vaincu l'Homme [24].

### II.3 Définition de l'intelligence artificielle (IA)

L'intelligence artificielle est un domaine de l'informatique qui cherche à créer des systèmes capables de réaliser des tâches qui nécessitent normalement l'intelligence humaine à partir d'un ensemble de théories et de techniques mises en œuvre.

### II.4 Machine Learning & Deep Learning

L'Intelligence Artificielle est un domaine très vaste, où les techniques d'apprentissage automatique (ou Machine Learning) en sont une branche. L'apprentissage profond (ou Deep Learning) est quant à lui un sous-ensemble du Machine Learning. **(figure II.1).**

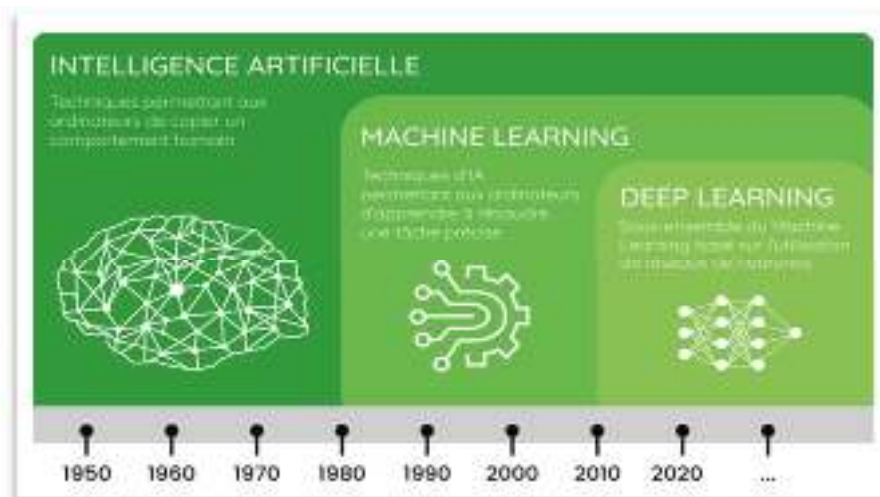


Figure II.1 : L'Intelligence Artificielle et ses branches [25]

#### II.4.1 Machine learning (apprentissage automatique)

C'est une branche de l'intelligence artificielle qui permet aux systèmes d'apprendre et de s'améliorer à partir de l'expérience sans être explicitement programmés pour cela. Il utilise des algorithmes statistiques pour trouver des motifs ou des règles dans des données et les utiliser pour prédire des résultats futurs **(figure II.2).**

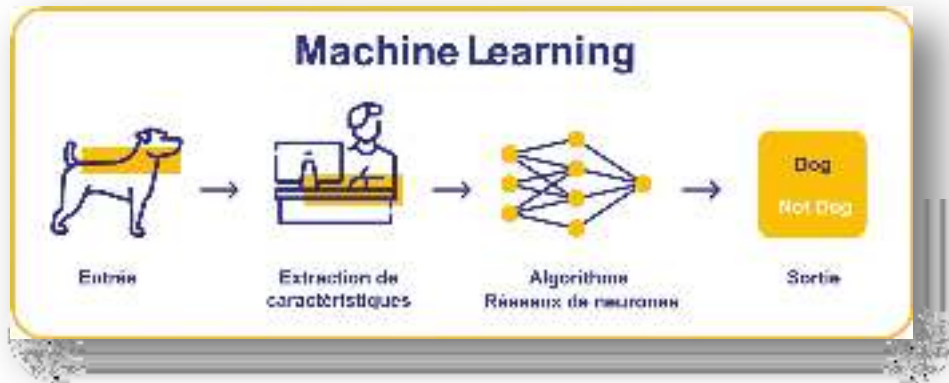


Figure II.2 : Schéma illustre le Machine learning [26].

#### II.4.2 Deep Learning (apprentissage profond)

C'est une sous-catégorie de l'apprentissage automatique (machine learning) qui utilise des réseaux de **neurones artificiels** avec de nombreuses couches, ou "profondes". Ces réseaux sont inspirés par la structure et le fonctionnement du cerveau humain et sont destinés à simuler la manière dont les humains apprennent à partir de grandes quantités de données (**figure II.3**).

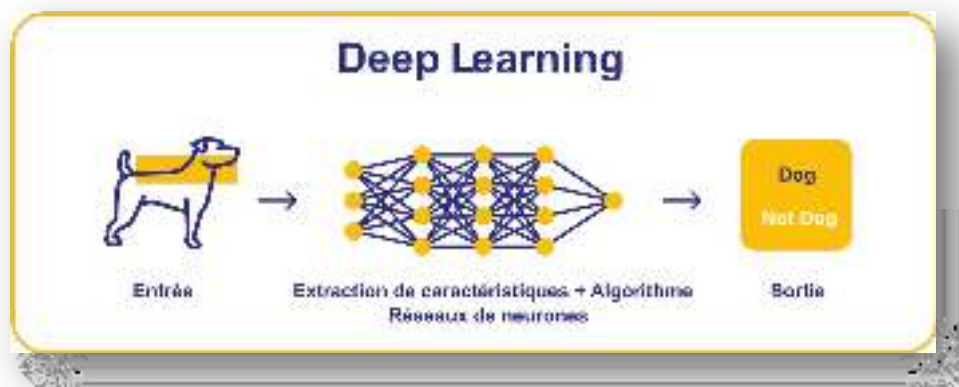


Figure II.3 : Schéma illustre le Deep learning [26].

Ce tableau suivant (**figure II.4**) offre une vue d'ensemble des techniques les plus couramment utilisées dans le machine learning traditionnel et le deep learning. Il est important de noter que ces techniques ne sont pas exclusives les unes des autres et peuvent souvent être combinées pour résoudre des problèmes complexes.

Techniques	Machine Learning	Deep Learning
Régression linéaire	✓	
Régression logistique	✓	
Arbres de décision	✓	
Machines à vecteurs de support (SVM)	✓	
k-plus proches voisins (k-NN)	✓	
Réseaux de neurones		✓
Réseaux neuronaux convolutifs (CNN)		✓
Réseaux de neurones récurrents (RNN)		✓
Réseaux adversariaux génératifs (GAN)		✓
Réseaux de neurones profonds (DNN)		✓

**Tableau II.1 : Techniques couramment utilisées en machine learning et en deep learning :**

## II.5 Apprentissage

Les méthodes d'intelligence artificielle peuvent être appliquées dans le cadre de l'apprentissage supervisé, non supervisé, semi-supervisé ou par renforcement, adaptant leur approche en fonction de la disponibilité et de la nature des données pour répondre au mieux aux exigences spécifiques de chaque tâche.

### II.5.1 Apprentissage Supervisé

Les techniques les plus courantes ici incluent les réseaux de neurones, les machines à vecteurs de support (SVM), les arbres de décision, et les modèles linéaires. Ces méthodes **nécessitent des données étiquetées** pour apprendre à prédire une sortie à partir de nouvelles entrées. Elles sont idéales lorsque vous avez accès à des données bien étiquetées qui définissent clairement les entrées et les sorties souhaitées.

### II.5.2 Apprentissage Non Supervisé

Des techniques comme le clustering (e.g., K-means, DBSCAN), l'analyse en composantes principales (PCA), et les auto-encodeurs tombent généralement sous cette catégorie. Ces méthodes

ne nécessitent pas de données étiquetées et sont utilisées pour trouver des structures ou des patterns dans les données sans supervision externe. Elles sont utiles pour explorer les données, découvrir des groupements naturels, réduire la dimensionnalité, ou identifier des anomalies.


### II.5.3 Apprentissage Semi-supervisé

Certaines méthodes peuvent être adaptées pour utiliser à la fois des données étiquetées et non étiquetées. Par exemple, les auto-encodeurs peuvent être utilisés pour pré-entraîner des réseaux de neurones de manière non supervisée avant de les affiner avec une petite quantité de données étiquetées. D'autres approches, comme les modèles graphiques ou certaines variantes de réseaux de neurones, peuvent également être configurés pour exploiter les avantages des deux types de données.

### II.5.4 Apprentissage par Renforcement

Cette catégorie d'apprentissage est un peu différente et spécifique. Elle implique un agent qui apprend à prendre des décisions en interagissant avec un environnement pour maximiser une certaine notion de récompense cumulée. Les techniques ici sont généralement spécifiques à l'apprentissage par renforcement, comme Q-learning ou les réseaux de neurones profonds utilisés dans les approches comme Deep Q-Networks (DQN).

Limage suivante (**figure II.4**) résume et explique les différents types d'apprentissages :



**Figure II.4 : Schéma résume et explique les différents types d'apprentissage [27].**

#### ☞ Remarque

Pas toutes les méthodes de l'intelligence artificielle (IA) sont intrinsèquement flexibles pour s'adapter aux trois types d'apprentissage (supervisé, non supervisé, et semi-supervisé). Certaines

techniques sont spécifiquement conçues pour l'un ou l'autre. Cependant, de nombreux algorithmes populaires en machine learning peuvent effectivement être adaptés à différentes configurations d'apprentissage en fonction de la disponibilité et de la nature des données.

## II.6 Les réseaux de neurones


### II.6.1 Les Neurones biologiques

Le système nerveux est composé de milliards de cellules : c'est un réseau de neurones biologiques. En effet, les neurones ne sont pas indépendants les uns des autres, ils établissent entre eux des liaisons et forment des réseaux plus ou moins complexes.

Le neurone biologique est composé de trois parties principales (**figure II.5**) :

- **Le corps cellulaire** : Composé du centre de contrôle traitant les informations reçues par les dendrites.
- **Les dendrites** : Sont les principaux fils conducteurs par lesquels transitent l'information venue de l'extérieur.
- **L'axone** : C'est le fil conducteur qui conduit le signal de sortie du corps cellulaire vers d'autres neurones.

**Les synapses** : Elles font effet de liaison et de pondération entre neurones et permettent donc aux neurones de communiquer entre eux.



a) : Représentation schématique d'un neurone biologique

b) : Un neurone avec son arborisation dendritique

Figure II.5 : Schéma d'un neurone biologique [28].

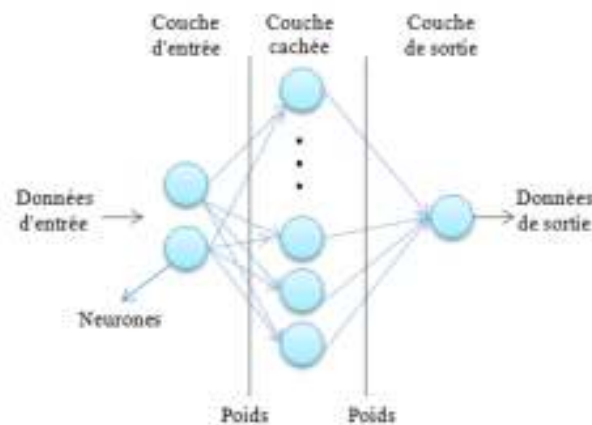


## II.6.2 Les réseaux de neurones artificiels

### II.6.2.1 Définition et constitution

Les réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés (SNN) constituent un sous-ensemble de l'apprentissage automatique et sont au cœur des algorithmes de l'apprentissage en profondeur. Leur nom et leur structure sont inspirés du cerveau humain, imitant la manière dont les neurones biologiques s'envoient des signaux.

Les réseaux de neurones artificiels (ANN) sont constitués de couches nodales, contenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie (**figure II.6**).



**Figure II.6 : Structure de modèle de réseau de neurones artificiels [29].**

### II.6.2.2 Fonctionnement du neurone artificiel

Le neurone artificiel va recevoir plusieurs entrées d'informations, plusieurs valeurs, qui vont être attaché à un poids qui peut être ajusté. Ces entrées correspondent aux dendrites, et les poids qui leurs sont associés, correspondent aux actions excitatrices ou inhibitrices des synapses, ils vont pouvoir amplifier ou minimiser un signal d'entrée. Le neurone dans sa forme basique, va effectuer une somme de l'ensemble de ces variables en fonction de leurs poids, correspondant au soma. Cette valeur passe ensuite par une fonction d'activation, qui en sera l'unique sortie. Celle-ci correspond au point de départ de l'axone qui est le cône d'émergence (**figure II.7**).

Le principe de ces réseaux va donc être d'assembler de grande quantité de neurone entre eux pour former des couches.

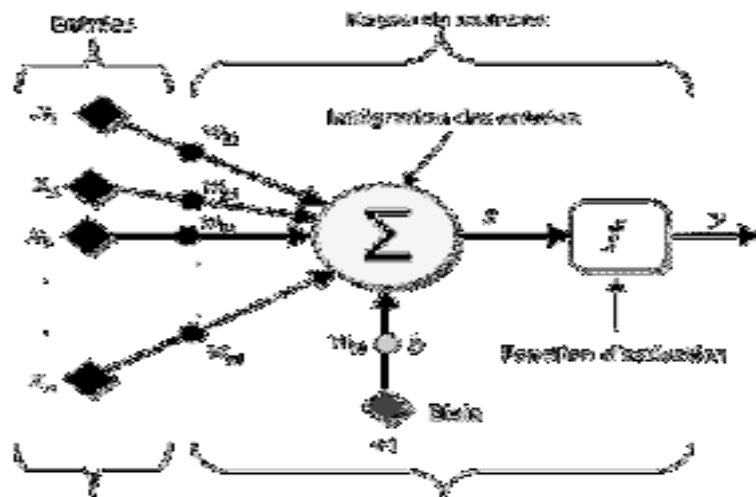


Figure II.7 : Représentation mathématique d'un neurone artificiel [30].

