

## CHAPITRE 3

### MÉTHODOLOGIE

En utilisant des capteurs pour déterminer à quel moment la vérification des équipements est nécessaire, il est possible de prévenir les pannes et de réduire les coûts de la maintenance de routine. Grâce à des capteurs intégrés et connectés à internet, le contrôle des équipements de production s'effectue à distance et en temps réel. Dans ce cas, les recommandations sont envoyées aux services de l'exploitation et de la maintenance afin de remédier aux problèmes avant même qu'ils ne surviennent. Cette méthode permet de réduire les coûts d'exploitation et les coûts d'investissement en favorisant des réparations et une maintenance proactive des équipements en vue d'améliorer l'utilisation de la capacité et de la productivité [1].

#### 3.1. INTRODUCTION

La méthode développée dans ce projet est testée sur des données de référence extraites du « référentiel de données pronostiques de la NASA » et relatives à plusieurs expériences de défaillances des roulements effectuées dans différentes conditions de fonctionnement. En outre, la méthode est comparée aux pronostics traditionnels de caractéristiques temporelles et fréquentielles dont les résultats de simulation sont présentés à la fin du document.

#### 3.2. PROTOCOLE D'ACQUISITION DES SIGNAUX

Les données ont été générées par le centre National Science Foundation (NSF) Industry–University Cooperative Research Centers (IUCRC) pour les systèmes de maintenance intelligents (IMS - [www.imscenter.net](http://www.imscenter.net)) avec le soutien de Rexnord Corporation à Milwaukee, Wisconsin États-Unis.

Quatre roulements ont été installés sur un arbre. La vitesse de rotation a été maintenue constante à 2000 tr/min par un courant alternatif. Le moteur est couplé à l'arbre via des courroies de frottement. Une charge radiale de 6000 lb est appliquée sur l'arbre et le roulement par un mécanisme à ressort. Tous les roulements sont lubrifiés à force. Les roulements à double rangée Rexnord ZA-2115 ont été installés sur l'arbre comme indiqué à la figure 4. Une Carte PCB 353B33 avec des accéléromètres Quartz ICP à haute sensibilité a été installée sur le corps de palier avec un accéléromètre pour chaque roulement. La figure 4 indique également la position des capteurs. Toutes les défaillances sont survenues après avoir dépassé la durée de vie prévue du roulement qui est de plus de 100 millions de révolutions [9].

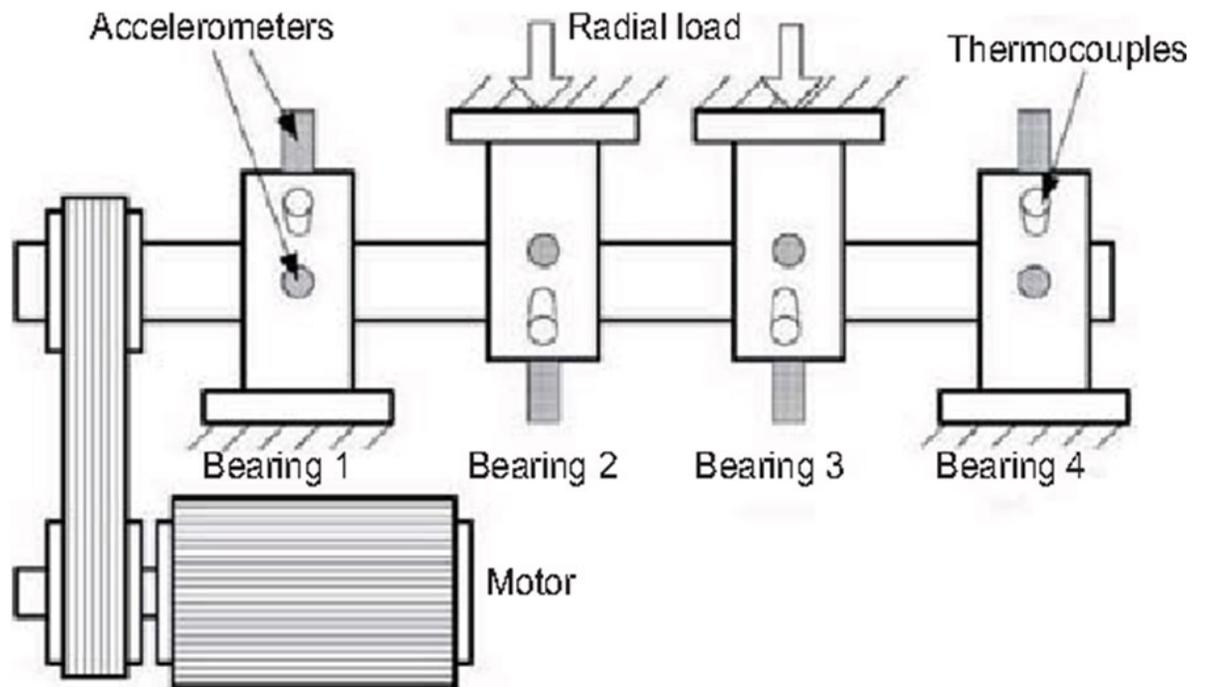


Figure 4 : Banc d'essai et illustrateur de placement des capteurs [9].

### 3.3. PRÉTRAITEMENT DES SIGNAUX

Pour le prétraitement de nos signaux, nous avons utilisé la boîte à outils Signal Processing Toolbox du logiciel MATLAB qui permet grâce à ses fonctions de détecter les valeurs aberrantes et de les corriger. Il permet également de travailler avec des signaux échantillonnés irrégulièrement, et de les préparer pour une analyse plus poussée [39].

