

## CHAPITRE 2

### CADRE THÉORIQUE ET REVUE DE LA LITTÉRATURE

#### 2.1. INTERNET DES OBJETS (IoT)

##### 2.1.1. DÉFINITION

L'Internet des objets (IoT) permet à des objets et des appareils qui jadis fonctionnaient de manière isolée et non connectée de se détecter, de communiquer, d'interagir et de collaborer au sein d'un même réseau.

Selon la définition de l'Union internationale des télécommunications (UIT) « L'Internet des objets : est une infrastructure mondiale pour la société de l'information, qui permet de disposer de services évolués en interconnectant des objets (physiques ou virtuels) grâce aux technologies de l'information et de la communication interopérables existantes ou en évolution » [10].

L'Internet des objets se veut l'avenir de l'Internet actuel. Il est généralement défini comme un réseau de périphériques ou d'objets physiques et virtuels capables de collecter des données environnantes et de les échanger entre eux ou via Internet. Pour permettre la collecte de données, il faut intégrer aux périphériques des capteurs, des logiciels et des composants électroniques ; les échanges sont rendus possibles en les connectant à des réseaux locaux ou à Internet. Les origines de l'Internet des objets sont diffuses. Bien que le mot ait été inventé pour la première fois en 1999 par Kevin Ashton, cofondateur et directeur exécutif du centre Auto-ID du MIT, pour des entreprises telles que CISCO, l'IoT est né en 2009, lorsque plus d'appareils que de personnes étaient connectés au réseau internet. À cette époque, le nombre

d'appareils connectés s'élevait à 10 milliards, mais les attentes sont nombreuses. On pense que d'ici 2020, plus de 50 milliards d'appareils seront connectés à Internet [11].

La prolifération des capteurs et des puces à bas prix permet de concevoir des systèmes électroniques moins coûteux et permet la communication des données entre les objets connectés. En plus de cela, nous avons les différentes évolutions rapides dans le domaine des réseaux sans fil et de l'infrastructure infonuagique (Cloud) qui propose des solutions et des plateformes avancées spécialement conçu pour l'internet des objets. L'ensemble de ces facteurs influencent le développement de cette nouvelle étape de l'internet et la culture d'objet connecté au sein du grand public.

### **2.1.2. CONCEPT DE L'loT**

L'loT donne aux TIC une nouvelle dimension en ce sens que, grâce à lui, la communication est non seulement possible en tout lieu et à tout moment, comme c'était déjà le cas, mais aussi avec n'importe quel OBJET. Dans l'loT, les objets sont représentés par des objets du monde physique (objets physiques) ou du monde de l'information (objets virtuels), pouvant être identifiés et intégrés dans des réseaux de communication. Au fil du temps, le terme loT a évolué et est décrit comme un réseau d'entités connectées via n'importe quel type de capteur, permettant à ces entités, appelées objets physiques ou virtuels connectés à Internet, d'être localisées, identifiées et même exploitées.

Les objets physiques appartiennent au monde physique et peuvent être détectés, commandés et connectés. L'environnement qui nous entoure, les robots industriels, les biens et les équipements électriques sont autant d'exemples d'objets physiques. Et les objets virtuels appartiennent au monde de l'information ; on peut les stocker, les traiter et y accéder. Ces objets sont par exemple des contenus multimédias ou des logiciels [10].

### 2.1.3. ARCHITECTURE ET PROTOCOLE DES IoT

#### ➤ ARCHITECTURE

Dans cette partie, nous allons présenter l'architecture IoT et les protocoles généralement utilisés pour cette technologie. L'architecture IoT peut être considérée comme un système physique, virtuel ou qui regroupe les deux donc hybride.

Elle consiste ainsi à un regroupement d'ensembles d'objets physiques, de capteurs, de couches de communication, d'utilisateurs, et une couche application. Des architectures particulières agissent en tant que composant pivot d'une infrastructure spécifique à l'IoT, et les principales parties qui constituent cette architecture peuvent être regroupées en trois grands groupes. Nous avons d'abord la partie composée d'un parc d'objets connectés fixes ou mobiles, répartis géographiquement. Ensuite, nous avons la partie réseau qui va permettre de connecter les objets à internet ou entre eux pour transmettre les données, ce réseau peut être filaire ou sans-fil, court ou longue portée. Et enfin la partie application, développée le plus souvent en technologie web ou une application sur un téléphone intelligent qui collecte les données du réseau d'objets pour fournir une information traitée, compréhensible et qui permet de prendre une décision [12].