- ✓ Les  $x_i$  : Représentent les vecteurs d'entrées, ils proviennent soit des sorties d'autres neurones, soit de stimuli sensoriels (capteur visuel, sonore...);
- ✓ Les  $w_{ij}$  : Sont les poids synaptiques du neurone  $j$ . Ils correspondent à l'efficacité synaptique dans les neurones biologiques ( $w_{ij} > 0$ : synapse excitatrice;  $w_{ij} < 0$  : synapse inhibitrice). Ces poids pondèrent les entrées et peuvent être modifiés par apprentissage;
- ✓ **Biais** : entrée prend souvent les valeurs -1 ou +1 qui permet d'ajouter de la flexibilité au réseau en permettant de varier le seuil de déclenchement du neurone par l'ajustement des poids et du biais lors de l'apprentissage.
- ✓ **Noyau** : intègre toutes les entrées et le biais et calcul la sortie du neurone selon une fonction d'activation qui est souvent non linéaire pour donner une plus grande flexibilité d'apprentissage [30].

☞ Le neurone artificiel réalise alors trois opérations sur ses entrées :

- ✓ **Pondération** : multiplication de chaque entrée par un paramètre appelé poids de connexion.
- ✓ **Sommation** : une sommation des entrées pondérées est effectuée.
- ✓ **Une fonction de transfert (fonction d'activation)** : génère alors la sortie grâce à ce potentiel. Cette fonction de transfert est très importante, et détermine le fonctionnement du neurone et du réseau.

Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone, les plus utilisées sont les fonctions « seuil » (en anglais « hard limit »), « linéaire » et « sigmoïde » (figure II.8).

Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée. Plus précisément, une entrée négative ne passe pas le seuil, la fonction retourne alors la valeur 0 (on peut interpréter ce 0 comme signifiant faux), alors qu'une entrée positive ou nulle ne dépasse le seuil, et la fonction retourne à 1 (vrai).




Figure II.8. Différents fonction de transfert: (a) du neurone « seuil » : (b) du neurone « Linéaire » et (c) du neurone « sigmoïde » [30].

### II.6.2.3 Représentation mathématique de neurone artificiel

Un neurone  $j$  peut être décrit mathématiquement avec l'équation suivante [31] :

$$y_j^{(i)} = f \left( b_j^{(i)} + \sum_{k=1}^{n_i-1} w_{jk}^{(i)} y_k^{(i-1)} \right) \tag{II.1}$$

Avec :

$f$  : représente la fonction de transfert (fonction d'activation) du neurone  $j$  ;

$i$  : représente la couche cachée.

$y_k^{(i-1)}$ ,  $k = 1, \dots, n_{i-1}$  : représente les signaux d'entrée du neurone  $j$  et  $n$  nombre de neurones dans la couche cachée  $i$  ;

$w_{jk}^{(i)}$  : représente les coefficients de poids de la connexion entre les entrées et le neurone  $j$  ;

$b_j^{(i)}$  : est le biais (seuil) du neurone  $j$ .

L'erreur dans la couche de sortie entre la sortie  $y_s$  et sa valeur désirée ( $y_s - y_{s\text{-désirée}}$ ) est minimisée par l'erreur quadratique moyenne à la couche de sortie, définie comme suit :

$$\text{Erreur} = \frac{1}{2} \sum_{s=1}^R (y_s - y_{s - \text{désirée}})^2 \quad (\text{II.2})$$

Avec :


**R** : nombre de neurones dans la couche de sortie [31].

#### II.6.2.4 Principaux types de réseaux de neurones artificiels

Les réseaux de neurones sont classés en plusieurs types en fonction de leur architecture et de leur façon de traiter les données. Cette classification est basée sur des caractéristiques telles que la présence de connexions récurrentes, l'organisation des couches de neurones, les types de fonctions d'activation utilisées, ainsi que les types de données qu'ils sont capables de traiter efficacement, comme les données séquentielles, spatiales ou temporelles.

##### II.6.2.4. a Réseaux de Neurones Feedforward (FNN)

Les FNN sont les réseaux de neurones les plus simples, où les informations passent dans une seule direction, des neurones d'entrée aux neurones de sortie, sans boucles (**figure II.9**).




**Figure II.9 : Exemples d'architecture de réseaux de neurones FNN [32].**

- **Caractéristiques** : Flux unidirectionnel, absence de cycles.
- **Applications** : Reconnaissance de formes, classification, prévision simple.

### II.6.2.4. b Perceptron Multicouche (MLP)

Les MLP sont une extension des FNN avec une ou plusieurs couches cachées entre l'entrée et la sortie, permettant de modéliser des relations non linéaires (**figure II.10**).



**Figure II.10 : Deux exemples d'architectures de réseaux de neurones MLP [32].**

- **Caractéristiques** : Une ou plusieurs couches cachées, fonctions d'activation non linéaires.
- **Applications** : Reconnaissance de la parole, classification, régression

### II.6.2.4. c Réseaux de Neurones Convolutifs (CNN)

Les CNN sont conçus pour traiter des données structurées en grille, telles que des images, en utilisant des couches de convolution pour extraire des caractéristiques locales (**figure II.11**).




**Figure II.11 : Exemple d'architecture de réseaux de neurones CNN [32].**

- **Caractéristiques** : Convolution, sous-échantillonnage, couches entièrement connectées.
- **Applications** : Vision par ordinateur, classification d'images, détection d'objets.

#### II.6.2.4. d Réseaux de Neurones Récurrents (RNN)

Les RNN sont adaptés au traitement de séquences de données en tenant compte des informations précédentes grâce à des connexions récurrentes (**figure II.12**).



**Figure II.12 : Deux exemples d'architecture de réseaux de neurones RNN [32].**

- **Caractéristiques** : États internes, traitement de séquences.
- **Variantes** : Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU).
- **Applications** : Traduction automatique, analyse de sentiment, reconnaissance vocale.

### II.7 L'importance de l'intelligence artificielle et ses techniques pour le classement des défauts d'un entraînement électrique (machine asynchrone)

L'intelligence artificielle (IA), en particulier les techniques d'apprentissage automatique et profond, joue un rôle crucial dans le classement des défauts d'un entraînement électrique pour plusieurs raisons essentielles :

#### ➤ Détection précoce des défauts

L'IA permet de repérer rapidement les anomalies dans les données de l'entraînement électrique, prévenant ainsi les pannes et les dommages coûteux.

#### ➤ Classification automatisée des défauts

Grâce à l'apprentissage automatique, les défauts peuvent être identifiés et classés rapidement, facilitant une réponse adaptée et efficace.

➤ **Maintenance proactive**

En utilisant des modèles prédictifs, l'IA aide à planifier les interventions de maintenance avant que les défauts ne deviennent critiques, minimisant ainsi les temps d'arrêt.

➤ **Adaptabilité aux changements :**

Les techniques d'IA peuvent s'ajuster aux nouvelles données et aux évolutions des conditions de fonctionnement, maintenant ainsi leur efficacité au fil du temps.

➤ **Amélioration de l'efficacité opérationnelle**

En réduisant les temps d'arrêt et en optimisant les processus de maintenance, l'utilisation de l'IA contribue à une meilleure productivité et à des coûts d'exploitation plus bas.

## **II.8 Conclusion**

Ce chapitre nous a offert un aperçu sur l'intelligence artificielle (IA). Nous avons exploré son évolution historique et défini ses principes fondamentaux, tout en mettant en évidence ses diverses branches spécialisées. Nous avons également examiné en détail les différents types d'apprentissage. Ensuite, nous avons illustré les différents types de réseaux de neurones et leurs architectures variées. Enfin, nous avons souligné l'importance cruciale de l'IA dans la classification des défauts des systèmes d'entraînement électrique, notamment dans le contexte des machines électriques.

## **Bibliographie**

- [24] : <https://datascientest.com/https://datascientest.com/>. Consulté le 25 Mai 2024
- [25] : <https://www.dilepix.com/blog/author/aur%C3%A9lien-yol>. Consulté le 31 Juin 2024.
- [26] : <https://habefast.ch/seo-machine-learning-et-deep-learning/>. Consulté le 31 Juin 2024.
- [27] : <https://hellofuture.orange.com/fr/learning-zoo/>. Consulté le 31 Juin 2024.
- [28] : Nouma Amira & Kanoun Maroua : Diagnostic de la machine asynchrone par l'usage des réseaux de neurones artificiels, Diplôme Master, Université Saad Dahlab de Blida1 ,2021-2022.
- [29] : [https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels\\_fig5\\_322263283](https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels_fig5_322263283).
- [30] : Mr. Mesai Ahmed Hamza Mr. Nadir Kais : Commande de la machine asynchrone à double alimentation – apport des techniques de l'intelligence artificielle : diplôme Master, Université Djillali Liabes de Sidi-Bel-Abbes ,Juin 2017.
- [31] : Raghda Alilouch : Détection, classification et localisation des défauts dans les lignes de transmission par les réseaux de neurones artificiels :Mémoire présenté comme exigence partielle de la maîtrise en ingénierie, université du Québec en Abitibi-Témiscamingue, Novembre 2022.
- [32] : <https://www.google.com/search?q=types+de+reseaux+de+neurones+artificiels>, visité le 15 avril 2024.
- [23] Classification automatique des textes par Les réseaux de neurones à convolution MALKI NARIMENE 2018/2019.
- [24] : Pr. Mustapha BOURAHLA : Chapitre 4 : Réseaux de neurones convolutifs :, Département d'Informatique, Université de M'Sila, Contact : [mustapha.bourahla@univ-msila.dz](mailto:mustapha.bourahla@univ-msila.dz)
- [25] :Djemaa Mahir : Classification des images par CNN : Diplôme de MASTER Académique , Université 8 Mai 1945 – Guelma, 2022/2023
- [26] : support\_de\_cours\_-deep\_learning-chapitre3-cnn.pdf
- [27] : <https://geekflare.com/fr/convolutional-neural-networks/>





### **III.1 Introduction**

Dans ce chapitre, nous explorons les approches neuronales à travers les réseaux de neurones simples et convolutifs, suite à un rappel théorique initial. Nous avons ensuite utilisé des simulations basées sur des images acoustiques représentant les défauts de roulement et les barres rotoriques d'une machine asynchrone. L'analyse des résultats obtenus est suivie de commentaires sur l'efficacité de ces techniques dans la maintenance prédictive industrielle.

### **III.2 Rappel théorique**

Les réseaux de neurones simples (ou perceptrons multicouches) et les réseaux de neurones convolutionnels (CNN) des architectures de réseaux de neurones artificiels, mais ils diffèrent principalement dans leur structure et leur utilisation spécifique.

#### **III.2.1 Réseaux de neurones simples**

Un réseau de neurones artificiel simple, tel qu'un perceptron multicouche (MLP), est composé de plusieurs couches de neurones interconnectées. Il comprend au minimum deux couches : une couche d'entrée pour recevoir les données et une couche de sortie pour produire les prédictions .

#### **III.2.2 Réseaux de neurones convolutionnels (CNN)**

Ils utilisent des couches de convolution pour extraire des caractéristiques spatiales à partir des données d'entrée, typiquement des images. Les CNN sont composés de couches de convolution, de couches de pooling et de couches entièrement connectées à la fin pour la classification ou la régression

##### **III.2.2.1 Fonctionnement des CNN**

Un réseau neuronal convolutif peut disposer de dizaines, voire de centaines de couches qui apprennent chacune à détecter différentes caractéristiques d'une image. Des filtres sont appliqués à chaque image du jeu d'apprentissage avec différentes résolutions, puis la sortie de chaque image convoluée est utilisée comme entrée de la couche suivante [33].

Au début, ces filtres peuvent concerner des caractéristiques très simples, comme la luminosité et les contours, puis se complexifier jusqu'à représenter des caractéristiques uniques propres à l'objet.

### III.2.2.2 Les couche de CNN

Les couches effectuent des opérations pour modifier les données, afin d'en apprendre les caractéristiques spécifiques. Les trois couches les plus courantes sont : la convolution, l'activation (ou ReLU) et le pooling.

#### III.2.2.2.a La couche de convolution (Convolutional Layer)

Elle applique un ensemble de filtres convolutifs aux images en entrée, chacun d'entre eux activant certaines caractéristiques des images.