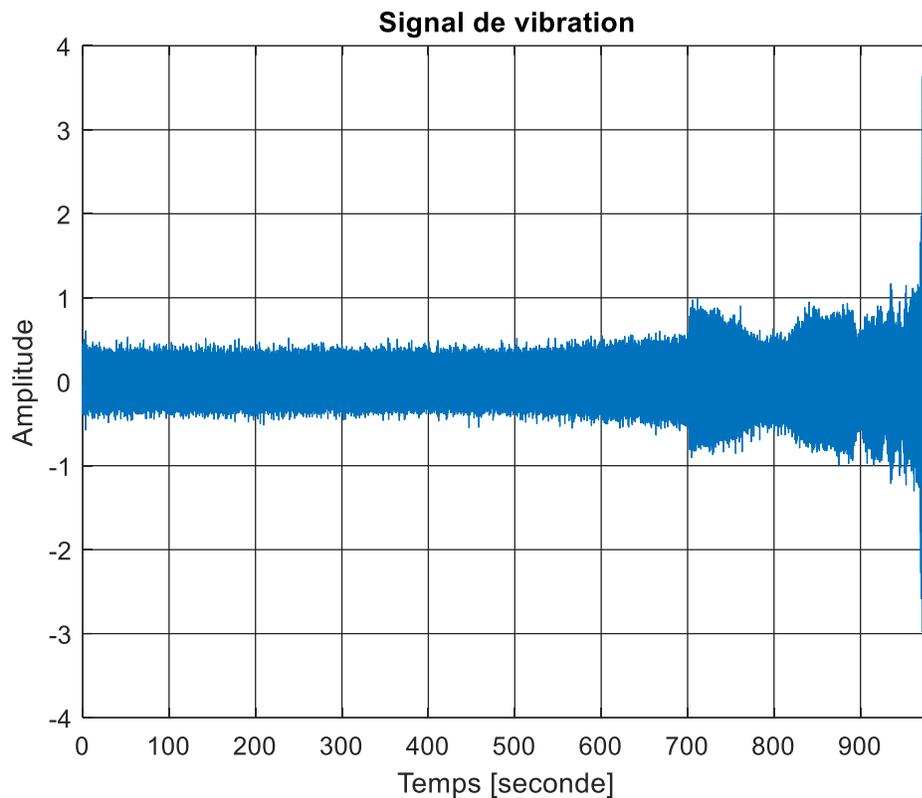


Figure 5 : Signal de vibration de la machine enregistré jusqu'à la défaillance.

Nous avons pour les besoins de notre projet découpé notre signal en trois groupes de données en fonction du niveau de dysfonctionnement observé durant le cycle de vie de la machine. Pour la conception du système de surveillance de la machine, nous avons procédé au filtrage de notre signal en appliquant un filtre médian (MED) aux signaux de vibration pour conserver les informations utiles en éliminant les composantes de bruit à haute fréquence.

Étant donné que les spectrogrammes  $P(t, \omega)$  des données des roulements sains et défectueux sont différentes, des caractéristiques représentatives peuvent être extraites des spectrogrammes et utilisées pour calculer avec précision la fréquence de crête moyenne comme indicateur de l'état du système [40] :

$$PeakFreq(t) = \operatorname{argmax}_{\omega} \{P(t, \omega)\} \quad (3.1)$$

La fréquence de crête moyenne est la moyenne des fréquences de crête définies ci-dessus :

$$MeanPeakFreq = \frac{1}{T} \int_0^T PeakFreq(t) dt \quad (3.2)$$

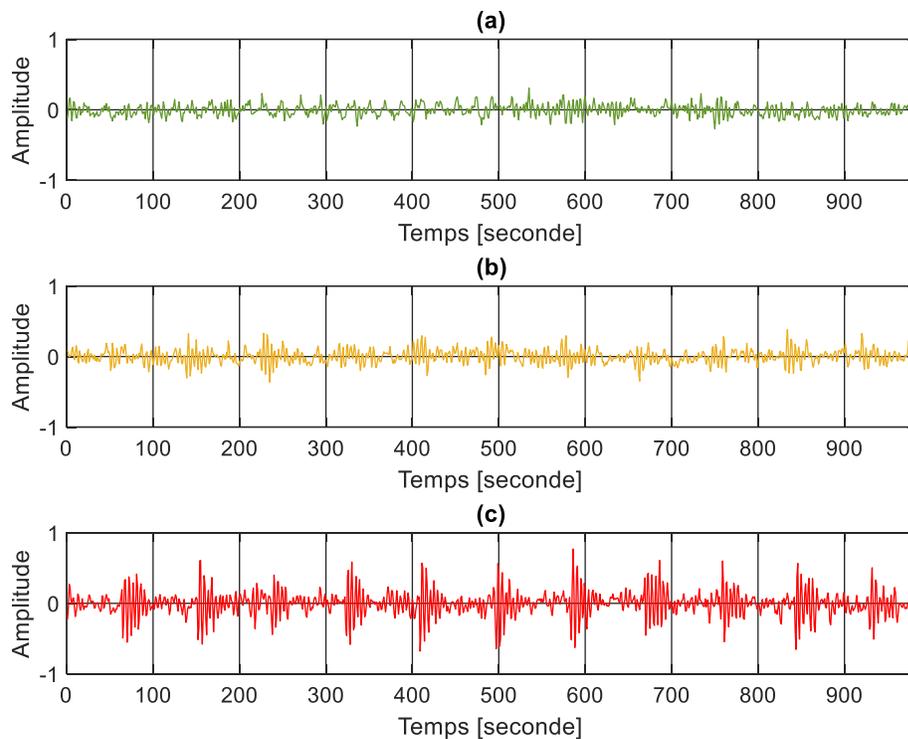


Figure 6 : Découpage du signal en trois groupes selon la présence ou non de défauts. (a)Signal nominal ; (b)Signal dégradé ; (c)Signal défaillant.

### 3.4. SÉLECTION DES CARACTÉRISTIQUES

Le logiciel MATLAB fournit des fonctions qui permettent d'explorer et d'extraire des modèles dans les signaux. Plus précisément, localiser les pics de signal et déterminer leur hauteur, leur largeur et trouver des points de changement dans les signaux [39].

Les caractéristiques du signal fournissent des métriques statistiques générales basées sur le signal qui peuvent être appliquées à tout type de signal, y compris un signal de vibration. Les modifications apportées à ces fonctionnalités peuvent indiquer des modifications de l'état de santé du système.

#### 3.4.1. CARACTÉRISTIQUES TEMPORELLES

L'analyse du domaine temporel présente les inconvénients d'une faible sensibilité et d'une faible précision, mais ses calculs simples et son traitement direct du signal contribuent à raccourcir le temps de traitement. La méthode simple du domaine temporel ne convient pas pour un diagnostic efficace des défauts, mais elle est bien meilleure lorsqu'elle est combinée avec d'autres approches, par exemple, les méthodes de classification, le réseau neuronal et l'intelligence artificielle. C'est-à-dire en utilisant des mesures statistiques pour obtenir des fonctionnalités utiles, puis en les classant par exemple avec un algorithme d'arbre de décision.

Les caractéristiques temporelles capables d'identifier l'emplacement précis des défauts sont les suivantes :

➤ **CARRE DE LA MOYENNE QUADRATIQUE (ROOT MEAN SQUARE (RMS)) :**

Qui indique l'état général aux derniers stades de dégradation. RMS est sensible à la charge et aux changements de vitesse.