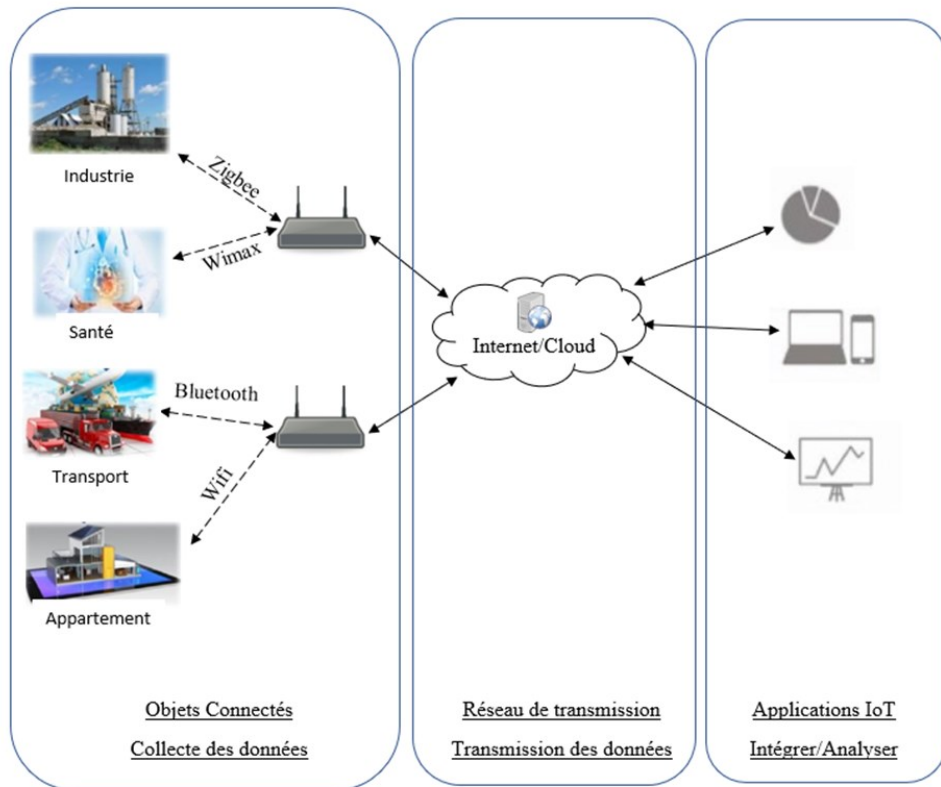


Figure 1 : Architecture des réseaux IoT

## ➤ PROTOCOLES

Les protocoles de communication constituent l'épine dorsale des systèmes IoT et permettent la connectivité au réseau et le couplage aux applications. Les protocoles de communication permettent aux appareils d'échanger des données via le réseau. Les protocoles définissent les formats d'échange de données, le codage des données, les schémas d'adressage pour les périphériques et le routage des paquets de la source à la destination. Les autres fonctions des protocoles incluent le contrôle de séquence, le contrôle de flux et la retransmission de paquets perdus. Dans cette partie, nous allons comparer différentes technologies de communication sans fil par rapport à divers paramètres [12].

✓ **802.11 – WiFi**

Le WiFi est basé sur la norme IEEE (802.11), c'est une collection de normes de communication pour les réseaux locaux sans fil (WLAN). Par exemple, le (802.11a) fonctionne dans la bande des 5 GHz, le (802.11b) et le (802.11g) dans la bande des 2,4 GHz, le (802.11n) dans les bandes des 2,4/5 GHz, le (802.11 ac) dans la bande des 5 GHz et le (802.11 ad) dans les bandes de 60GHz. Ces normes fournissent des débits allant de 1 Mb/s à 6,75 Gb/s. Le WiFi offre une portée de communication de l'ordre de 20 m (intérieur) à 100 m (extérieur).

✓ **802.16 - WiMax**

Le WiMax est basé sur la norme IEEE (802.16), c'est un ensemble de normes large bande sans fil. Les normes WiMAX fournissent des débits de données compris entre 1,5 Mb/s et 1 Gb/s. La mise à jour récente (802,16 m) fournit un débit de données de 100 Mb/s pour les stations mobiles et de 1 Gb/s pour les stations fixes. Les spécifications sont facilement disponibles sur le site Web du groupe de travail IEEE 802.16 [13].

✓ **802.15.4 - LR-WPAN**

LR-WPAN est basé sur la norme IEEE (802.15.4), c'est une collection de normes LR-WPAN (Wireless Personal Area Networks). Ces normes constituent la base des spécifications pour les protocoles de communication de haut niveau tels que ZigBee. Les normes LR-WPAN fournissent des débits allant de 40 kb/s à 250 kb/s. Ces normes permettent une communication à faible coût et à faible vitesse avec des périphériques soumis à des contraintes d'alimentation. Il fonctionne respectivement aux fréquences de 868/915 MHz et 2,4 GHz à des débits de données faibles et élevés. Les spécifications des normes (802.15.4) sont disponibles sur le site Web du groupe de travail IEEE802.15 [14].