- ✓ **Filtres (Noyaux):** Petites matrices de poids qui parcourent l'image d'entrée (ou la carte de caractéristiques) pour extraire des caractéristiques locales.
- ✓ **Stride :** Le pas de déplacement des filtres sur l'image. Un stride de 1 signifie que le filtre se déplace d'un pixel à la fois.
- ✓ **Padding :** Ajout de pixels autour de l'image d'entrée pour contrôler la taille des cartes de caractéristiques. Le padding peut être 'valid' (aucun padding) ou 'same' (padding pour conserver la taille d'entrée)

En résumé, la couche de convolution est essentielle dans un CNN. Elle effectue la convolution des images avec des filtres pour extraire des caractéristiques importantes. Les hyper paramètres tels que la profondeur, le pas et la marge jouent un rôle crucial dans la manière dont la convolution est appliquée et dans la dimension du volume de sortie.

1	1	1	3
4	6	4	8
30	0	1	5
0	2	2	4

En commençant par le premier filtre, l'opération de convolution commence au coin supérieur gauche de la matrice de la même taille que le filtre de convolution. L'opération de convolution est la somme des produits des éléments qui sont situées sur les mêmes positions des deux matrices. Le résultat de 7 dans la matrice de résultat est trouvé comme suit:  $(1 \times 1) + (1 \times 0) + (4 \times 0) + (6 \times 1) = 7$

1	1	1	3
4	6	4	8
30	0	1	5
0	2	2	4

 $\times \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} =$ 

7			

Le même processus se répète jusqu'à ce que la carte des caractéristiques du filtre donné soit produite, comme la montre la figure [34] :

$$\begin{array}{|c|c|c|c|} \hline 1 & 1 & 1 & 3 \\ \hline 4 & 6 & 4 & 8 \\ \hline 30 & 0 & 1 & 5 \\ \hline 0 & 2 & 2 & 4 \\ \hline \end{array} * \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{array}{|c|c|c|} \hline 7 & 5 & 9 \\ \hline 4 & 7 & 9 \\ \hline 32 & 2 & 5 \\ \hline \end{array}$$

### II.2.2.2.b La couche ReLU (Rectified linear unit)

Elle favorise un apprentissage plus rapide et plus efficace en remplaçant les valeurs négatives par des zéros et en conservant les valeurs positives. Ce procédé est parfois appelé activation, car seules les caractéristiques activées sont transmises à la couche suivante.

La fonction ReLU ( $f(x) = \max(0, x)$ ), cette fonction (**figure III.1**) force les neurones à retourner des valeurs positives [34].

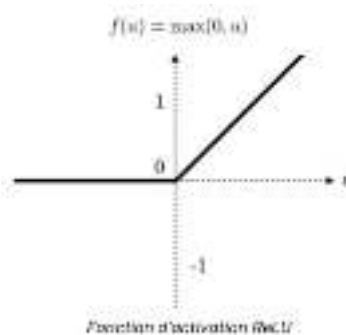


Figure III.1: Fonction d'activation Relu [34].

### II.2.2.2.c Couche de Pooling (Pooling Layer)

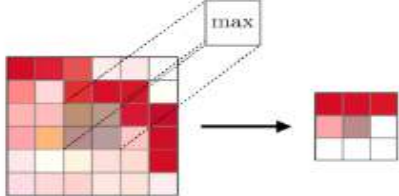
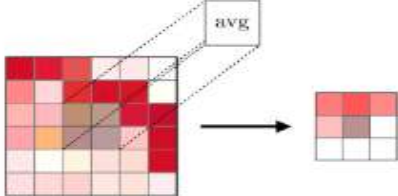
Elle simplifie la sortie en réalisant un sous-échantillonnage non linéaire, ce qui permet de réduire le nombre de paramètres que le réseau doit apprendre [35].

- ✓ **Max Pooling** : Sélectionne la valeur maximale dans chaque sous-région d'une carte de caractéristiques.
- ✓ **Average Pooling** : Calcule la moyenne des valeurs dans chaque sous-région.
- ✓ **Stride et Taille de Pooling** : Définissent la taille de la fenêtre de pooling et le pas de déplacement.

Deux types de regroupement couramment utilisés : le regroupement maximum (max pooling) et le regroupement moyen (average pooling).

Dans le **regroupement maximum**, une fenêtre (généralement de taille 2x2 ou 3x3) glisse sur la carte d'activation générée par la couche convolutive, et la valeur maximale dans chaque fenêtre est sélectionnée pour former une nouvelle carte d'activation réduite. Cela permet de conserver les caractéristiques les plus dominantes tout en réduisant la taille spatiale.

Dans le **regroupement moyen**, la même fenêtre glisse sur la carte d'activation, mais cette fois, la valeur moyenne des activations dans chaque fenêtre est calculée pour former la nouvelle carte d'activation réduite. Cette opération permet de prendre en compte l'information globale de chaque région et de produire une représentation plus lisse. Le regroupement de couches permet donc de réduire la dimension spatiale des caractéristiques tout en conservant les informations les plus importantes. Cela aide à réduire le nombre de paramètres et de calculs nécessaires dans le réseau, tout en introduisant une certaine invariance aux translations dans les données (**figure III.2**) [35].

Type	Max pooling	Average pooling
<b>But</b>	Chaque opération de pooling sélectionne la valeur maximale de la surface	Chaque opération de pooling sélectionne la valeur moyenne de la surface
<b>Illustration</b>		
<b>Commentaires</b>	<ul style="list-style-type: none"> <li>• Garde les caractéristiques détectées</li> <li>• Plus communément utilisé</li> </ul>	<ul style="list-style-type: none"> <li>• Sous-échantillonne la <i>feature map</i></li> <li>• Utilisé dans LeNet</li> </ul>

**Figure III.2: le regroupement (max pooling) et le regroupement moyen (average pooling) [35].**

- ☞ Ces opérations sont répétées sur des dizaines ou des centaines de couches, chaque couche apprenant à identifier différentes caractéristiques.

#### II.2.2.2.d Couche de Normalisation (Normalization Layer)

- ✓ **Batch Normalization** : Normalise les activations en ajustant la moyenne et la variance, stabilisant et accélérant l'entraînement.

- ✓ **Layer Normalization** : Normalise les activations au niveau de chaque couche.
- ✓ **Instance Normalization** : Normalise les activations pour chaque échantillon indépendamment.

#### III.2.2.2.e. Couche Complètement Connectée (Fully Connected Layer)

- ✓ **Dense Layer** : Chaque neurone de cette couche est connecté à tous les neurones de la couche précédente. Cette couche est utilisée pour combiner les caractéristiques extraites et produire une sortie finale.
- ✓ **Fonction d'Activation Softmax** : Utilisée dans la dernière couche pour les tâches de classification, elle convertit les sorties en probabilités.

#### II.2.2.3 Poids et biais partagés

Contrairement aux réseaux de neurones classiques (simple), un réseau neuronal convolutif possède des valeurs de poids et de biais partagées, qui sont identiques pour tous les neurones cachés d'une couche donnée.

Cela signifie que l'ensemble des neurones cachés détectent la même caractéristique (par exemple, un contour ou un blob) dans différentes régions de l'image. Ainsi, le réseau devient tolérant à la translation d'objets dans une image. Par exemple, un réseau entraîné à reconnaître des voitures sera en mesure d'identifier un véhicule, quel que soit son emplacement dans l'image.

#### II.2.3.4 Architecture d'un CNN

Un CNN est organisé en deux parties : l'extraction de l'information et l'analyse de cette information.

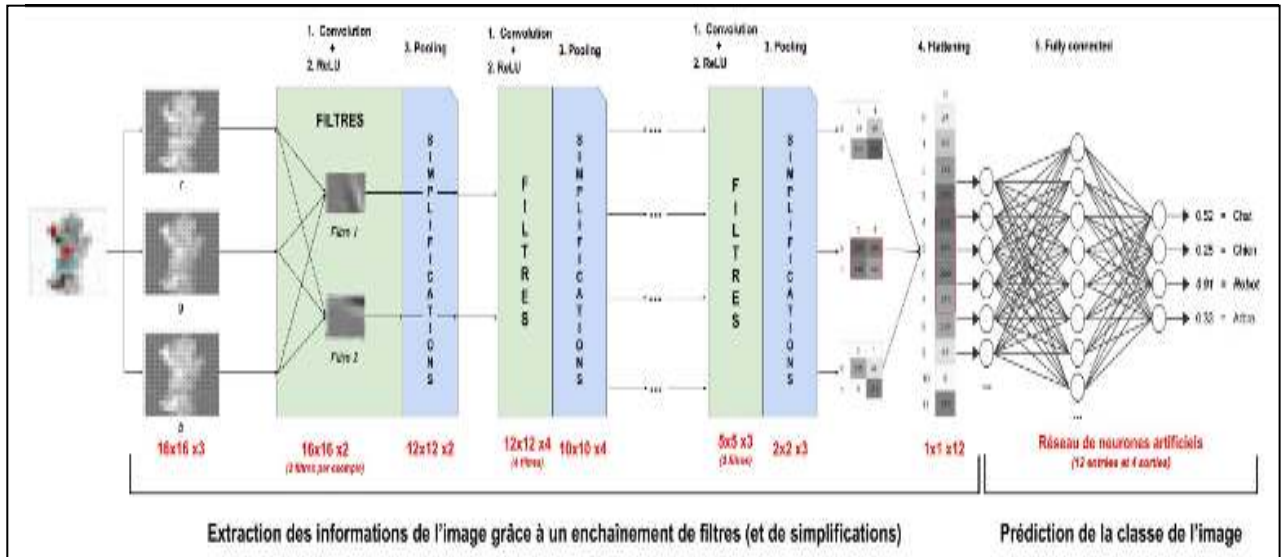


Figure II.3 : Architecture d'un CNN [36].

### III.3 Simulation sur Matlab

#### III.3.1 Approche 1 : Réseaux de Neurone artificiel Simple (RNS)

Le processus est : Prétraitement des images et formation d'un réseau de neurones pour la classification d'images. Les étapes incluent la préparation des données, la conception du réseau de neurones, l'entraînement, et l'analyse des résultats (figure III.4)

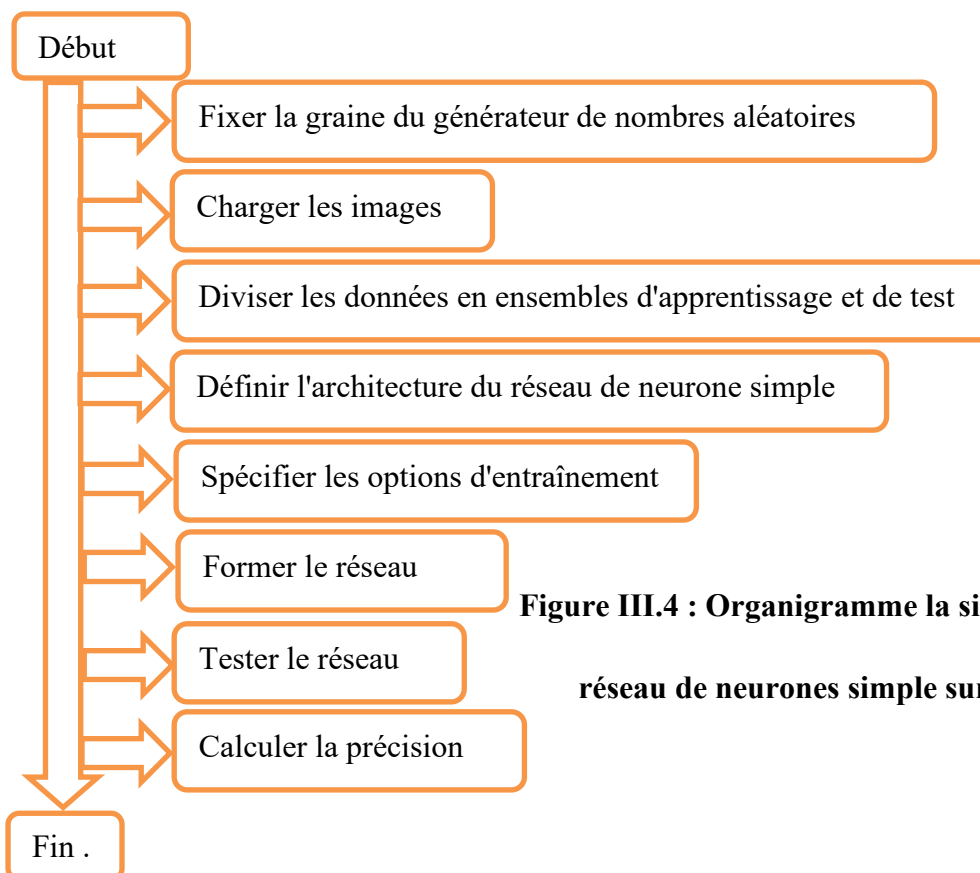


Figure III.4 : Organigramme la simulation du réseau de neurones simple sur MATLAB.

### III.3.1.1 Formation d'un Réseau de Neurons Simple

Notre réseau de neurones artificiel est composé de plusieurs couches organisées de manière séquentielle. La « couche d'entrée » reçoit les images de taille 150x133 en niveaux de gris, ce qui correspond à 19 950 neurones, un pour chaque pixel.