- **FACTEUR DE CRÊTE** : Qui indique un rapport entre la valeur de crête du signal et la valeur RMS indiquant les signes précoces de dommages, en particulier lorsque les signaux de vibration présentent des caractéristiques impulsives.
  
- **KURTOSIS** : Indique les pics principaux de la distribution d'amplitude des signaux de vibration. C'est un paramètre calculé statistiquement à partir de la forme d'onde temporelle qui informe de la quantité de pics présents dans la forme d'onde.

**Tableau 2 : Caractéristiques temporelles**

Caractéristiques	Expression mathématique
Moyenne	$\frac{1}{N} \sum_{i=1}^N  x_t(i)  \quad (3.3)$
Root Mean Square (RMS)	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_t(i)^2} \quad (3.4)$
Valeur pic (PEAK)	$Max(x_t) \quad (3.5)$
Facteur de crête	$\frac{VP(x_t)}{RMS(x_t)} \quad (3.6)$
Coefficient d'asymétrie (skewness en anglais)	$\frac{1}{N} \sum_{i=1}^N \left[ \frac{x_t(i) - \bar{x}_t}{\sigma_s} \right]^3 \quad (3.7)$
Kurtosis	$\frac{1}{N} \sum_{i=1}^N \left[ \frac{x_t(i) - \bar{x}_t}{\sigma_s} \right]^4 \quad (3.8)$

Où :

$x_t$  = Signal brut,

$N$  = Le nombre de points enregistrés à l'instant (t)

$\sigma_s$  = L'écart-type du signal.

Les caractéristiques issues du Kurtosis sont obtenues en considérant un moment d'ordre 4 du signal et se calculent selon la formule (3.8) présentée dans le tableau 2. Dans le même ordre d'idée, le Skewness est un indicateur d'ordre 3 mesurant l'énergie par rapport à la moyenne.

Beaucoup de recherches ont fait ressortir l'efficacité du Kurtosis, pour la détection des défauts de roulements. Il s'agit d'un indicateur représentant les impulsions dans un signal. Certains articles de recherche [41] ont démontré l'utilité de l'utilisation du Kurtosis pour la détection des défauts de roulements par rapport aux autres indicateurs conventionnels tels que le PEAK ou le RMS. Cet indicateur permet d'avoir une idée sur la santé du roulement sans pour autant savoir beaucoup de choses sur l'historique de la machine. En effet, une valeur supérieure à 3 signifie que le roulement est défectueux [42], sauf que le Kurtosis peut être plus sensible qu'il ne le faut et peut donner des alarmes prématurément [43].

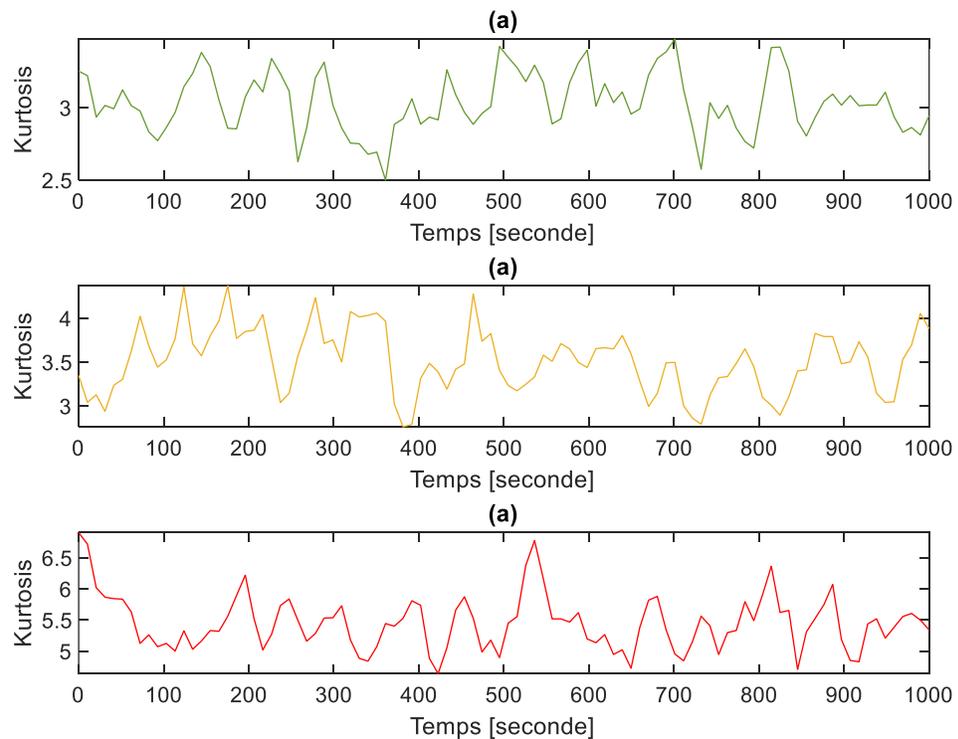


Figure 7 : Spectre de kurtosis dans le domaine temporel des signaux. (a)Signal nominal ; (b)Signal dégradé ; (c)Signal défaillant.

### 3.4.2. CARACTÉRISTIQUES FRÉQUENTIELLES

L'analyse spectrale est déterminante pour diagnostiquer l'endommagement d'un roulement, ce qui nous permet, par comparaison de l'évolution des amplitudes spectrales, de prédire le degré de détérioration du roulement et de planifier son remplacement. Dans cette partie, nous approfondirons l'utilisation de ces techniques.

La détérioration des éléments générera une ou plusieurs fréquences caractéristiques défaillantes dans les spectres de fréquences qui nous permettront une identification rapide et facile. Les quatre fréquences de défaillance de roulement possibles sont [44] :

- ✓ **BPFO** (Ball Pass Frequency Outer) ou fréquence d'échec de course externe : Qui correspond physiquement au nombre de billes ou de rouleaux qui passent par un point donné de la course extérieure à chaque fois que l'arbre effectue un tour complet.
- ✓ **BPFI** (Ball Pass Frequency Inner) ou fréquence d'échec de la course interne : Qui correspond physiquement au nombre de billes ou de rouleaux qui passent par un point donné de la piste intérieure chaque fois que l'arbre effectue un tour complet.
- ✓ **BSF** (Ball Spin Frequency) ou fréquence de défaillance des éléments roulants : Qui correspond physiquement au nombre de tours qu'une bille ou un rouleau de roulement effectue chaque fois que l'arbre effectue un tour complet.
- ✓ **FTF** (Fundamental Train Frequency) ou fréquence de défaillance de cage : Qui correspond physiquement au nombre de tours que fait la cage de roulement à chaque fois que l'arbre effectue un tour complet.