✓ **2G / 3G / 4G - communication mobile**

Il existe différentes générations de normes de communication mobile, notamment les normes de deuxième génération (2G, notamment GSM et CDMA), de troisième génération (UMTS et CDMA2000 de troisième génération) et de quatrième génération (LTE, notamment de 4G). Les appareils IoT basés sur ces normes peuvent communiquer sur des réseaux cellulaires. Les débits de données pour ces normes vont de 9,6 kb/s (2G) à 100Mb/s (4G) et sont disponibles sur les sites Web de 3GPP.

✓ **802.15.1 - Bluetooth**

Bluetooth est basé sur la norme IEEE (802.15.1). Il s'agit d'une technologie de communication sans fil à faible consommation d'énergie qui convient à la transmission de données entre appareils mobiles sur une courte distance (8 à 10 m). La norme Bluetooth définit une communication PAN (Personal Area Network). Il fonctionne dans la bande 2,4 GHz. Le débit de données dans différentes versions du Bluetooth varie de 1 Mb/s à 24Mb/s. La version ultra basse consommation et à faible coût de cette norme porte le nom Bluetooth Low Energy (BLE ou Bluetooth Smart). Auparavant, en 2010, BLE avait fusionné avec la norme Bluetooth v4.0.

✓ **LoRaWAN R1.0 - LoRa**

LoRaWAN est un protocole de communication à longue portée récemment développé par LoRa™ Alliance, une association ouverte et à but non lucratif. Son objectif principal est de garantir l'interopérabilité entre différents opérateurs dans une norme mondiale et ouverte. Les débits de données LoRaWAN vont de 0,3 kb/s à 50 kb/s. LoRa fonctionne dans les bandes ISM 868 et 900MHz. Selon Postscapes, LoRa communique entre les nœuds connectés dans un rayon de 20 miles (30 km), dans des environnements non obstrués. La durée de vie de la batterie dépend de l'utilisation du nœud.

#### 2.1.4. SÉCURITÉ DES RÉSEAUX IoT

La tâche principale de l'IoT est d'interconnecter une multitude d'objets hétérogènes via Internet. Ces objets produiront un trafic beaucoup plus important sur le réseau, car davantage de données seront stockées. Par conséquent, une sécurité efficace pour l'IoT doit traiter de nombreux aspects tels que la confidentialité et la sécurité.

Certaines applications IoT prennent en charge des infrastructures sensibles et des services stratégiques tels que le réseau intelligent et la protection des installations. D'autres applications IoT généreront de plus en plus d'énormes quantités de données personnelles sur la situation des ménages, de la santé et des finances que les entreprises pourront exploiter pour leurs activités. L'absence de sécurité et de confidentialité créera une réticence à l'adoption de l'IoT par les entreprises et les particuliers. Il est possible de résoudre les problèmes de sécurité en formant les concepteurs de logiciels à intégrer des solutions de sécurité (systèmes de prévention des intrusions, pare-feu, par exemple) dans leurs produits et en encourageant les utilisateurs à utiliser les fonctionnalités de sécurité IoT intégrées à leurs appareils [15].

De plus en plus d'appareils connectés sont introduits dans les réseaux IoT, la menace potentielle pour la sécurité s'intensifie. Bien que l'IoT améliore la productivité des entreprises et améliore la qualité de vie des personnes, l'IoT augmentera également les surfaces d'attaque potentielles pour les pirates informatiques et autres cybercriminels. Une étude récente de Hewlett Packard (2014) a révélé que 70% des périphériques IoT les plus couramment utilisés contiennent de graves vulnérabilités. Les périphériques IoT présentent des vulnérabilités en raison d'un manque de cryptage de transport des données, d'interfaces Web non sécurisées, d'une protection insuffisante des logiciels et d'un niveau d'autorisation insuffisant. Les périphériques sur l'IoT n'utilisent généralement pas de techniques de cryptage de données[16].

### **2.1.5. DOMAINE D'APPLICATION DES IoT**

La disponibilité d'une large gamme de capteurs et d'appareils de différentes tailles et de capacités de calcul diverses fait de l'IoT un paradigme de premier plan pour permettre l'innovation dans différents domaines d'application. Les principaux domaines d'application des solutions IoT peuvent être regroupés comme suit : bâtiment [17, 18], environnement [19, 20], industrie, santé [21], transport et sécurité [22].