Ensuite, le réseau comporte une « première couche cachée entièrement connectée » avec 400 neurones, où chaque neurone est connecté à tous les pixels de l'image d'entrée. Cette couche est suivie d'une « couche d'activation ReLU » qui maintient le même nombre de neurones et introduit une non-linéarité nécessaire au processus d'apprentissage.

La « deuxième couche cachée », également entièrement connectée, est dimensionnée en fonction du nombre de classes uniques dans l'ensemble de données d'entraînement et sert à la classification.

La « couche softmax » transforme ensuite les scores en probabilités, avec un nombre de neurones équivalent à celui de la couche précédente.

Enfin, la « couche de sortie », ou couche de classification, utilise ces probabilités pour prédire la classe de l'image d'entrée. Le nombre de neurones ici correspond également au nombre de classes.

Chaque couche du réseau joue un rôle spécifique dans le traitement des images et la prédiction des classes, formant ainsi une structure cohérente pour l'analyse d'image.

### III.3.1.2 Les options d'entraînement

Les options d'entraînement du réseau de neurones ont été configurées pour utiliser l'optimiseur 'sgdm' (Stochastic Gradient Descent with Momentum). L'entraînement est prévu pour un maximum de 15 époques, avec un taux d'apprentissage initial fixé à 0.00009. Les données de validation sont fournies par l'ensemble de test `imdsTest`, et la validation est effectuée tous les 15 itérations. L'entraînement est exécuté en mode verbeux, ce qui permet de suivre en détail le processus d'apprentissage. Enfin, les progrès de l'entraînement sont visualisés grâce à l'option 'Plots' (**figure III.5**), qui est définie sur 'training-progress' (**tableau III.1**).



Epoque	Iteration	Time Elapsed (hh:mm:ss)	Précision de l'apprentissage	Précision de validation	Pert de l'apprentissage	Pert de validation
1	1	00 :00 :01	22.66%	22.66%	11.6828	10.6283
8	15	00 :00 :24	99.22%	80.00%	0.1246	3.1885
15	30	00 :00 :37	99.22%	86.67%	0.1246	2.1257

Tableau III.1 : Tableau de Progression d'Apprentissages de RNS.

### III.3.1.2.1 Analyse de tableau

- Époque : Le nombre total d'époques est de 15, ce qui signifie que l'ensemble d'apprentissage a été parcouru 15 fois.
- Précision d'entraînements: La précision du mini-lot atteint 99,22% à la 8ème époque, ce qui indique que le modèle s'est bien comporté sur les données d'entraînement.
- Précision de la validation : La précision de la validation atteint 86,67% à la 15ème époque. C'est la capacité du modèle à bien généraliser sur de nouvelles données.
- Perte d'entraînements : La perte du mini-lot diminue à chaque époque, ce qui est un bon signe que le modèle apprend correctement.
- Perte de validation : La perte de validation est relativement stable après la 15ème époque, ce qui pourrait indiquer que le modèle a atteint sa meilleure performance sur l'ensemble de validation.

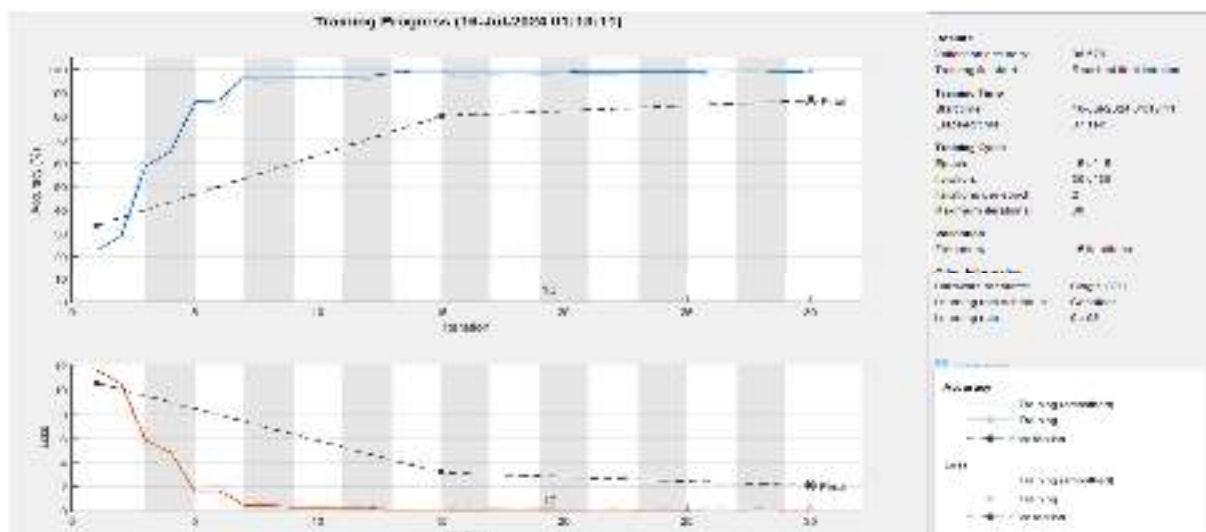


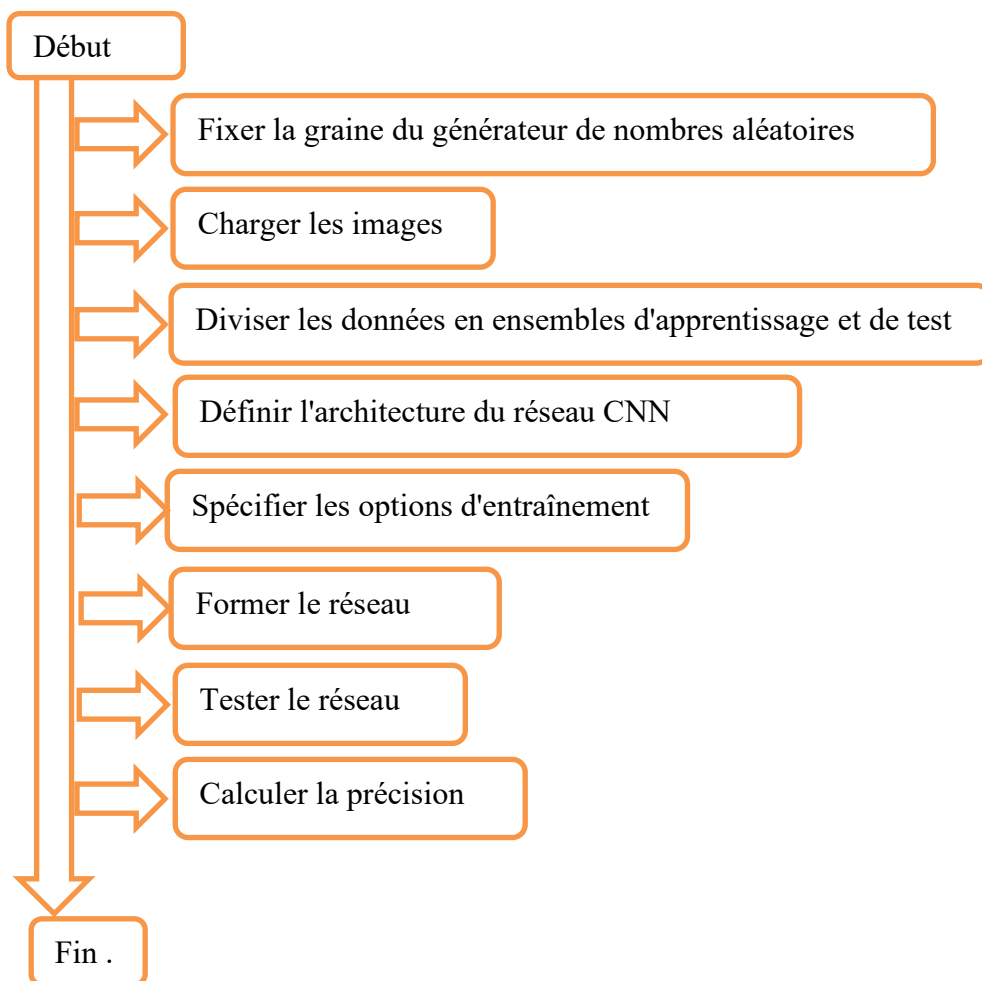
Figure III.5 : Courbe de précision et de la perte au fil du temps pendant l'entraînement de réseaux de neurones simples.

### **III.3.1.2.1 Observation de la figure**

- La courbe de précision montre que la précision de l'entraînement et de la validation augmente avec le temps, ce qui est un bon signe que le modèle apprend correctement.
- La courbe de perte montre que la perte de l'entraînement et de la validation diminue avec le temps, ce qui est également un bon signe que le modèle apprend correctement.
- Il semble y avoir un écart entre la précision de l'entraînement et de la validation, ainsi qu'entre la perte de l'entraînement et de la validation. Cela pourrait indiquer un certain surapprentissage, ce qui signifie que le modèle pourrait ne pas généraliser aussi bien sur de nouvelles données.
- Le modèle montre une bonne performance globale avec une précision de validation de 86.67%, ce qui est respectable pour un modèle simple.
- La perte de validation stable suggère que le modèle a atteint une bonne convergence.

### III.3.2 Approche 2 : Réseaux de Neurone Convolutif (CNN)

Le réseau commence par une couche d'entrée qui accepte les images en niveaux de gris. Ensuite, il passe par une série de blocs convolutionnels et de normalisation, chacun composé de couches de convolution 2D, de normalisation par lot, de fonctions d'activation ReLU et de couches de pooling. Ces blocs permettent d'extraire et de raffiner les caractéristiques importantes des images tout en réduisant progressivement les dimensions spatiales. Enfin, les caractéristiques extraites sont passées à travers une couche entièrement connectée, une couche softmax et une couche de classification pour prédire les classes des images d'entrée ( **figure III.6**).



**Figure III.6 : Organigramme du simulation du modèle CNN sur MATLAB.**

#### III.3.2 .1 Structure détaillée du réseau de neurones convolutif (CNN)

Notre réseau de neurones convolutif (CNN) commence par une couche d'entrée de l'image qui accepte des images en niveaux de gris de dimensions 150x133 pixels.

Le premier bloc de traitement est un bloc convolutionnel et de normalisation qui comprend une couche de convolution avec 8 filtres de taille 3x3, une couche de normalisation par lots, une couche d'activation ReLU et une couche de pooling maximal avec un filtre 2x2 et un pas de 2. Ce bloc vise à extraire des caractéristiques locales tout en maintenant les dimensions de l'image et en introduisant la non-linéarité.

Le réseau continue avec trois autres blocs similaires (**blocs 2, 3 et 4**), chacun augmentant le nombre de filtres dans les couches de convolution (16, 24 pour le bloc 2, puis 32, 40 pour le bloc 3, et finalement 48 pour le bloc 4), ce qui permet d'extraire des caractéristiques plus complexes à chaque étape.

Enfin, le réseau se termine par un **bloc entièrement connecté et de classification**, comprenant une couche entièrement connectée avec 5 neurones (correspondant au nombre de classes à prédire), une couche softmax qui transforme les scores en probabilités, et une couche de classification qui calcule la perte pour évaluer la performance du réseau.

Chaque étape du réseau est conçue pour transformer progressivement les données d'entrée en une forme qui est utilisée pour la classification efficace des images.

### III.3.2.2 Les options d'entraînement pour le réseau de neurones convolutif (CNN)

Les données d'apprentissage sont mélangées à chaque époque pour éviter que le réseau ne s'ajuste à une séquence particulière, ce qui améliore la capacité de généralisation du modèle. Les données de validation utilisées sont spécifiées par (`imdsTest`), permettant de surveiller la performance du modèle sur un ensemble de données séparé à intervalles réguliers. La validation est effectuée toutes les 13 itérations, permettant de vérifier régulièrement les performances de validation pendant l'entraînement.

Le mode verbeux est activé (`Verbose,true`), ce qui signifie que des informations détaillées sur le processus d'entraînement seront affichées, y compris la précision et la perte pour chaque mini-lot ainsi que les performances de validation. Enfin, la progression de l'entraînement sera visualisée en temps réel grâce à l'option « Plots » (**figure III.7**), « training-progress » (**tableau III.2**), permettant de voir les courbes de perte et de précision pour les ensembles d'apprentissage et de validation.