**Tableau 3 : Caractéristiques fréquentielles**

Caractéristiques	Expression mathématique
BPFO	$\frac{Nb}{2} \left( 1 - \frac{Bd}{Pd} \cos \theta \right) \times \omega \quad (3.9)$
BPFI	$\frac{Nb}{2} \left( 1 + \frac{Bd}{Pd} \cos \theta \right) \times \omega \quad (3.10)$
BSF	$\frac{Pd}{2Bd} \left[ 1 - \left( \frac{Bd}{Pd} \cos \theta \right)^2 \right] \times \omega \quad (3.11)$
FTF	$\frac{\omega}{2} \left( 1 \pm \frac{Bd \cos \theta}{Pd} \right) \quad (3.12)$

Où :

$Nb$  = Nombre de billes

$Bd$  = Diamètre des billes

$Pd$  = Pas diamétral

$\theta$  = Angle de contact

$\omega$  = La vitesse de rotation de la partie tournante

La technique la plus répandue pour extraire ce type de caractéristiques est la transformée de Fourier discrète et rapide (Fast Fourier Transform : FFT). La transformée de Fourier discrète  $X(k)$  d'un signal échantillonné  $x(n)$  composé de  $N$  échantillons est donnée par l'expression suivante :

$$X(k) = \sum_{n=0}^{N-1} x(n). e^{-2i\pi \frac{k}{N}} \quad (3.13)$$

Où :  $0 \leq k \leq N$

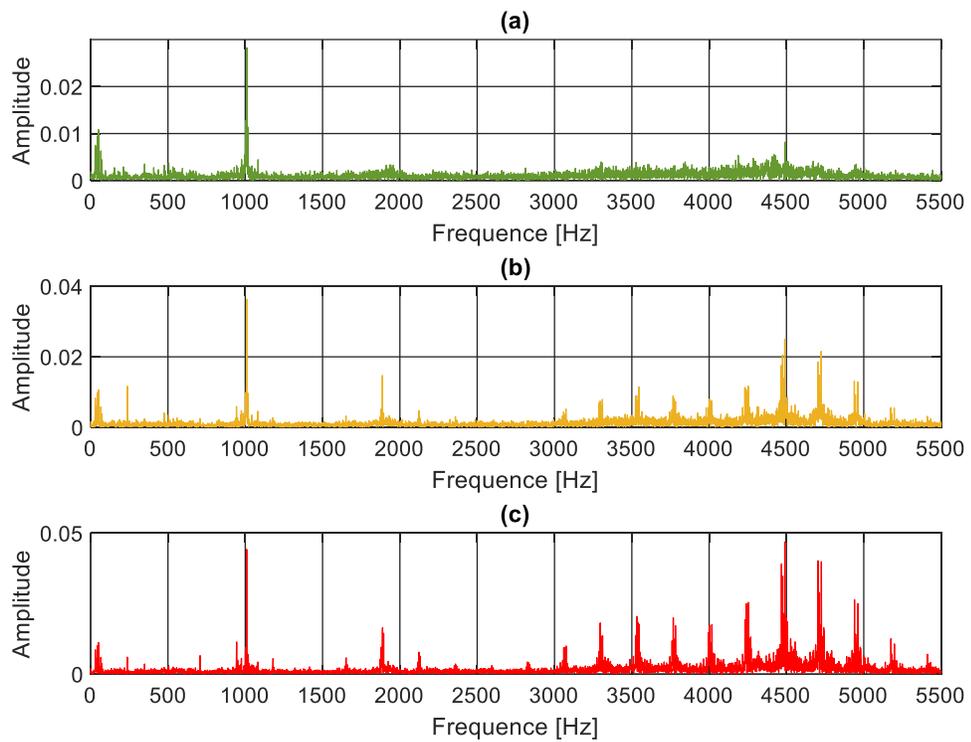


Figure 8 : Spectre d'amplitude des signaux obtenus de la FFT. (a)Signal nominal ; (b)Signal dégradé ; (c)Signal défaillant.

### **3.4.3. CARACTÉRISTIQUES TEMPS-FRÉQUENCE**

L'analyse temps-fréquence fournit les informations de distribution conjointe du domaine temporel et fréquentiel, qui illustrent clairement que la fréquence du signal variant en fonction du temps. Pour caractériser l'intensité énergétique d'un signal à différents moments et fréquences, diverses approches ont été proposées, telles que la transformée de Fourier à court terme [45], la distribution de Wigner-Ville [46] et la transformée en ondelettes continues [47]. Cependant, le calcul de ces méthodes prend trop de temps pour que le processus de classification devienne plus compliqué. Bien que de nombreuses recherches aient été menées dans le domaine du diagnostic des défauts, il est évident que très peu de littératures ont signalé l'amélioration des algorithmes pour reconnaître efficacement les défauts de taille micro [48].

### **3.4.4. LES LIMITES DES APPROCHES TEMPS-FRÉQUENCE**

La plupart des indicateurs temporels ne sont réactifs à de basses vitesses qu'à un stade assez avancé de la dégradation du roulement. Mais la limitation réelle derrière l'approche temps-fréquence est le temps de calcul et les ressources que consomme cette méthode. Étant donné que l'objectif principal est de mettre en place un système de surveillance permanente pour des machines tournantes, le temps de calcul est un paramètre très important à considérer.

### **3.5. SYSTÈME DE SURVEILLANCE D'ÉTAT DE LA MACHINE**

Dans cette partie du projet, nous avons mis en place un système largement inspiré de [40] qui explique comment extraire des caractéristiques des données mesurées pour effectuer une surveillance et des pronostics. Sur la base des fonctionnalités extraites, des modèles dynamiques sont générés, validés et utilisés pour prévoir le temps des pannes afin que des actions puissent être entreprises avant que les pannes réelles ne se produisent. Donc l'idée est d'implémenter des seuils de références dans cette approche temps-fréquence, pour que le système de surveillance soit capable de donner l'état des machines en adoptant cette approche.

### 3.6. LES ALGORITHMES DE CLASSIFICATION

Après la description de l'utilité des caractéristiques à la section 3.4. Nous constatons qu'elles servent à construire un vecteur pour la classification des défauts à l'aide d'algorithme de classification. Ces algorithmes permettent, dans la grande majorité des cas, d'obtenir de très bon taux de reconnaissance. En effet, le principe de base repose sur un ensemble de données du problème qui servent à entraîner l'algorithme de classification ce qui permet alors d'exploiter des outils puissants dans le domaine de l'apprentissage automatique. Au vu de notre objectif de recherche qu'est la détection préventive des défauts de la machine tournante, ces algorithmes semblent être la solution à déployer selon différentes stratégies d'approches.