#### **➤ DOMAINE INDUSTRIEL**

Typiquement, le terme IoT industriel désigne l'utilisation de la technologie IoT pour la gestion du processus de fabrication. Dans ce contexte, l'IoT exploite les technologies de communication et d'automatisation de machine à machine (M2M) mise en œuvre depuis des années dans l'industrie. Les données acquises par les capteurs, par exemple les étiquettes RFID placées sur les articles, permettent aux entreprises de résoudre de manière rapide et efficace tous les problèmes rencontrés au cours du processus de la chaîne d'approvisionnement et de livraison, ce qui permet d'économiser du temps et de l'argent. Ce processus nécessite des conditions de travail restreintes, telles que des environnements soumis à des processus de travail à température contrôlée et à humidité contrôlée. Une autre application de la solution IoT dans le domaine industriel concerne le marché de la vente au détail. Par exemple, les technologies d'identification peuvent aider à lutter contre la contrefaçon en suivant tout le cycle de vie d'un produit, y compris des informations sur son emplacement et en précisant le processus de transport.



## ➤ **DOMAINE DE LA SÉCURITÉ**

L'utilisation de technologies compatibles avec l'IoT constitue une excellente application pour sécuriser les infrastructures critiques, telles qu'une infrastructure de production d'énergie, un stade, un port, une banque ou un autre environnement public. La surveillance par des capteurs peut fournir des informations sur la présence de personnes et leur comportement ou détecter des substances dangereuses dans l'air. La RFID ou d'autres technologies d'identification peuvent détecter si une personne est autorisée à rester dans une zone réglementée. Des capteurs peuvent surveiller la température des équipements industriels afin de vérifier s'ils fonctionnent en toute sécurité, que ce soit pour l'opérateur humain ou pour l'environnement. Bien entendu, plus les sources d'informations disponibles sont nombreuses, plus le système d'alerte sera efficace. Par ailleurs, une utilisation excessivement invasive de telles technologies peut donner lieu à des atteintes à la vie privée.

## **2.2. CLOUD COMPUTING**

La technologie en infonuagique (Cloud computing) est devenue une alternative réseau distribuée à hautes performances et à faible coût. Elle fournit des solutions de virtualisation matérielle, « la virtualisation : technologie qui extrait les détails du matériel physique et fournit des ressources virtualisées pour des applications de haut niveau » [23]. Il fournit un accès aux données à haute vitesse et une puissance de calcul complexe aux problèmes d'ingénierie à grande échelle via Internet. Internet est l'épine dorsale de la technologie cloud computing [24].

Avec la technologie cloud computing, une entreprise n'a pas besoin de posséder un matériel et des processeurs (GPU) coûteux pour résoudre des problèmes d'ingénierie complexes. Au lieu de cela, ils peuvent acheter un espace de stockage et une puissance de calcul haute performance sous forme de service, « matériel en tant que service (HaaS) et logiciel en tant que service (SaaS) ». Le cloud computing comprend le stockage matériel, les systèmes

d'exploitation, l'environnement d'exécution du programme, la base de données, le développement d'applications, les tests et la plateforme de déploiement. Les fournisseurs de services informatiques célèbres qui offrent des services en nuage sont entre autres : Microsoft, Google et Amazon [23].

### **2.3. BIG DATA**

L'analyse des données massives et l'intelligence d'affaires transforment les données en renseignements exploitables, en modèles prédictifs, en outils d'aide à la décision et en tableaux de bord.

Compte tenu des gigantesques volumes d'informations générés par les appareils connectés dans les chaînes de valeur du secteur de la fabrication, on peut dire que le Big Data se transforme progressivement en « Thing » Data. Les capteurs des appareils périphériques connectés peuvent théoriquement enregistrer leur comportement et leur statut en continu. Ces données d'événements sont alors filtrées, puis agrégées dans des référentiels Big Data gérés par l'intermédiaire de bases de données NoSQL. La recherche à partir du Big Data est ainsi à l'origine de solutions et de diagnostics proactifs, qui permettent d'anticiper et bien souvent d'éviter des incidents susceptibles d'engendrer d'onéreux processus de maintenance [8].

### **2.4. INDUSTRIE 4.0**

Les quatre grandes révolutions industrielles sont illustrées par une première révolution qui a été celle des machines à vapeur vers 1780. La deuxième fut celle de la production de masse avec l'électricité et le travail à la chaîne à partir de 1870. Ensuite vient la troisième révolution industrielle soit celle de l'automatisation, de l'électronique et des robots. De nos jours, plusieurs industries sont à cette étape dans leurs usines et d'autres sont toujours à la deuxième étape.

Aujourd'hui, nous sommes au stade de la quatrième grande révolution industrielle : celle de l'internet des machines industrielles et de l'usine intelligente. Les particularités de cette révolution très perturbatrice sont multiples. Il y'a par exemple : la rapidité à laquelle elle se déploie mondialement, le haut niveau de compétence exigée et la complexité accrue dans la gestion des données. L'intelligence artificielle devient de plus en plus la clé de voûte « incontournable » permettant d'utiliser de façon optimum la masse de données disponibles.