Epoque	Iteration	Time Elapsed (hh:mm:ss)	Précision de l'apprentissage	Précision de validation	Pert de l'apprentissage	Pert de validation
1	1	00 :00 :19	18.75%	20.0%	3.3276	2.2456
7	13	00 :02 :38	89.84%	73.67%	0.3519	0.8325
13	26	00 :05 :29	99.22%	86.67%	0.0383	0.2746
20	39	00 :08 :21	100.0%	93.33%	0.0135	0.2482
20	40	00 :08 :35	99.22%	93.33%	0.0286	0.2385

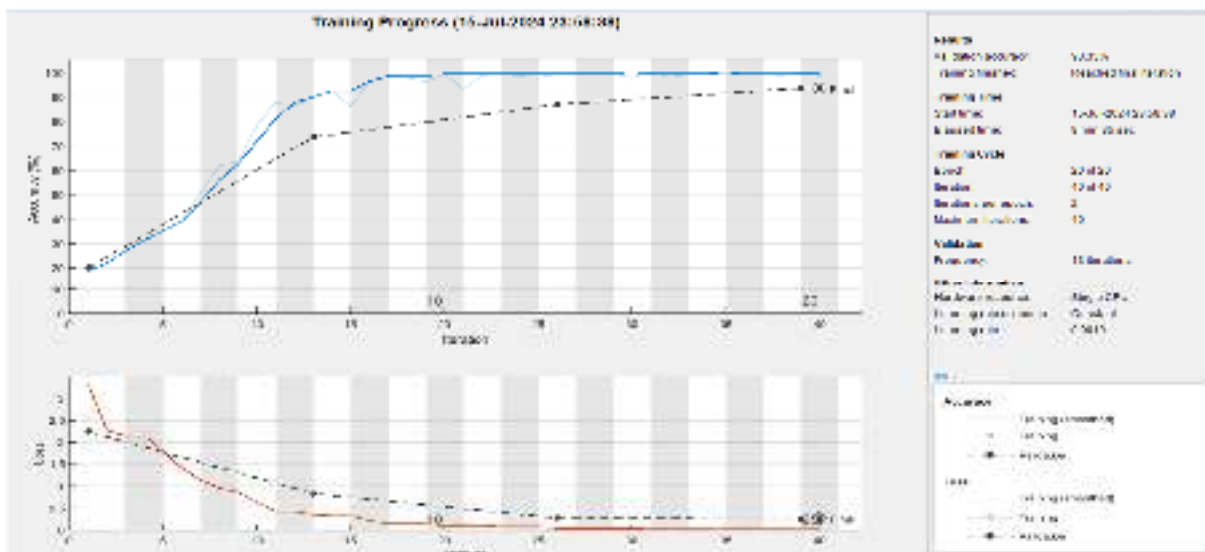
Tableau III.2 : Progression de l'entraînement du modèle CNN.

III.3.2.2.1 Analyse des résultats de tableau

D'après les résultats on peut observer une amélioration significative de la précision au fil des époques. Voici quelques points clés de l'analyse :

- La précision d'apprentissage a augmenté rapidement, atteignant 100% à l'époque 20, ce qui indique que le réseau apprend efficacement à partir des données d'entraînement.
- La précision de validation a également augmenté, mais à un rythme plus lent, atteignant 93.33% à l'époque 20 .
- La perte d'apprentissage et la perte de validation ont toutes deux diminué, ce qui est un bon signe que le modèle s'améliore.

Cependant, il y a une légère différence entre la précision de l'apprentissage et la précision de validation.



**Figure III.7: Courbe de précision et de la perte au fil du temps pendant l'entraînement de Réseaux de Neurones Convolutifs.**

### III.3.2.2.2 Analyse des résultats de la figure

D'après les résultats on peut observer une amélioration significative de la précision au fil des époques. Voici quelques points clés de l'analyse :

- Précision atteinte : La précision finale est de (93.13%), ce qui est généralement considéré comme un bon résultat pour un modèle d'apprentissage automatique.
- Temps écoulé : L'entraînement a pris « 1 minute et 19 secondes », ce qui indique une exécution relativement rapide.

Les graphiques montrent que la précision de validation suit de près la précision d'entraînement, ce qui est bon signe car cela indique que le modèle n'est pas en sur ajustement (overfitting). De plus, la perte de validation est légèrement supérieure à la perte d'entraînement, ce qui est normal.

## III.4 Conclusion

En conclusion, les approches neuronales telles que les réseaux de neurones simples et convolutifs se sont révélées extrêmement efficaces pour la classification des défauts à partir d'images d'émission acoustique. Les réseaux de neurones simples offrent une méthode directe mais peuvent être limités en précision, tandis que les réseaux convolutifs exploitent la structure spatiale des images pour une meilleure capture des caractéristiques, améliorant ainsi la précision des classifications. En termes de performances, bien que les réseaux convolutifs puissent demander plus de temps de traitement en raison de leur complexité, ils surpassent souvent les réseaux simples en termes de précision, ce qui en fait un choix privilégié pour des applications nécessitant une classification détaillée et précise des défauts.







## IV.1 Introduction

L'algorithme des k plus proches voisins (KNN) est un pilier dans les machine learning, utilisé pour la classification et la régression. Deux approches couramment employées sont le KNN avec un nombre fixe de voisins et le KNN avec recherche en grille.

Dans cette étude, nous revisiterons la théorie de cet algorithme et deux approches, puis procéderons à leur simulation. Nous analyserons et comparerons leurs résultats pour évaluer leurs performances respectives. Enfin, nous conclurons sur les avantages et les limitations de chaque approche dans divers contextes d'application.

## IV.2 Rappel théorique sur KNN (K-Nearest Neighbors)

KNN, ou "K-Nearest Neighbors" en anglais, est traduit en français par "K plus proches voisins" est un algorithme d'apprentissage automatique simple et intuitif utilisée pour la classification et la régression. Il fonctionne en identifiant les K échantillons les plus proches d'un point de données donné dans l'espace des caractéristiques [37].




Figure IV.1 : Exemple simple sur KNN [37].

### ❖ L'interprétation de l'exemple

Dans cet exemple nous avons une donnée non classée et tous les autres données sont classées (étoile et triangle) chacun avec leur classe (classe A et B).

- **Si  $k=3$**  : les données les plus proches de la nouvelle donnée sont à l'intérieur de premier cercle, et la classe la plus prédominante c'est le triangle (Classe B) donc la donnée sera classer comme un triangle (Classe B).
- **Si  $k=7$**  : les données les plus proches de la nouvelle donnée sont à l'intérieur de deuxième cercle, et la classe la plus prédominante c'est l'étoile (Classe A) donc la donnée sera classer comme étoile (Classe A).

❖ **La distance entre le point non classée et les plus proches voisins**

La distance entre le point non classée et les plus proches voisins est mesuré en utilisant différents méthode comme la distance : uclidienne, de Manhattan, de Minkowski, de Jaccard, de Hamming. . . etc. Pour les données de même type la distance euclidienne est le bon candidat, et pour les données qui ne sont pas de même type la distance de Manhattan est la bonne mesure pour l'utiliser [37].

- Deux approches principales de KNN sont largement utilisées :

**IV .2.1 Première approche : KNN avec un nombre fixe de voisins**

- Cette approche implique de fixer un nombre prédéfini de voisins (K) à l'avance.
- Lorsqu'une nouvelle observation doit être classée, les K voisins les plus proches sont sélectionnés pour influencer la décision.

**IV.2.2 Deuxième approche : KNN avec recherche en grille**

- Contrairement à l'approche avec un nombre fixe de voisins, cette méthode ne fixe pas K à l'avance.
- Elle explore plutôt une plage de valeurs de K via une validation croisée pour sélectionner le K optimal qui maximise les performances du modèle.

### IV.3 Simulation

Les deux approches suivent une méthodologie de base similaire pour classer les données en identifiant les voisins les plus proches :

#### IV.3.1 Collecte des données et prétraitement

- Un ensemble de données approprié a été sélectionné pour l'étude, comprenant des caractéristiques pertinentes et des étiquettes de classe.
- Les données ont été prétraitées, y compris le nettoyage des données, la normalisation si nécessaire, et la division en ensembles d'entraînement et de test.

##### IV .3.1.1 Organisation des images

Les images de signal émission acoustique de taille [150 133] dans dossier nommé comme suit :

- ✓ Folder1 contient 59 images cas Défaillance de roulement.
- ✓ Folder2 contient 60 images cas de Healthy (Sain).
- ✓ Folder3 contient 61 images cas de 1 barre rotorique cassée.
- ✓ Folder5 contient 60 images cas de 2 barres rotorique cassées.
- ✓ Folder4 contient 60 images cas de 3 barres rotorique cassées.

##### IV.3.1.2 Prétraitement de la donnée

-Fixer la graine du générateur de nombres aléatoires pour la reproductibilité.

-Initialiser les variables nécessaires pour le traitement des images.

-Pour chaque dossier, lire chaque image, la redimensionner à une taille uniforme, et ajouter les pixels de l'image à une matrice de données. Ajouter également l'étiquette de l'image à une matrice d'étiquettes.

##### IV.3.1.3 Redimensionné les données

Ajustez la taille de toutes les images pour qu'elles aient les mêmes dimensions. Cela est nécessaire car l'algorithme KNN requiert que les données d'entrée soient de la même forme.

#### IV.3.1.4 Normaliser les données

Transformez les valeurs des pixels pour qu'elles se situent dans une plage commune, généralement entre 0 et 1. Cela aide à réduire les biais dus aux variations d'éclairage et de contraste entre les images.

#### IV.3.1.5 Organigramme de prétraitement

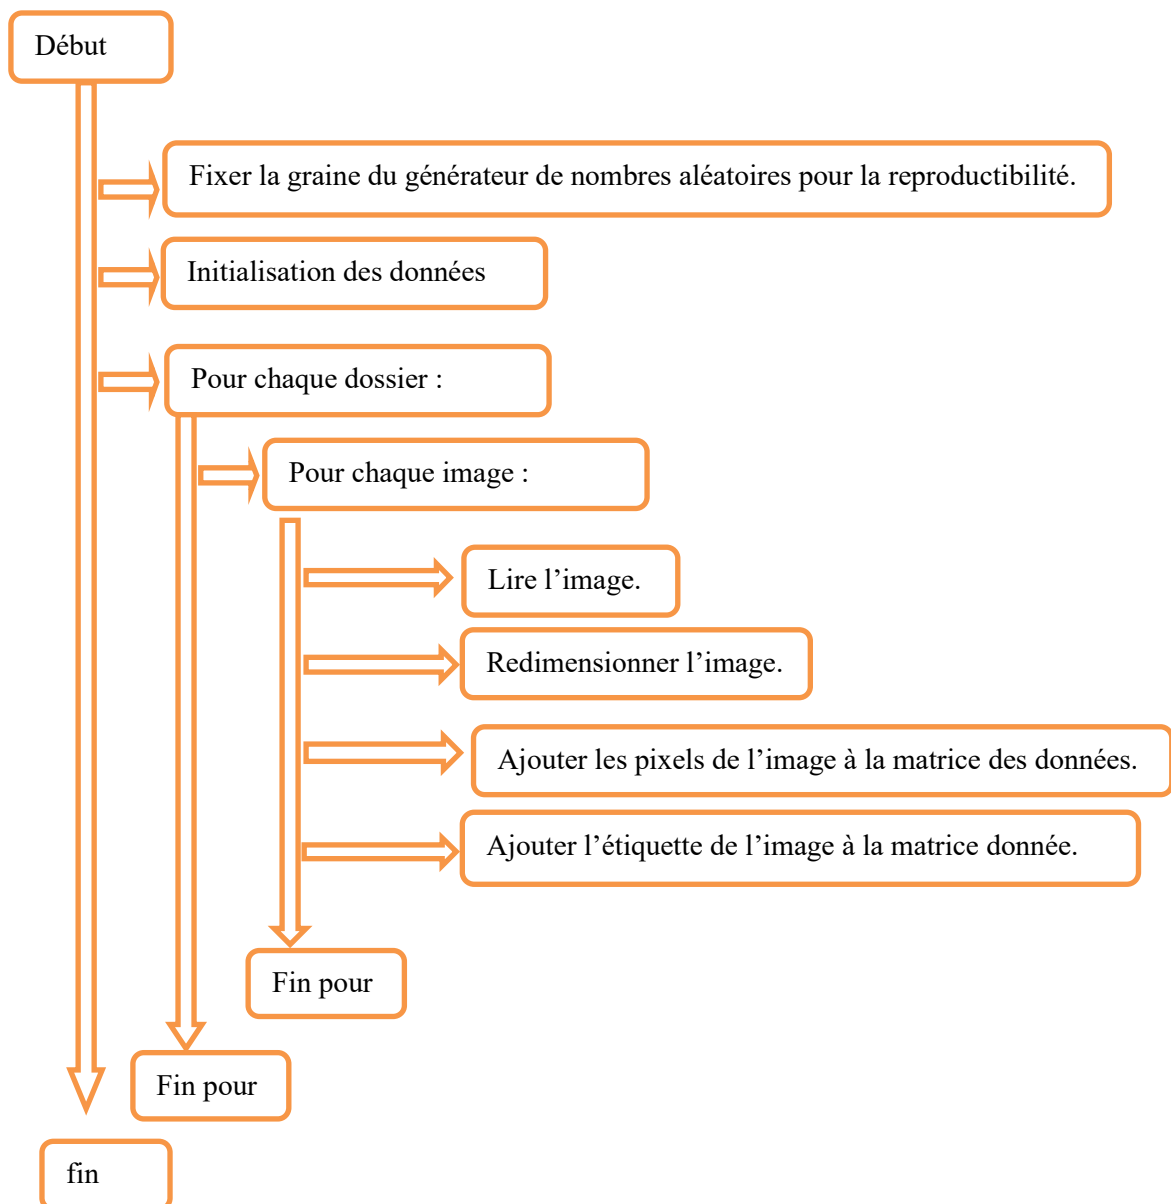


Figure IV. 2: Organigramme de Prétraitement de modèle K-NN.