L'apprentissage supervisé est un type d'apprentissage automatique qui utilise un jeu de données connu pour effectuer des prédictions. L'ensemble de données d'apprentissage comprend les données d'entrée et les valeurs de réponse. Les algorithmes d'apprentissage supervisé cherchent à créer un modèle capable de prédire les valeurs de réponse d'un nouvel ensemble de données. L'utilisation de jeux de données d'apprentissage plus volumineux et l'optimisation des hyperparamètres du modèle peuvent souvent augmenter le pouvoir prédictif du modèle et lui permettre de bien généraliser pour les nouveaux jeux de données. Un ensemble de données de test est souvent utilisé pour valider le modèle.

Les modèles de classification sont utilisés pour affecter des éléments à un groupe ou une classe discrète en fonction d'un ensemble spécifique de fonctionnalités. Chaque modèle a ses propres forces et faiblesses dans un scénario donné. Le choix d'un modèle de classification des données est étroitement lié à l'analyse de rentabilisation et à une solide compréhension de ce qu'on essaye d'accomplir. Le choix de la bonne approche nécessite souvent des essais et des erreurs pour atteindre le bon équilibre entre complexité, performances et précision. Les sections suivantes décrivent certains des modèles courants qui sont utiles à connaître.

Dans notre projet, nous avons utilisé la boîte à outils (Statistics and Machine Learning Toolbox) du logiciel MATLAB pour faire la classification de nos signaux qui peuvent être séparés en "classes" spécifiques. Les tests ont porté sur les algorithmes de classification suivante :

### 3.6.1. ARBRES DE DÉCISION

Un arbre de décision est un enchaînement hiérarchique de règles logiques ou de production construites de manière automatique à partir d'un ensemble de données. La construction de l'arbre de décision consiste à utiliser les descripteurs, pour subdiviser progressivement l'ensemble en sous-ensembles de plus en plus fins. L'algorithme estime la probabilité qu'une observation se trouve dans le nœud  $t$  en utilisant la formule :

$$P(T) = \sum_{j \in T} w_j \quad (3.14)$$

Où :

$w_j$  = Poids des observations,

$T$  = Ensemble de tous les indices d'observation du nœud  $t$

$n$  = Égale au nombre d'observations.

Les arbres de décision sont des algorithmes de classification de données reposant sur un apprentissage supervisé. Comme son nom l'indique, la structure de ces algorithmes ressemble à des arbres constitués de nœuds, de branches et de feuilles. La construction de ces arbres est réalisée à l'aide d'une base de données brute (vecteur des caractéristiques et classes) et de lois qui permettent de déterminer les variables discriminantes pour la classification efficace des futures données. Chacun des nœuds constituant l'arbre représente une règle de classification préalablement déterminée de manière récursive.

Dans les domaines de l'informatique décisionnelle et du forage de données, ce type d'algorithmes est très utilisé, car ils permettent de construire automatiquement des classifications et leur vitesse d'exécution surpasse tous les autres types des algorithmes. Cependant, ils ne permettent pas d'obtenir de bons résultats quand les données sont complexes.

Pour voir comment un arbre de décision prédit une réponse, il faut suivre les décisions dans l'arbre du nœud racine (début) jusqu'au nœud feuille qui contient la réponse. Les arbres de classification donnent des réponses nominales, tel que vrai ou faux et les arbres de régression donnent des réponses numériques. Les arbres de décision sont relativement rapides et faciles à suivre dans leur résolution ; vous pouvez voir une représentation complète du chemin parcouru de la racine à la feuille. Cela est particulièrement utile si vous devez partager les résultats avec des personnes intéressées par la manière dont une conclusion a été tirée.

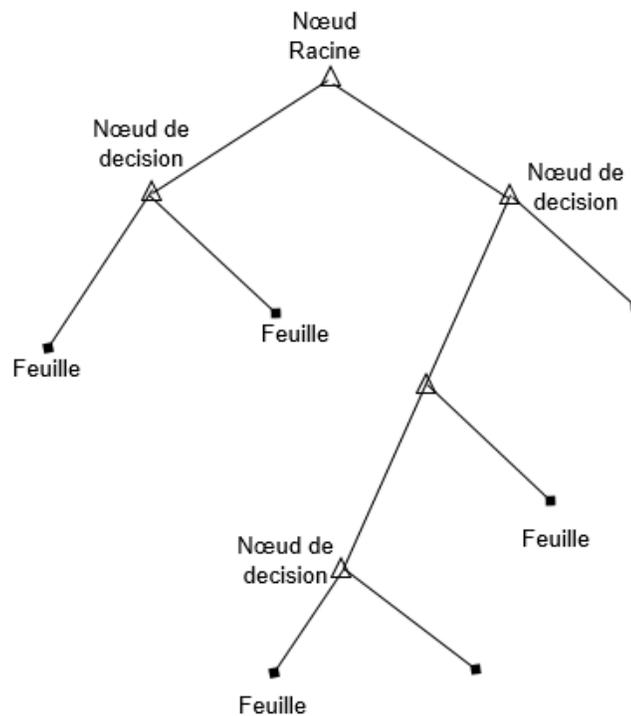


Figure 9 : Exemple d'illustration d'un arbre de décision.

### 3.6.2. MACHINES A VECTEURS DE SUPPORT (SVM)

Les machines à vecteurs de support (SVM) ont été développées à l'origine par Vapnik et ses collègues en 1992 sur la base de la théorie de l'apprentissage statistique de Vapnik & Chervonenkis dans les années 1960. Le SVM a été appliqué avec succès dans de nombreuses applications, notamment la reconnaissance manuscrite, la prédiction de séries chronologiques, la reconnaissance vocale, le problème de séquence protéique, le diagnostic du cancer du sein et bien d'autres [49].

Les machines à vecteur de support (SVM) sont utilisées lorsque les données ont exactement deux classes. L'algorithme SVM classe les données en trouvant le meilleur hyperplan qui sépare tous les points de données d'une classe de ceux de l'autre classe (le meilleur hyperplan pour un SVM est celui avec la plus grande marge entre les deux classes). L'algorithme SVM peut aussi être utilisé avec plus de deux classes, auquel cas le modèle créera un ensemble de sous-ensembles de classification binaire.