L'internet des objets, et plus particulièrement les technologies Machines à Machines liées au concept de l'Industrie 4.0, sont entraînent de prendre leur envol en Europe, avec comme leader, l'Allemagne. Selon une étude réalisée en 2015 par PwC& Strategy, le marché européen des machines connectées et intelligentes est appelé à exploser au cours des prochaines années. Au Québec et au Canada, l'utilisation de machines intelligentes ultra-efficaces permettra à l'industrie manufacturière de relever rapidement les défis tels que : l'augmentation de la productivité, la flexibilité de la production face aux besoins changeants des clients et surtout la résolution de la grave pénurie de main-d'œuvre annoncée par le vieillissement de la population active. Les cinq axes de technologies cités entourant l'usine intelligente ci-dessous amèneront rapidement les machines à apprendre, à prédire et à s'adapter à la production [25].

Il s'agit de :

- ✓ La robotique collaborative ;
- ✓ L'autoadaptation des systèmes de production ;
- ✓ La réalité virtuelle ou augmentée ;
- ✓ L'impression 3D.
- ✓ Et des capteurs intelligents et connectés ;

## **2.5. TYPES DE MAINTENANCE**

De nombreux types de maintenance coexistent afin de fournir aux industriels la possibilité d'optimiser leurs chaînes de production. Chaque entreprise définit donc ses besoins en matière de maintenance industrielle et met en place une stratégie de planification.

La maintenance est la combinaison de toutes les actions techniques et des actions administratives correspondantes, y compris les opérations de surveillance et de contrôle, destinées à maintenir ou à remettre une entité dans un état lui permettant d'accomplir une fonction requise [26]. Beaucoup de recherches sur la surveillance des roulements ont été faites vu l'importance de ces composantes dans l'industrie et la nécessité de faire un suivi fréquent et fiable. On distingue plusieurs types de mesures exploitées en industrie entre autres les analyses surs : les vibrations, l'huile et les mesures de température. Nous allons dans cette partie du mémoire présenter les principaux types de maintenance industrielle.

### **2.5.1. LA MAINTENANCE CORRECTIVE**

Comme l'indique son nom, la maintenance corrective vise à corriger les défauts de fonctionnement de tout équipement ou ligne de production dès leur apparition. Si la panne qui perturbe le processus de production n'a pas été anticipée par d'autres types de maintenance, comme la maintenance préventive, les techniciens chargés de la maintenance industrielle s'occupent de la résolution du problème dès leur survenue. Il s'agit ici d'une maintenance préventive non planifiée ou maintenance curative. Ce type d'intervention peut coûter cher aux entreprises.

### **2.5.2. LA MAINTENANCE PRÉVENTIVE**

Ce type de maintenance s'applique par les techniciens chargés de la maintenance industrielle en amont de toute apparition de panne ou de dysfonctionnement. Elle touche aux pièces détachées, aux composants ainsi qu'aux machines et aux équipements afin de réduire le risque d'échec ou de défaillance. La numérisation des entreprises industrielles a apporté de nombreuses solutions technologiques permettant aux techniciens d'effectuer, suivre et planifier la maintenance préventive efficacement.

### **2.5.3. LA MAINTENANCE PRÉDICTIVE**

L'émergence des solutions de traitement et d'analyse des données ainsi que de l'intelligence artificielle a permis aux industriels de planifier une maintenance prédictive ou prévisionnelle qui se base sur la prédiction des pannes et des dysfonctionnements. Ce type de maintenance industrielle permet aux entreprises d'anticiper les problèmes en planifiant les interventions nécessaires basées sur les prédictions. Elle permet ainsi de limiter les dépenses causées par les pannes inattendues et la perturbation de la production.

## **2.6. ANALYSE ET CLASSIFICATION DE DONNÉES**

En définition, l'analyse de données est un ensemble de méthodes descriptives ayant pour objectif de résumer et visualiser l'information pertinente contenue dans un grand tableau de données.

Les énormes progrès techniques récents en matière de puissance de calcul et de traitement, de capacité de stockage et d'interconnexion des différentes technologies de l'information ont créé des quantités sans précédent de données numériques. L'exploration de données est la science consistant à extraire des connaissances utiles de tels dépôts de données.

Elle est devenue un domaine en pleine croissance et interdisciplinaire en informatique. Les techniques d'extraction de données ont été largement appliquées aux problèmes de l'industrie, de la science et de l'ingénierie, ce qui prouve que l'extraction de données aura un impact profond sur notre société [27].