### IV .3.2 Simulation pour première approche KNN avec un nombre fixe de voisins

Nous avons utilisé Les données pour entraîner un modèle KNN, en utilisant un seul voisin le plus proche pour faire les prédictions. Pour évaluer la performance de notre modèle, nous avons effectué une validation croisée à 5 plis.

Enfin, nous avons calculé la précision de notre modèle en comparant les étiquettes prédites par le modèle aux vraies étiquettes. Les résultats ont montré que notre modèle a une précision de ... (99.33%), ce qui indique l'erreur de validation croisée pour le modèle KNN est (22.00%), dans une durée de simulation (7. 278 s.).

#### IV.3.2.1 Organigramme

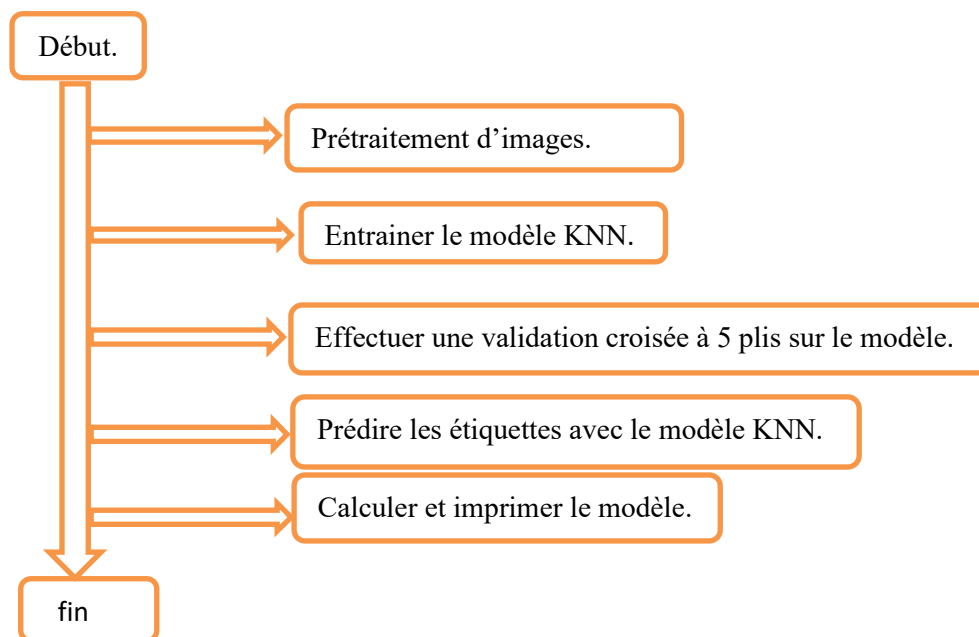


Figure IV.3 : Organigramme de KNN avec un Nombre Fixe de Voisins.

#### IV.3.2.2 Recherche du Nombre Optimal de Voisins

Pour trouver le nombre optimal de voisins, on va fixer le nombre de voisin et en simule à chaque fois pour trouver k idéal. Cette technique consiste à tester une série de valeurs possibles pour k, à entraîner un modèle pour chaque valeur, et à évaluer la performance de chaque modèle.

Nous avons défini une plage de valeurs pour  $k$  allant de 1 à 10. Pour chaque valeur de  $k$ , nous avons entraîné un modèle KNN et évalué sa performance en utilisant la validation croisée, les résultats sont résumés dans le tableau suivant (**tableau IV.1**) :

<b>k</b>	<b>La précision</b>	<b>L'erreur de validation</b>	<b>Le temps de simulation</b>
1	99.3%	20.0%	6.278s
2	89.3%	28.3%	6.628s
3	87.2%	31.2%	7.362s
4	86%	32%	6.974s
5	83%	34.3%	6.663s
6	77.7%	38%	6.841s
7	76.7%	41.7%	6.339s
8	71.3%	43%	6.255s
9	68.3%	47.3%	6.628s
10	66.3%	46.3%	6.278s

**Tableau IV.1 : Performance pour KNN avec nombre fixe de voisin.**

### IV.3.2.3 Analyse des Résultats

- **Précision**

- La précision est la plus élevée (99.3%) pour ( $k = 1$ ) et diminue régulièrement à mesure que ( $k$ ) augmente (**figure IV.4**).

- Pour des valeurs plus élevées de ( $k$ ), la précision diminue significativement, atteignant 66.3% pour ( $k = 10$ ).

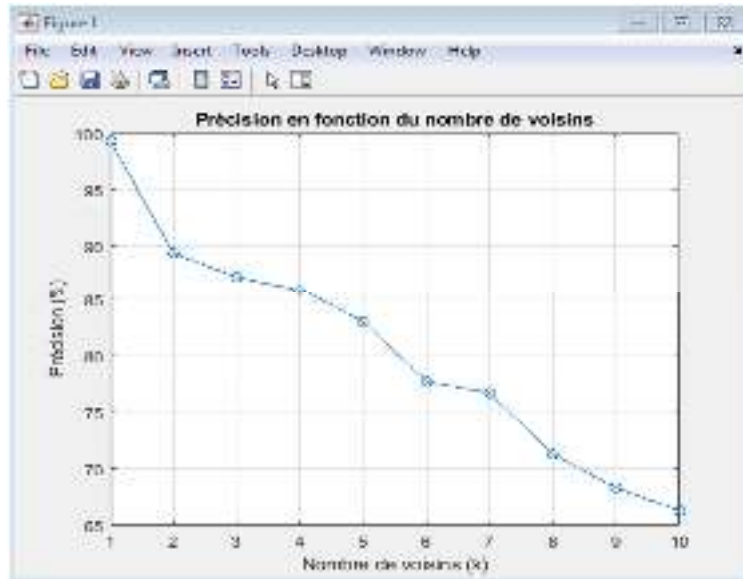


Figure IV.4 : La precision en fonction de nombre de voisin.

- Erreur de Validation

- L'erreur de validation (**figure IV.5**) est la plus basse (20.0%) pour (k = 1).
- Elle augmente avec (k), atteignant un maximum de 47.3% pour (k = 9), avant de légèrement diminuer à 46.3% pour (k = 10).




Figure IV.5: Erreur de validation en fonction du nombre de voisins.

- Temps de Simulation :

- Le temps de simulation varie légèrement avec (k), avec des valeurs allant de 6.255s à 7.362s (**figure IV.5**).
- Le temps de simulation le plus long est observé pour (k = 3) (7.362s).

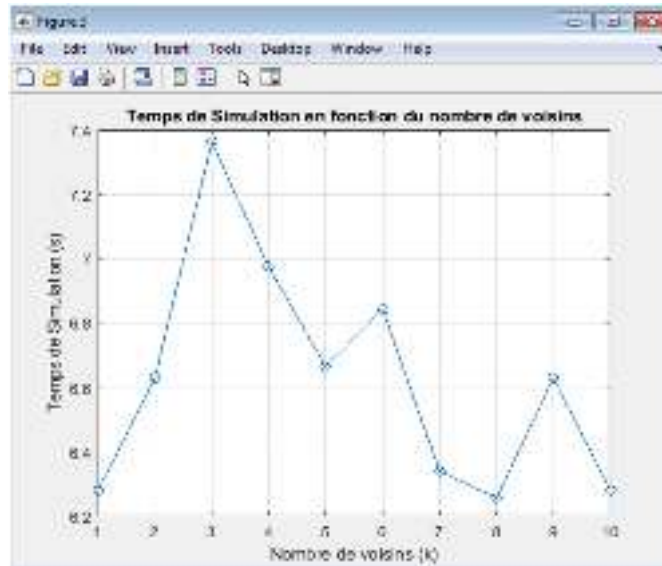


Figure IV.6 : Temps de simulation en fonction du nombre de voisins

#### IV.3.2.4 Commentaires des résultats

L'analyse des résultats de simulation pour KNN avec un nombre fixe de voisins met en évidence des tendances claires : une précision optimale est atteinte à  $k=1$ , mais diminue avec des valeurs plus élevées de  $k$  ; le temps de simulation reste relativement stable, avec une légère augmentation observée pour  $k=3$  ; et l'erreur de validation augmente également avec  $k$ , suggérant que la généralisation peut être compromise pour des valeurs plus élevées de  $k$ . Ces résultats soulignent l'importance de choisir judicieusement  $k$  en tenant compte de la précision, du temps de calcul et de la capacité du modèle à généraliser.



### **IV.3.3 Recherche en Grille du Nombre Optimal de Voisins :**

Dans notre projet, nous avons commencé par initialiser les variables nécessaires pour le traitement des images. Les images ont été collectées à partir de dossiers spécifiques, chaque image a été redimensionnée à une taille uniforme et les pixels de l'image redimensionnée ont été ajoutés à une matrice de données. Chaque image a été étiquetée en fonction du dossier d'origine.

Ces données sont ensuite été utilisées pour entraîner un modèle KNN. Après une recherche en grille, nous avons déterminé que le meilleur nombre de voisins (Kbest) était 1,

Pour évaluer la performance de notre modèle, nous avons effectué une validation croisée à 5 plis.

Enfin, nous avons calculé la précision de notre modèle en comparant les étiquettes prédites par le modèle aux vraies étiquettes. Les résultats ont montré que notre modèle a une précision de 99.33%, ce qui indique que l'erreur de validation croisée pour le modèle KNN est de 22.33%. La durée de la simulation était de 57.080 secondes.

#### **IV.3.3.1 Algorithme de KNN recherche en grille**

- Initialiser les variables nécessaires.
- Lire et prétraiter les images à partir des dossiers spécifiés.
- Effectuer une recherche en grille pour trouver le nombre optimal de voisins (k) pour l'algorithme KNN.
- Créer un modèle KNN en utilisant le k optimal trouvé.
- Effectuer une validation croisée sur le modèle KNN.
- Calculer la précision du modèle KNN.
- Imprimer le k optimal, l'erreur de validation croisée et la précision du modèle.