Il y a quelques avantages importants à utiliser l'algorithme SVM. Tout d'abord, il est extrêmement précis et n'a pas tendance à suradapter les données. Deuxièmement, les machines à vecteurs de support linéaire sont relativement faciles à interpréter. Parce que les modèles SVM sont très rapides, une fois que votre modèle a été formé, vous pouvez supprimer les données de formation si vous avez une capacité de mémoire disponible limitée. Il a également tendance à très bien gérer les classifications complexes et non linéaires en utilisant une technique appelée « astuce du noyau ». Cependant, les algorithmes SVM doivent être formés et réglés à l'avance, vous devez donc investir du temps dans le modèle avant de pouvoir commencer à l'utiliser. De plus, sa vitesse est fortement affectée si vous utilisez le modèle avec plus de deux classes.

L'algorithme SVM est un classificateur dit linéaire, ça veut dire que, dans le cas parfait, les données doivent être linéairement séparables. Il permet de trouver le meilleur séparateur (ligne, plan ou hyperplan) qui sépare le mieux les deux classes.

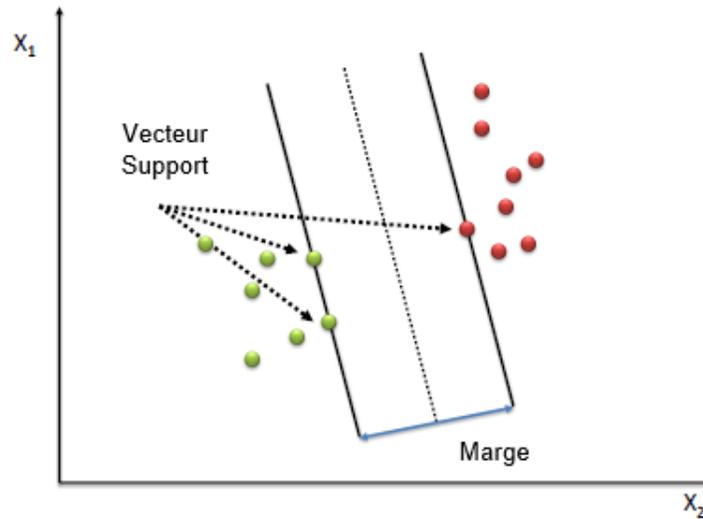


Figure 10 : Principe de l'algorithme SVM.

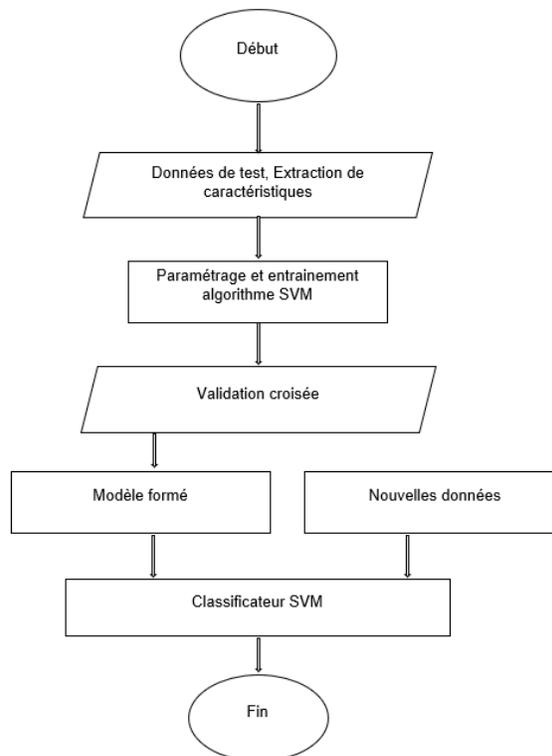


Figure 11 : Organigramme de l'algorithme SVM.

### 3.6.3. LES k-PLUS PROCHES VOISINS (k-NN)

L'algorithme des k-plus proches voisins (k-NN) se base sur les données en entier. En effet, pour une observation, qui ne fait pas partie des données, qu'on souhaite prédire, l'algorithme va chercher les k instances les plus proches de notre observation et choisir pour chaque observation la classe majoritaire parmi ses k plus proches voisins.

La méthode k-NN est une technique d'apprentissage supervisé, et est considérée comme l'une des plus simples dans le domaine de la classification. Elle permet de classer une nouvelle observation (vecteur de caractéristiques extraites) en calculant la distance avec les données d'entraînement, et de prendre les k plus proches voisins (en termes de distance). Puis, observé la classe qui est majoritairement représentée parmi les k-plus proches voisins et d'assigner cette classe à la nouvelle observation.

Bien que le temps d'apprentissage de l'algorithme k-NN soit court, le temps de requête réel (et l'espace de stockage) peut être plus long que celui des autres modèles. Cela est particulièrement vrai lorsque le nombre de points de données augmente, car toutes les données d'entraînement doivent être conservées, mais pas seulement l'algorithme.

Le plus grand inconvénient de cette méthode est qu'elle peut être erronée par des attributs non pertinents qui masquent des attributs importants. Il existe des moyens de corriger ce problème, par exemple en appliquant des pondérations aux données. Comme nous l'avons détaillé ci-dessus, l'algorithme k-NN calcule la distance entre les points de données. Pour cela, nous utilisons la formule de la distance euclidienne :

$$d(p, q) = d(q, p) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2}$$

$$d(p, q) = d(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (3.15)$$

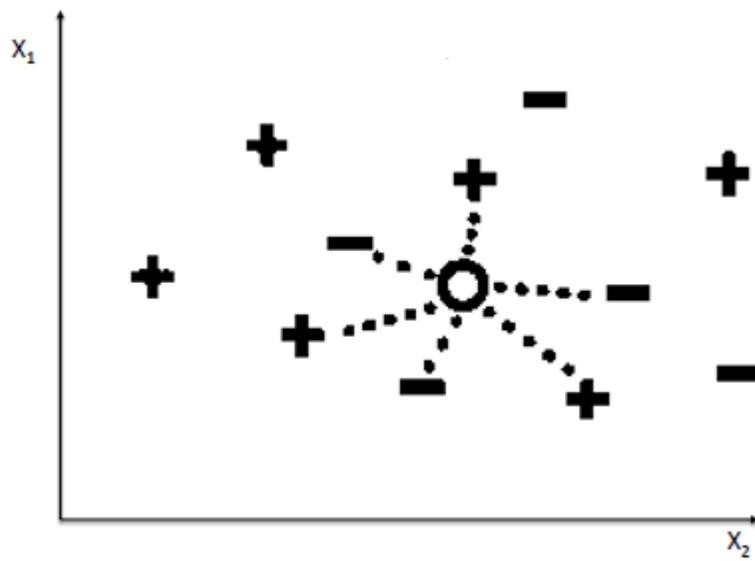


Figure 12 : Principe de l'algorithme k-NN.