### **2.6.1. ANALYSE DE DONNÉE**

De nos jours, le volume des données collectées ne cesse d'augmenter exponentiellement et le critère du temps devient important. De ce fait, les techniques de classification automatique de données sont devenues très importantes pour faciliter l'exploitation de ces données. Plusieurs recherches et études ont été réalisées dans le domaine de la classification de forme pour permettre de mieux comprendre et d'exploiter les données surtout dans le cas où ces données sont de volume important et que les critères de sélection sont moins visibles.

Le processus de la classification de formes commence par une première étape d'acquisition et de prétraitement pour éliminer les différents bruits des données enregistrées. La deuxième étape consiste à définir les différentes caractéristiques à utiliser lors de la classification. Parmi ces caractéristiques, on trouve la moyenne, l'écart-type, la médiane. L'étape suivante consiste à développer le classificateur pour reconnaître les différentes classes et la dernière étape permet d'évaluer et valider le système de classification [28].

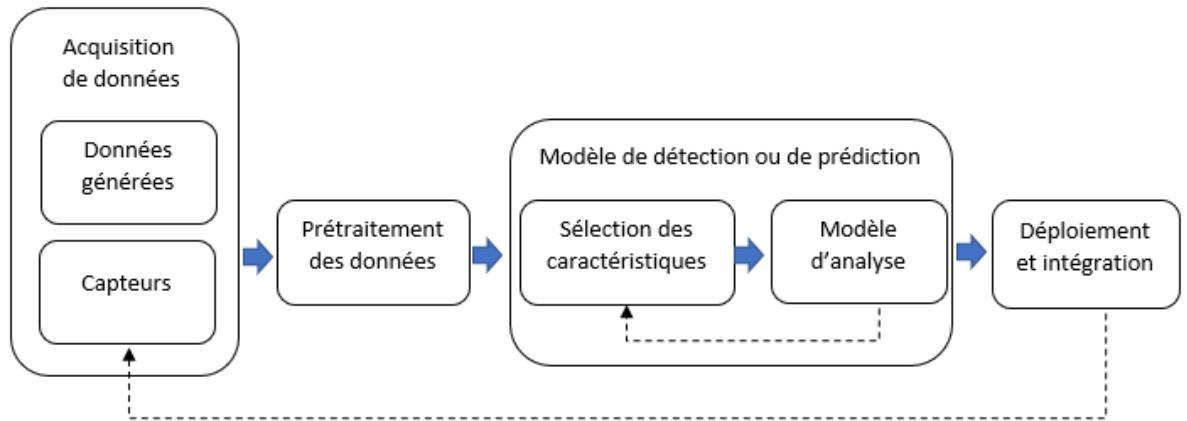


Figure 2 : Étapes d'analyse de donnée (classification) [29].

➤ **ACQUISITION DES DONNÉES :**

Le but de l'acquisition de données est d'importer les données mesurées et générées par les capteurs et les organiser pour une utilisation dans les applications d'analyse de données.

➤ **PRÉPARATION ET PRÉTRAITEMENT DES DONNÉES :**

Cette étape de l'analyse de données inclut le filtrage, le traitement dans le domaine temporel, le traitement dans le domaine fréquentiel et l'interpolation des signaux à étudier. Il est souvent nécessaire de nettoyer les données et les convertir dans un formulaire à partir duquel on pourra extraire des indicateurs de condition de prétraitement des données.

Généralement, le prétraitement consiste à nettoyer et transformer les données à analyser pour identifier et extraire des indicateurs de condition prometteuse. La maîtrise du type de système et du type de données à étudier permet de déterminer quelles méthodes de prétraitement seront utilisées.

➤ **TRANSFORMATION ET SÉLECTION DES CARACTÉRISTIQUES D'ANALYSE :**

Le but de cette étape est d'identifier les caractéristiques qui permettent de discriminer les différentes classes. Dans le cadre de l'analyse de l'activité physique, Oscar et al [30] ont recensé deux types de caractéristiques :

- ✓ Les caractéristiques basées sur la fréquence (caractéristiques fréquentielles).
- ✓ Les caractéristiques basées sur le temps (caractéristiques temporelles) telles que la moyenne, la médiane, l'écart-type, l'interquartile [31].

D'autres types de caractéristiques qui permettent une représentation globale peuvent être utilisées. En l'occurrence, l'analyse en composantes principales (ACP) qui est une méthode d'analyse de données très connue en statistique et dans les sciences expérimentales. Elle consiste à rechercher les directions de l'espace qui représentent le mieux les corrélations dans un ensemble de données. Ceci a pour objectifs de réduire la dimension des caractéristiques et de les visualiser afin d'analyser les corrélations entre ces données [28].