IV.3.3.2 Organigramme

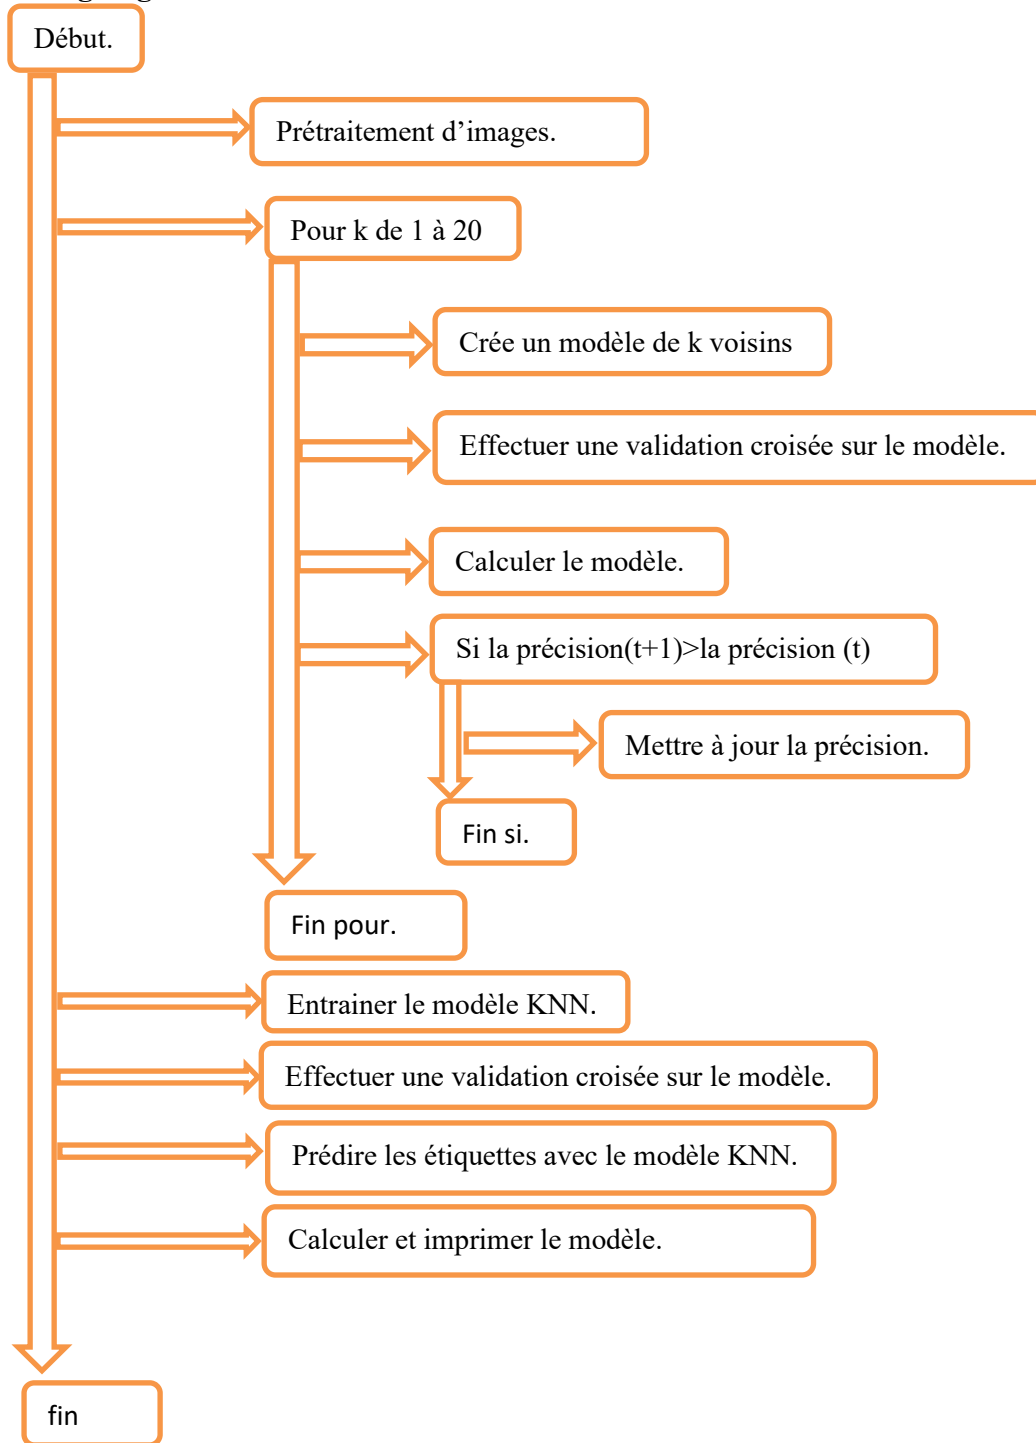


Figure IV.7 : Organigramme de l'approche KNN recherche en grille.

Nombre de plis	L'erreur de validation	Précision	Durée de simulation
5	22.33%,	99.33%.	57.080s
6	24.33%	99.33%	62.407s
7	23.63%	99.33%	75.963s
8	23%	99.33%	72.966s
9	23%	99.33%	63.950s
10	22.33%	99.33%	76.652s

Tableau IV.2 : Performance des KNN recherche en grille.

### IV.3.3.3. Analyse des Résultats

- Erreur de Validation

L'erreur de validation varie légèrement en fonction du nombre de plis utilisés dans la validation croisée (**figure IV.8**). Les configurations de 5 et 10 plis présentent l'erreur de validation la plus faible (22.33%), tandis que 6 plis montrent l'erreur la plus élevée (24.33%). Les autres configurations (7 à 9 plis) ont des erreurs de validation intermédiaires, allant de 23% à 23.63%.


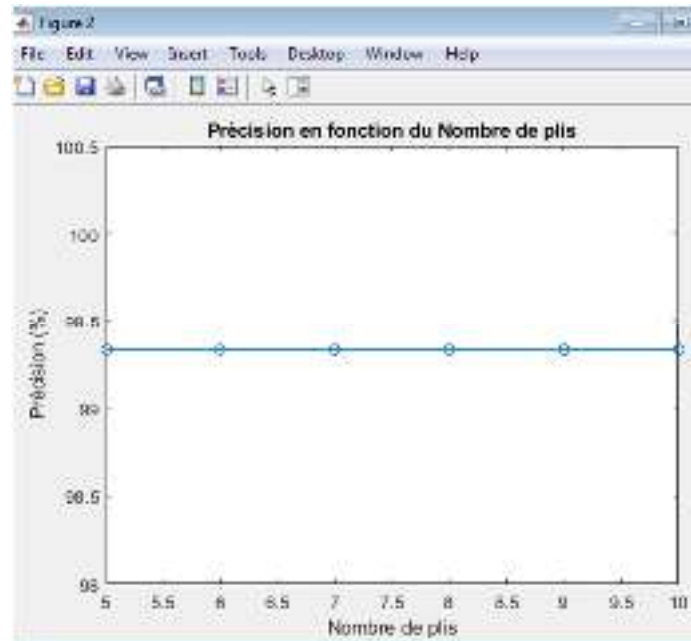


Figure IV.8 : Erreur de validation en fonction du nombre de plis.

- **Précision**

La précision de ce modèle KNN reste constante à 99.33% quel que soit le nombre de plis. Cela indique que la performance en termes de précision du modèle est très stable, indépendamment du nombre de plis utilisés pour la validation croisée (**figure IV.9**).



**Figure IV.9 : La précision en fonction du nombre de plis.**

- **Durée de Simulation**

La durée de simulation varie avec le nombre de plis (**figure IV.10**). La durée la plus courte est observée avec 5 plis (57.080 secondes), tandis que la durée la plus longue est observée avec 10 plis (76.652 secondes). En général, la durée de simulation tend à augmenter avec le nombre de plis, bien que certaines configurations comme 9 plis soient plus rapides que d'autres, comme 7 plis.

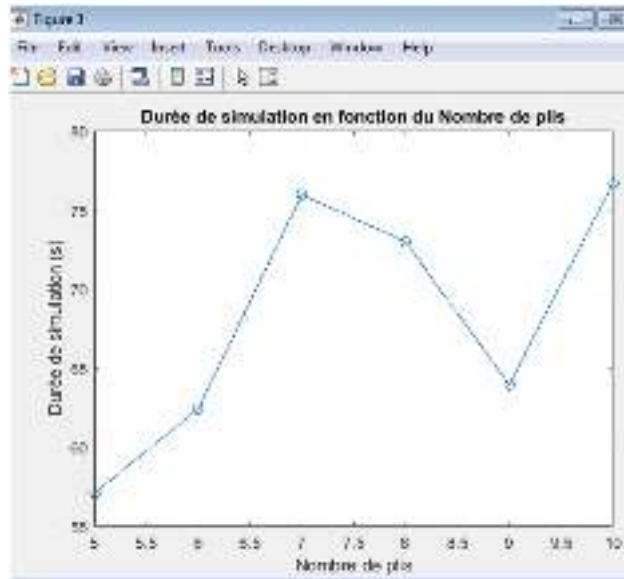


Figure III.10 : La durée de simulation en fonction du nombre de plis.

- **Kbest**

Le meilleur nombre de voisins trouvé par la recherche en grille est 1 pour toutes les configurations de plis (figure IV.11). Cela signifie que le modèle KNN avec un seul voisin a offert les meilleures performances globales en termes de précision et d'erreur de validation.

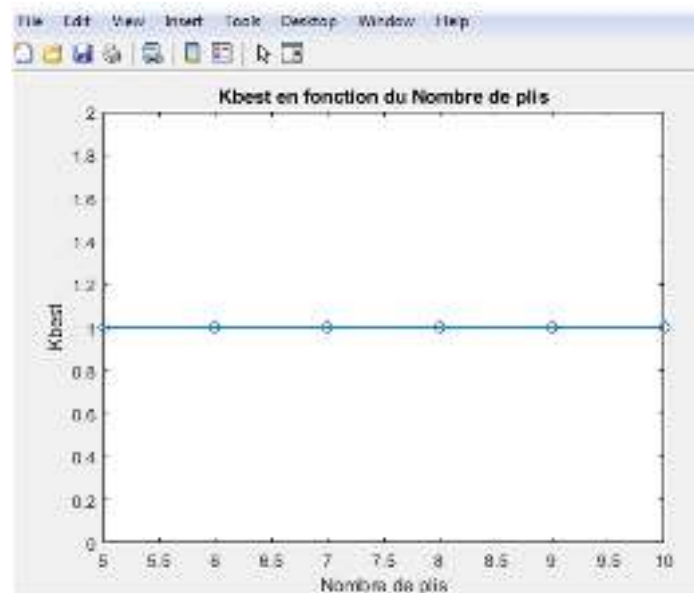


Figure IV.11 : Kbest de simulation en du nombre de plis.

**IV.3.3.4 Commentaires**

l'analyse des performances de KNN avec recherche en grille met en évidence des tendances distinctes : une précision optimale est généralement atteinte pour des combinaisons spécifiques de paramètres de grille, souvent associées à une taille de grille plus fine; le temps de recherche en grille varie en fonction de la taille de la grille et du nombre de paramètres, mais il peut être géré efficacement avec des techniques d'optimisation ; enfin, l'erreur de validation peut être minimisée en ajustant judicieusement les hyperparamètres de la grille, soulignant l'importance d'une exploration systématique et exhaustive des paramètres.

**IV.4 Comparaison entre les deux approches de KNN:**

<b>KNN avec un Nombre Fixe de Voisins</b>	<b>Recherche en Grille pour Trouver le Nombre Optimal de Voisins</b>
- Cette simulation a été réalisée avec un nombre fixe de voisins (de 1 à 10).	- Cette simulation a été réalisée avec un nombre variable de plis (de 5 à 10).
- La précision varie de (66.3%) à (99.3%).	- La précision est constante à (99.33%) pour tous les nombres de plis
- L'erreur de validation varie de (20%) à (47.3%).	- L'erreur de validation varie de (22.33%) à (24.33%).
- La durée de la simulation est relativement constante, variant de (6.255s) à (7.362s).	- La durée de la simulation varie de (57.080s) à (76.652s).
- La précision est la plus élevée (99.3%) pour (k = 1).	- Le nombre optimal de voisins (Kbest) est (1) pour tous les nombres de plis.

**Tableau IV.3 : Comparaison entre les deux approches de KNN.**

**IV.5. Conclusion :**

En résumé, l'évaluation du KNN avec un nombre fixe de voisins et du KNN avec recherche en grille démontre leur efficacité pour la classification des défauts de la machine asynchrone. Le KNN avec un nombre fixe de voisins atteint une précision élevée, tandis que le KNN avec recherche en grille améliore cette précision grâce à une sélection minutieuse des paramètres. Ces méthodes fournissent des outils robustes pour identifier et classer les défauts dans les machines asynchrones, contribuant ainsi à une maintenance proactive et à de meilleures performances des équipements industriels.





---

## Conclusion générale

---

Après avoir étudié les différentes approches d'intelligence artificielle utilisées pour classer les défauts d'une machine asynchrone, nous sommes parvenus à la conclusion que :

En conclusion, les approches neuronales telles que les réseaux de neurones simples et convolutifs ont prouvé leur grande efficacité pour la classification des défauts à partir d'images d'émission acoustique. Les réseaux de neurones simples offrent une méthode directe mais peuvent être limités en termes de précision. En revanche, les réseaux convolutifs exploitent la structure spatiale des images pour mieux capturer les caractéristiques, ce qui améliore la précision des classifications. Bien que les réseaux convolutifs nécessitent plus de temps de traitement en raison de leur complexité, ils surpassent souvent les réseaux simples en précision, les rendant préférables pour des applications exigeant une classification détaillée et précise des défauts.

Les méthodes KNN ont démontré leur efficacité en se basant sur la similarité des caractéristiques extraites des images. KNN avec un nombre fixe de voisins est simple à implémenter et a montré une bonne performance pour des ensembles de données de taille moyenne. En revanche, KNN avec recherche en grille s'est distingué en ajustant dynamiquement le nombre de voisins en fonction des caractéristiques locales, ce qui a amélioré la précision de la classification.

Les SVM sont efficaces pour classer les défauts dans les machines asynchrones. L'approche "one vs one" offre une précision élevée en entraînant un classificateur pour chaque paire de classes, mais peut devenir complexe avec de nombreuses classes. En revanche, l'utilisation de HOG (Histogram of Oriented Gradients) avec SVM extrait efficacement les caractéristiques des images acoustiques, optimisant la détection des défauts visuels. Le choix entre ces méthodes dépend des besoins spécifiques et des caractéristiques des données à analyser.

Les approches neuronales, en particulier les réseaux de neurones convolutionnels, se distinguent par leur capacité à traiter efficacement des données complexes en exploitant des représentations hiérarchiques et spatiales. Ils sont idéaux lorsque la complexité des données et la variabilité des défauts nécessitent une analyse approfondie des caractéristiques. En

revanche, les méthodes classiques comme SVM et KNN offrent des alternatives robustes et simples à implémenter, adaptées à divers contextes d'application et efficaces pour des ensembles de données de taille modérée.