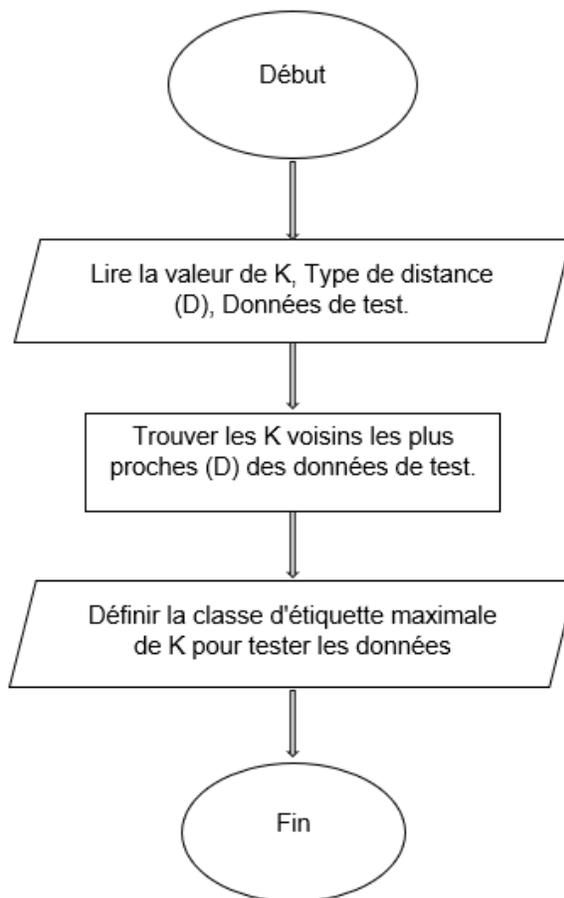


Figure 13 : Organigramme de l'algorithme KNN.

### 3.6.4. NAÏVE BAYES

Si les données ne sont pas complexes et que la tâche est relativement simple, les algorithmes Naïve Bayes peuvent être utilisés. Il s'agit d'un classificateur qui présente des avantages par rapport aux algorithmes de régression logistique et de l'algorithme k-plus proche voisin, lorsqu'il travaille avec une quantité limitée de données disponibles pour former un modèle.

L'algorithme Naïve Bayes est également un bon choix lorsque les ressources CPU et mémoire sont un facteur limitant. Parce qu'il est très simple, il n'a pas tendance à surcharger les données et peut être formé très rapidement. Il fonctionne également bien avec les nouvelles données continues utilisées pour mettre à jour le classificateur. Si la taille et la variance des données augmentent et que vous avez besoin d'un modèle plus complexe, d'autres classificateurs fonctionneront probablement mieux. De plus, sa simple analyse n'est pas une bonne base pour des hypothèses complexes.

L'algorithme Naïve Bayes est souvent le premier algorithme que les scientifiques essaient d'utiliser pour analyser du texte. C'est un algorithme de classification qui applique une estimation de densité aux données. L'algorithme exploite le théorème de Bayes et suppose que les données prédites sont conditionnellement indépendantes. C'est un classificateur probabiliste, qui est basé sur le théorème de Bayes :

$$P(A/B) = \frac{P(B/A) \cdot P(A)}{P(B)} \quad (3.16)$$

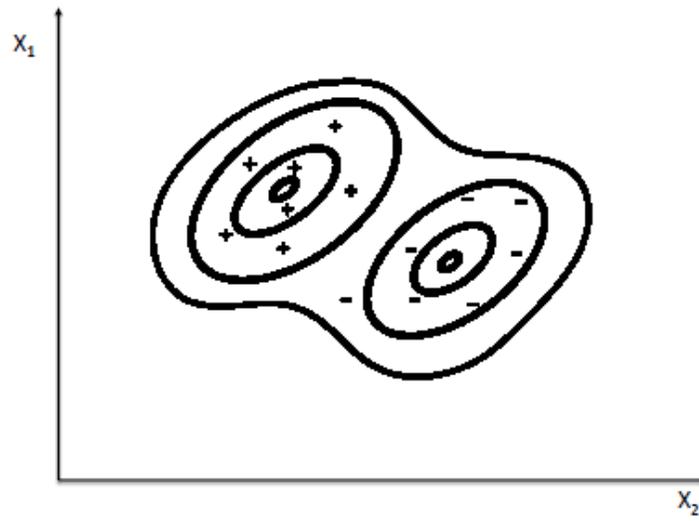


Figure 14 : Principe de l'algorithme Naïve Bayes.

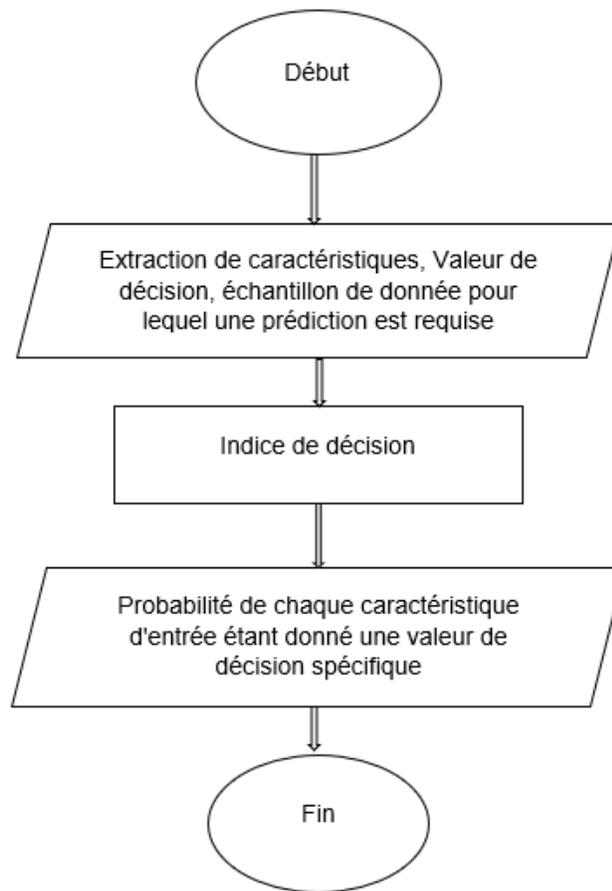


Figure 15 : Organigramme de l'algorithme Naïve Bayes.