➤ **EXPLORATION ET CRÉATION DU MODÈLE DE CLASSIFICATION DES DONNÉES :**

La classification de formes est « l'opération qui consiste à grouper formellement des éléments de configuration, des incidents, des problèmes ou des changements, en fonction de leur type » (Office québécois de la langue française, 2005). En d'autres termes, la classification de formes consiste à affecter un objet à une classe correspondante en se basant sur ses caractéristiques. Les méthodes de classification de formes peuvent être réparties en deux types. La classification supervisée et la classification non supervisée [28].



## ➤ INTERPRÉTATION ET ÉVALUATION :

L'évaluation d'un système de classification se base généralement sur un partage de la base de données en trois domaines aussi appelés sous-bases :

- ✓ D'apprentissage utilisé pour la conception du système de classification ;
- ✓ De test utilisé pour sélectionner l'architecture du système de classification ;
- ✓ De validation utilisée pour valider la pertinence de l'architecture choisie.

La distinction entre les deux premières bases est nécessaire pour ne pas fausser les tests de classification en testant sur des échantillons ayant servi pour la conception. La troisième sous-base permet d'obtenir une validation indépendante des critères de sélection. Dans certains cas, la taille de la base de données ne permet pas d'avoir un partage en trois sous-bases ; dans ce cas, on utilise uniquement un partage en deux : une sous-base d'apprentissage et une sous-base de tests [28].

## ➤ DÉPLOIEMENT :

Le déploiement ou intégration d'un algorithme d'analyse de données est généralement la dernière étape du flux de travail pour la conception d'un système de classification. Elle représente la mise en exploitation du système.

## 2.6.2. CLASSIFICATION DE DONNÉES

La première étape d'un projet d'apprentissage automatique est la récupération et l'importation des données. Malheureusement, dans des projets réels, nous obtenons régulièrement des fichiers incomplets, comportant des erreurs. Il est donc crucial, avant même de travailler sur des visualisations ou des algorithmes, de s'assurer d'obtenir des données correctes, et bien étiquetées. L'apprentissage automatique comporte généralement deux phases. La première consiste à estimer un modèle à partir de données, appelées observations, qui sont disponibles et en nombre fini, lors de la phase de conception du système. La seconde phase correspond à la mise en production : le modèle étant déterminé, de nouvelles données peuvent alors être soumises afin d'obtenir le résultat correspondant à la tâche souhaitée.

Selon les informations disponibles durant la phase d'entraînement, l'apprentissage est qualifié de différentes manières. Si les données sont étiquetées (c'est-à-dire que la réponse à la tâche est connue pour ces données), il s'agit d'un apprentissage supervisé. On parle de classification si les étiquettes sont discrètes, ou de régression si elles sont continues. Si le modèle est appris de manière incrémentale en fonction d'une récompense reçue par le programme pour chacune des actions entreprises, on parle d'apprentissages par renforcement. Dans le cas le plus général, sans étiquette, on cherche à déterminer la structure sous-jacente des données (qui peuvent être une densité de probabilité) et il s'agit alors d'apprentissage non supervisé.

Les différences entre l'analyse de regroupement (ou clustering) et l'analyse discriminante ne concernent que la session d'apprentissage de l'algorithme. Une fois que les paramètres sont déterminés et que nous commençons à utiliser le modèle, les deux modèles ont le même usage pour classer un objet dans un certain nombre de catégories.

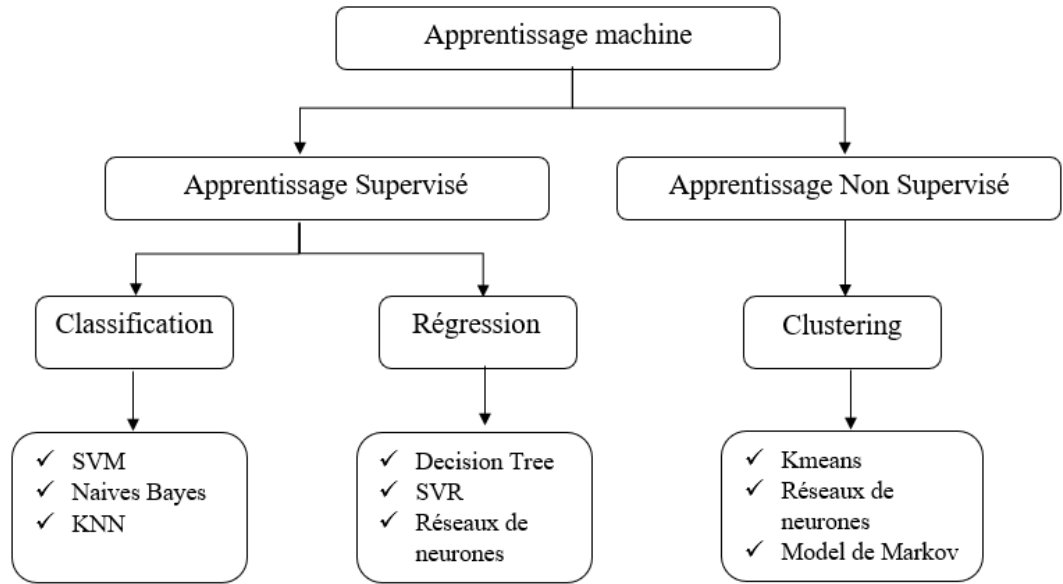


Figure 3 : Taxonomie des modèles d'apprentissage automatique [32].