## **Perspectives**

Pour continuer à améliorer la classification des défauts dans les machines asynchrones, plusieurs perspectives peuvent être envisagées :

- **Intégration de méthodes hybrides** : Explorer des approches combinant réseaux de neurones et méthodes traditionnelles comme SVM ou KNN pourrait permettre de bénéficier des avantages complémentaires de chaque méthode.
- **Utilisation de techniques de prétraitement avancées** : Appliquer des techniques de prétraitement innovantes pour améliorer la qualité des données en amont pourrait renforcer la capacité des modèles à détecter des défauts subtils ou peu fréquents.
- **Adaptation aux environnements dynamiques** : Développer des modèles capables d'ajuster dynamiquement leurs paramètres en fonction des variations de conditions opérationnelles des machines asynchrones pourrait améliorer la robustesse et la fiabilité des systèmes de détection de défauts.

---

## Résumé

---

Ce mémoire se concentre sur la classification des défauts d'un entraînement électrique à l'aide des outils de l'intelligence artificielle. L'étude repose sur une base de données comprenant des images acoustiques] représentant des défauts de roulements et de barres rotoriques d'une machine asynchrone.

Pour accomplir cette tâche, deux approches neuronales ont été implémentées à l'aide de MATLAB : les réseaux de neurones simples et les réseaux de neurones convolutifs. En parallèle, des approches classiques ont été utilisées, notamment le KNN (K plus proches voisins) avec deux méthodes : KNN avec un nombre fixe de voisins et KNN avec recherche en grille. De plus, les SVM (machines à vecteurs de support) ont été explorés avec deux configurations : SVM en un-contre-un et SVM utilisant le descripteur de caractéristiques HOG (Histogram of Oriented Gradients).

Cette étude vise à comparer l'efficacité de ces différentes méthodes dans la classification précise des défauts détectés dans les composants de l'entraînement électrique. Les résultats obtenus sont analysés et discutés afin de déterminer les avantages et les limitations de chaque approche.

**Mots clés :** **Machine asynchrone** : Moteur électrique dont le rotor tourne à une vitesse différente du champ magnétique du stator, **Défauts** : Anomalies électriques, mécaniques ou de performance affectant le fonctionnement de la machine, **Classification** : Processus d'identification et de catégorisation des différents types de défauts, **Intelligence artificielle** : Utilisation d'algorithmes avancés pour la détection et la classification automatique des défauts.

---

## Abstract

---

This thesis focuses on the classification of faults in an electric drive using artificial intelligence tools. The study is based on a database that includes acoustic images representing bearing and rotor bar faults in an asynchronous machine.

To accomplish this task, two neural approaches were implemented using MATLAB: simple neural networks and convolutional neural networks. In parallel, classical approaches were used, including KNN (K-nearest neighbors) with two methods: KNN with a fixed number of neighbors and KNN with grid search. Additionally, SVMs (support vector machines) were explored with two configurations: one-vs-one SVM and SVM using the HOG (Histogram of Oriented Gradients) feature descriptor.

This study aims to compare the effectiveness of these different methods in the accurate classification of detected faults in the electric drive components. The obtained results are analyzed and discussed to determine the advantages and limitations of each approach.

**Keywords:** Asynchronous machine: Electric motor whose rotor rotates at a different speed than the stator's magnetic field, Faults: Electrical, mechanical, or performance anomalies affecting the machine's operation, Classification: Process of identifying and categorizing different types of faults, Artificial intelligence: Use of advanced algorithms for automatic fault detection and classificatio.

## Tulmisiin

---

Akatay-a (1) yeenaasismel (2) uzligazruran (3), i ttgenttawilat n tigzi (4) Tazrawt-a tersyeflukciwintussnanin (5), anda kkinttugniwin (6), tikustikin n (150 ×133) i d-yettgensisen(7) tuccdiwin n yifeggagen n Rotoriques n tmacininAsychrone.

Akken ad nezdiInoronon-a i yettef MATLAB, Izedwa n Yirononen, udsent (8) yertid n klasik, u smersent di KNN, ( K yudesyersnat n tarrayin-a10., n KNN s umdan (11) Igit n yinaragen-a (12) d unadi n yixef-is, Rnu SVM, (Tamacint s umaway (13) d tmawayt) , nger- asenti s snat n tarrayin, anda nessemrestimuylwin, SVM, s yiwenmgal(14) yiwen, d SVM s ttawil n HOG ( Histogram of Oriented Gardiens).

Tazrawt-a teena aserwes (15) n tarrayin yemgaraden n usismel, d uwekked n tuccdiwin, d usukkes azruran, Igemmad (16) yer i nessawed nwala-ten, nesqerdec-iten, akken kan ad d-naf anta tarrayt yudsen yer tayed.

### Terminologies de résumé en langue tamazighth

1- mémoire. 2- Classification. 3 – électrique. 4 – intelligence. 4 - base de données. 5 - images

6 – représentant. 7 – proche. 8 – utiliser. 9 – methodes . 10 – nombre. 12 – voisins.

13 – vecteur. 14 – contre. 15 – comparer. 16 - resultats.

## Summary

---

This thesis focuses on the classification of faults in an electrical drive using artificial intelligence tools. The study is based on a database consisting of acoustic and [150 x 133] size images depicting faults in bearings and rotor bars of an asynchronous machine.

To accomplish this task, two neural network approaches were implemented using MATLAB: simple neural networks and convolutional neural networks. Concurrently, classical approaches were employed, including KNN (K-Nearest Neighbors) with two methods: KNN with a fixed number of neighbors and KNN with grid search. Additionally, SVMs (Support Vector Machines) were explored with two configurations: one-versus-one SVM and SVM using the HOG (Histogram of Oriented Gradients) feature descriptor.

This study aims to compare the effectiveness of these different methods in accurately classifying faults detected in the components of the electrical drive. The obtained results are analyzed and discussed to determine the advantages and limitations of each approach.

---

## Bibliographie

---

- [1] : Yagoub Ali & Otmame Houari : Surveillance et diagnostic d'un moteur électrique asynchrone triphasé dans le cadre d'une maintenance conditionnelle, Mémoire de Master, université de Tiaret, 2020,2021.
- [2] : Gazzam Abdelhak et Safsafa Chouaib : Diagnostic des défauts rotorique des machines asynchrones à cage par différentes techniques de traitement de signal : Mémoire de Master, universite Amar Telidji de Laghouat, 2018.
- [3] : Al-Mushiaa Mohammed Mansoor et Aoukli Zakaria : Technique de diagnostic des défauts dans les systèmes électriques par les réseaux de neurones (machine asynchrone) : Mémoire de Master, université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj, Juin 2022.
- [4] : Boukhari Bylia Amini Taous: Calcul des pertes fers dans la machine asynchrone: Mémoire Master, université de Tizi-Ouzou,.
- [5] : Bouaoun Oudai Chouia Abdeljalil : Contribution au Diagnostic des défauts de la cassure des barres rotoriques dans les systèmes électromécaniques : Application aux Moteurs à Induction : Master Acadimic, université d'El Oued, 2020.
- [6] : Julien Vaïssette : Moteur asynchrone : tout (vraiment tout) ce que vous devez savoir sur le moteur du futur, 2023, [julien@construire-sa-moto-electrique.org](mailto:julien@construire-sa-moto-electrique.org).
- [7] : Yassa Nacera: Détection des défauts dans les systèmes de conversion d'énergie polyphasés, Thèse Doctorat, université Tizi Ouzou, 2018.
- [8] : [www.west-cs.com.br](http://www.west-cs.com.br) . Consulté le 4 Mai 202.
- [9] : <https://www.abcclim.net/moteur-asynchrone-triphase.html>. Consulté le 4 Mai 2024
- [10] : <http://Wiki du BTS Electrotechnique - SA - Principe du moteur asynchrone>.ge.sts.free.fr. Consulté le 8Mai 2024.
- [11] : Mendaz Kheira : Adaptation des commandes floues et Neuro-floue aux actionnaires asynchrones en mode dégradé : application au transport ferroviaire, Thèse Doctorat, universite de Sidi-Bel-Abbes.
- [12] : Ayad Haroune : Diagnostic des defaillances de la machineasynchrone, Mémoire de Master, Université Badji Mokhtar – Annaba, 2020.
- [13] : Y. Azzoug, A. Menacer, T.Ameid et H. Cherif : Etude Expérimentale du Diagnostic des Défauts Statoriques et Rotoriques de la Machine à Induction en Boucle Ouverte en utilisant la Transformé de Fourier, Université de Biskra.
- [14] : Comparaison entre la Technique Vibratoire et la Technique des Courants Statoriques : Application au Diagnostic des Roulements à Billes. <https://www.semanticscholar.org/author/Mohamed-Boudiaf-Koura/2075526242>. Consulté le 15 Mai 2024.

- [15] : B. BESSAM : Analyse et détection de défauts dans la machine asynchrone sur la base de techniques intelligentes, Biskra: thèse de Doctorat, Université Mohamed Khidr, 2016.
- [16] : Tahar Achour : Diagnostic de défauts électriques et mécaniques de la machine 'asynchrone a simple cage d'ecureuil : Etude expérimentale : Mémoire d'ingénieur, Ecole Nationale Polytechnique, Juin 2008.
- [17] : Christophe Migeon : Émission acoustique et analyse vibratoire pour l'étude des défauts de roulements pour différents régimes moteurs. Mécanique [physics.med-ph]. 2011.
- [18] : DRIS El Yamine : Algorithmes Adaptatifs Appliqués à la Localisation et au Suivi de l'Evolution des Sources d'Emission Acoustique (EA) : Magister en Electronique(ENP), Ecole Nationale Polytechnique, 2021.
- [19] : Hanane Nechad : Evaluation de l'endommagement et de la rupture de matériaux hétérogènes par ultrasons et émission acoustique : Estimation de la durée de vie restante : Thèse de Doctorat, Ecole doctorale Matériaux de Lyon, Juillet 2004.
- [20] : Najah Hamamed : Capteurs acoustiques pour la détection de fuites dans les réseaux de distribution d'eau et l'évaluation non destructive des structures : conception, optimisation et étude comparative : Thèse de Doctorat, l'université du Mans, 2023.
- [21] : Jacques Jouhaneau : Techniques de l'ingénieur : "Microphones" et "Introduction à l'électroacoustique" par. [https://fr.wikiversity.org/wiki/Capteur/Capteurs\\_acoustiques](https://fr.wikiversity.org/wiki/Capteur/Capteurs_acoustiques).
- [22] : Zeina El-Hajj hamam : Simulation numérique et analyse de l'émission acoustique due à la rupture de fibre et à la décohésion à l'interface fibre/matrice dans un microcomposite : Thèse de Doctorat, Universite de Lyon, 2020.
- [23] : Fatiha Behloul . Farid Tafinine . Orhan Yaman : Induction Motor Fault Diagnosis with Local Ternary Pattern and AI Approaches : original research article, 27 September 2023, Consulté le 4 Avril 2024.
- [24] : <https://datascientest.com/https://datascientest.com/>. Consulté le 25 Mai 2024
- [25] : <https://www.dilepix.com/blog/author/aur%C3%A9lien-yol>. Consulté le 31 Juin 2024.
- [26] : <https://habefast.ch/seo-machine-learning-et-deep-learning/>. Consulté le 31 Juin 2024.
- [27] : <https://hellofuture.orange.com/fr/learning-zoo/>. Consulté le 31 Juin 2024.
- [28] : Nouma Amira & Kanoun Maroua : Diagnostic de la machine asynchrone par l'usage des réseaux de neurones artificiels, Diplôme Master, Université Saad Dahlab de Blida1 ,2022.
- [29] : [https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels\\_fig5\\_322263283](https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels_fig5_322263283).
- [30] : Mr. Mesai Ahmed Hamza Mr. Nadir Kais : Commande de la machine asynchrone à double alimentation – apport des techniques de l'intelligence artificielle : Mémoire de Master, Universite de Sidi-Bel-Abbes ,Juin 2017.

[31] : Raghda Alilouch : Détection, classification et localisation des défauts dans les lignes de transmission par les réseaux de neurones artificiels : Mémoire présenté comme exigence partielle de la maîtrise en ingénierie, université du Québec, Novembre 2022.

[32] : <https://www.google.com/search?q=types+de+reseaux+de+neurones+artificiels>, visité le 15 avril 2024.

[33] : Mustapha BOURAHLA : Chapitre 4 : Réseaux de neurones convolutifs : Département d'Informatique, Université de M'Sila, mustapha.bourahla@univ-msila.dz

[34] : Djemaa Mahir : Classification des images par CNN : Master Académique , Université 8 Mai 1945 ,Guelma, 2023.

[35] : support\_de\_cours\_-deep\_learning-chapitre3-cnn.pdf.

[36] : <https://www.google.com/url?sa=i&url=https%3A%2F%2Fpenseeartificielle.fr%2Ffocus-reseau-neurones-convolutifs>. Consulté le 3Avril 2024.

[37] : Belhachani Mohammed et MayouNasserEddine :Une application web pour la prédiction précoce du diabète basant sur les algorithmes d'apprentissage automatique :Mémoire de Master,Université de Ouargla, 2021.

[38] : Azzaz Soumia et Namous Rafika : Étude comparative des algorithmes d'apprentissage de la machine dans la prédiction et diagnostic du cancer de sein : Mémoire Master,Université Tébessa, 2022.