### 3.6.5. RÉSEAUX NEURONES ARTIFICIELS (ANN)

Les réseaux neurones artificiels sont des méthodes d'apprentissage supervisé et non supervisé qui tentent d'imiter la pensée humaine par la modélisation simplifiée des systèmes neuronaux du cerveau de l'homme. L'intention n'est pas de modéliser le mécanisme exact du fonctionnement biologique des cellules neurales dans le cerveau ni de créer un clone biologique. Au lieu de cela, la biologie n'est que la source d'inspiration. L'élément de traitement unitaire est un modèle simple appelé neurone. Chaque neurone est fondamentalement une fonction pouvant recevoir plusieurs entrées et ne produire qu'une sortie. La combinaison de plusieurs neurones en un réseau de neurones est-ce que nous avons appelé réseau de neurones artificiels [50].

Ce concept fut introduit pour la première fois en 1943 par McCulloch qui a proposé la première définition de neurone formel [51]. Puis, en 1957, Rosenblatt réalisa le premier réseau avec une couche d'entrée et de sortie afin de simuler le fonctionnement rétinien dans la reconnaissance de forme [52]. Depuis cette époque et au travers des puissances computationnelles qui ne cessent d'augmenter, il a été développé un nombre non négligeable de différents types de réseaux neurones artificiels [53]. Quelques exemples d'algorithmes de réseaux de neurones : McCulloch and Pitts, Perceptron, ADaptive Linear Neuron (ADALINE), Multi-Layer Perceptron (MLP), Many ADaptive Linear Neuron (MADALINE) et Back Propagation Network.

Un réseau de neurones artificiels (ANN) peut apprendre et donc être formé pour trouver des solutions, reconnaître des modèles, classer des données et prévoir des événements futurs. Les réseaux de neurones artificiels sont utilisés pour résoudre des problèmes plus complexes, tels que la reconnaissance des caractères, la prédiction boursière et la compression d'image. Le comportement d'un réseau de neurones est défini par la façon dont ses éléments individuels

sont connectés et par les forces de ces connexions, ou poids. Les poids sont automatiquement ajustés en entraînant le réseau selon une règle d'apprentissage spécifiée jusqu'à ce qu'il exécute correctement la tâche souhaitée.

Les réseaux de neurones artificiels sont excellents pour modéliser des données non linéaires avec un grand nombre de fonctionnalités d'entrée. Lorsqu'ils sont utilisés correctement, les ANN peuvent résoudre des problèmes qui sont trop difficiles à résoudre avec un algorithme simple. Cependant, les réseaux de neurones sont coûteux en calcul, il est difficile de comprendre comment un réseau de neurones artificiels a atteint une solution.

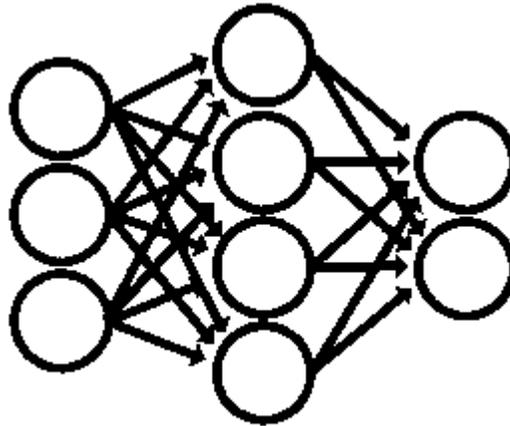


Figure 16 : Principe des réseaux de neurones artificiels.

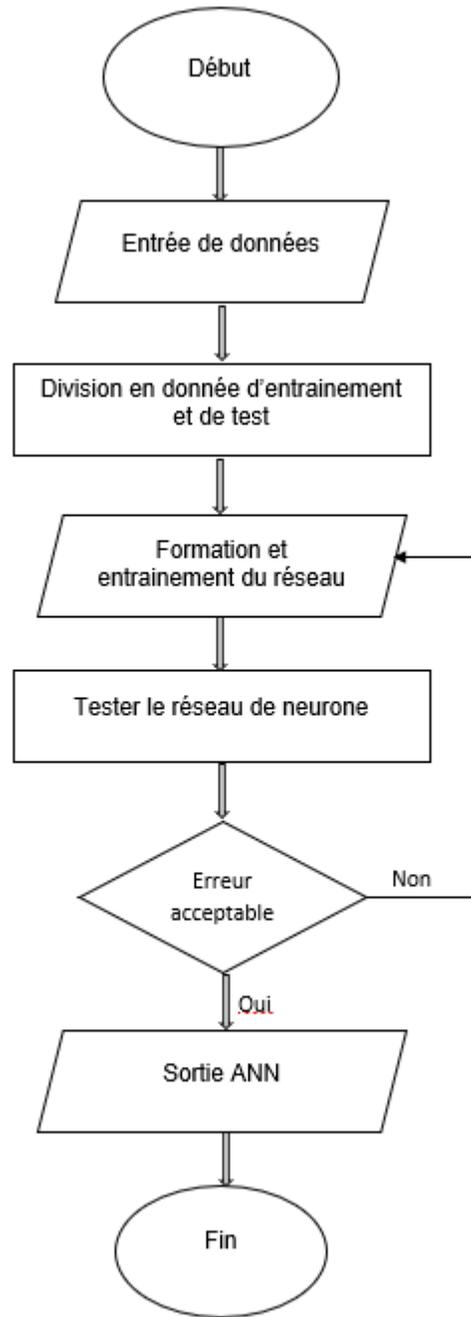


Figure 17 : Organigramme de l'algorithme ANN.

### 3.7 CONCLUSION

À travers cette section, nous avons démontré la méthodologie utilisée pour réaliser notre projet de recherche. Il faut retenir que les principales étapes pour la classification des signaux se font par une acquisition des signaux recueillis des capteurs placés sur les équipements et suivis d'une phase de prétraitement de ces signaux recueillis. Ensuite, il faut extraire les caractéristiques qui sont indispensables pour entraîner nos algorithmes de classification. L'objectif principal dans notre travail de recherche est de se servir de cette base pour réaliser une solution qui permet d'améliorer le processus de maintenance dans les industries. Nous devons alors mettre en place une stratégie de détection des défauts qui combine une analyse des fréquences de fonctionnement grâce à notre système de surveillance de l'état de la machine et les algorithmes de classifications. Ainsi, à la section suivante nous allons présenter les différents résultats que nous avons obtenus en appliquant cette méthodologie.