**Tableau 1 : Comparaison des types d'analyses de classification.**

	Analyse par classification	Analyse discriminante
Nom	Apprentissage non supervisé	Apprentissage supervisé
Période d'apprentissage	La catégorie d'objet est inconnue	La catégorie d'objet est connue
But de l'apprentissage	Connaître la catégorie d'objet inconnue	Connaître la règle de classement
Après l'apprentissage	Pour classer un objet dans un certain nombre de catégories	Pour classer un objet dans un certain nombre de catégories

### 2.6.2.1. APPRENTISSAGE SUPERVISÉ

#### ➤ CLASSIFICATION

Dans l'apprentissage automatique et les statistiques, la classification est le problème qui consiste à identifier à quel groupe de catégories (sous-populations) une nouvelle observation appartient, à partir d'un ensemble d'apprentissages contenant des données (ou instances) dont l'appartenance à une catégorie est connue. Par exemple, attribuer un courrier électronique donné à la classe "spam" ou "non-spam" et attribuer un diagnostic à un patient donné en fonction des caractéristiques observées du patient (sexe, pression artérielle, présence ou non de certains symptômes, etc.). La classification est considérée comme un exemple d'apprentissage supervisé et de reconnaissance de formes, c'est-à-dire un apprentissage dans lequel un ensemble de formations d'observations correctement identifiées est disponible. La procédure non supervisée correspondante est connue sous le nom de clustering. Elle consiste à regrouper des données en catégories en fonction d'une mesure de la similarité inhérente ou de la distance [33].

#### ➤ RÉGRESSION

L'analyse de régression est largement utilisée pour la prévision, pour comprendre quelles variables indépendantes sont liées à la variable dépendante et pour explorer les formes de ces relations. Dans des circonstances restreintes, une analyse de régression peut être utilisée pour déduire des relations de cause à effet entre les variables indépendantes et dépendantes.

### **2.6.2.2. APPRENTISSAGE NON SUPERVISÉ**

En clustering, la catégorie de l'objet est inconnue. Cependant, nous connaissons la règle à classer (généralement basée sur la distance) et nous connaissons également les caractéristiques (variables indépendantes) pouvant décrire la classification de l'objet. Il n'y a pas d'exemple de formation pour examiner si la classification est correcte ou non. Ainsi, les objets sont assignés à des groupes simplement basés sur la règle donnée.

## **2.7. REVUE DE LA LITTÉRATURE**

L'analyse des vibrations est l'une des techniques les plus utilisées pour la maintenance prédictive dans les machines tournantes à grande vitesse. En utilisant les informations contenues dans les signaux de vibration, des études ont porté sur la conception d'un système de détection et de diagnostic des défaillances de composants mécaniques. Étant donné que la collecte de données sur les défaillances précédentes est irréalisable dans des scénarios réels, une méthode utilisant le paradigme one-class-v-SVM est utilisée [34].

D'autres recherches dans nos lectures ont utilisé le paramètre de dégradation de l'état normal à l'état de panne du système, qui est nécessaire en tant qu'objet de surveillance de l'état de fonctionnement dans la maintenance. Des articles proposent un modèle de Markov caché pour évaluer la dégradation de l'état de la machine. Une analyse dynamique en composantes principales et la distance de Mahalanobis sont utilisées pour extraire les caractéristiques efficaces des signaux de vibration permettant de quantifier l'état de santé de la machine [34-36]; puis d'utiliser ces données pour estimer la durée de vie utile restante (RUL) des machines [35].

Des articles proposent d'appliquer l'entropie d'échantillons de paquets d'ondelettes dans la prévision de la tendance des défaillances des machines roulant. Cette méthode permettrait de mieux prévoir l'état de fonctionnement des roulements.

Ainsi, la méthode d'entropie des échantillons de paquets d'ondelettes peut être utilisée comme un bon outil pour la surveillance et la prévision des roulements [37].

Nous avons également découvert dans nos recherches qu'un logiciel appelé cbmLAD, en cours de développement à l'École Polytechnique de Montréal utilise une approche d'exploration de données d'apprentissage supervisé appelée analyse logique des données (LAD) [38].