الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Département : Génie électrique Et Informatique Industrielle

Mémoire de projet de fin d'études

Pour l'obtention du diplôme de Master en **Automatique**

Spécialité

Automatique et Informatique Industrielle

Thème

Application de l'intelligence artificielle à la maintenance prédictive des systèmes à base de réseaux de capteurs

Réalisé par

AMIR Farouk

KACI Kamelia

Présenté et soutenu publiquement le 04/07/2022

Composition du Jury :

Président	M. BOUDIAR Toufik,	Maître de conférences A	ENST
Encadrant	M. KHELOUAT Samir,	Maître de conférences B	ENST
Promoteur	M. BELMOUHOUB Mohammed,	Chef de projets IT Groupe	BIOPHARM
Examinateur	M. CHERABIT Nouredine,	Maître-assistant A	ENST
Examinatrice	Mme. OUSAADI Zahira,	Maître-assistant A	ENST

Année universitaire 2021-2022

Application de l'intelligence artificielle à la maintenance prédictive des systèmes à base de réseaux de capteurs

KACI Kamelia
Génie Electrique et Informatique Industrielle
Ecole Nationale Supérieure de Technologie
Alger, Algérie
k_kaci@enst.dz

AMIR Farouk
Génie Electrique et Informatique Industrielle
Ecole Nationale Supérieure de Technologie
Alger, Algérie
f_amir@enst.dz

***Abstract*—Une rupture technologique majeure offrant un champ d'innovation, de progrès et de croissance extraordinaire, dite « industrie 4.0 ou industrie du futur ». Caractérisée par la fusion du monde virtuel de l'internet délocalisé et du monde réel des installations industrielles. Son émergence a entraîné une automatisation accrue et une compétitivité croissante du marché, d'où l'importance d'une maintenance au sein des organisations, et avec la prolifération des réseaux de capteurs sans fils (WSN) et des dispositifs de transmission et de stockage de données via l'Internet des Objet (IOT), la quantité de données pouvant être extraites des systèmes industriels augmente de manière exponentielle, et pour les préserver de tout risque de perte, le passage à la maintenance prédictive est primordial. Par conséquent, il est essentiel d'identifier et de résoudre les pannes d'équipement. Pour y parvenir , les outils d'intelligence artificielle avec leur énorme potentiel d'analyse de grandes quantités de données, désormais facilement disponibles, améliorent la disponibilité du système, réduisent les coûts de maintenance, améliorent les performances opérationnelles et l'aide à la prise la décision.**

Mots-clés : Industrie 4.0; Intelligence artificielle; Maintenance prédictive; Réseaux de capteurs.

I. Introduction

Les technologies de l'information et de communication ont connu un progrès incontestable. De nombreuses nouvelles technologies ont signé leur apparition telles que le Cloud Computing, l'internet des objet (IOT), les Big Data, l'intelligence artificielle (IA), etc. Ces nouvelles disciplines scientifiques et ces technologies ont imprégné l'industrie et l'ont poussé vers une industrie intelligente ou industrie 4.0. Là où la maintenance de production a vraiment évolué grâce à l'IA, offrant la possibilité de mieux exécuter les opérations de maintenance en comprenant les performances passées et en utilisant ces connaissances et ces informations pour prédire et optimiser quantitativement l'efficacité globale de la production. L'IA permet donc la prévision des tendances, des évènements et des comportements futurs dans le sens d'une maintenance prédictive. Cette dernière fait partie des quatres activités de maintenance qui doivent être intégrées dans le processus de fabrication :

- **La maintenance corrective (ou curative)** qui est basée sur la réparation des pannes qui se sont déjà survenues.
- **La maintenance préventive** qui est effectuée régulièrement sur l'équipement dans l'intention de réduire la probabilité de la panne.
- **La maintenance prédictive** qui est effectuée avant que la panne se produise en se basant sur des informations prédictives telles que le "Remaining Useful Life" (RUL) ou "temps restant avant défaillance", sa force réside dans l'anticipation de la panne à venir grâce aux données collectées des équipements IOT, ce qui évite tout arrêt de la ligne de production.
- **La maintenance prescriptive** se produit une fois que la panne est prédite,qui consiste à identifier les mesures à prendre permettant d'améliorer les résultats.

La maintenance est alors un support indissociable du domaine opérationnel d'une entreprise. Et avec le potentiel des outils d'Intelligence Artificielle, plus précisément de Machine Learning, qui améliorent la disponibilité du système, réduisent les coûts de maintenance, augmentent les performances opérationnelles et la sécurité, et facilitent la prise de décision concernant le moment idéal et les mesures à prendre pour une intervention de maintenance.

De nombreuses études sur les approches de la maintenance conditionnelle sont apparues dans la littérature . En 2001, un groupe de scientifiques et d'industriels américains a proposé le cadre OSA-CBM (Open Systems Architecture for Condition-Based Maintenance) [1], et en 2005 l'architecture du système de maintenance prédictive intégrée (SMPI) a été introduite.

Le travail que l'on présente dans cet article a pour but de dresser un rapide panorama des différentes approches de pronostic liées à la maintenance prédictive. Les principales particularités de la maintenance prédictive sont l'estimation de la durée de vie utile résiduelle (RUL) et la prédiction du temps d'intervention. Dans cet article, nous explorerons les différentes classifications des approches de pronostic, leurs avantages et inconvénients, afin de de proposer une méthodologie spécifique pour le choix d'une approche de pronostic pour l'estimation de RUL.

II. Méthodologie

L'un des points clés de ce développement technologique est la donnée, qui peut désormais être lue, traitée, stockée, analysée et partagée plus facilement entre les machines et les êtres humains. De plus, l'Internet des objets (IoT) est défini comme un écosystème dans lequel les objets et les appareils qui y sont intégrés sont équipés de capteurs et d'autres appareils numériques afin que chaque dispositif, dans un réseau, puisse collecter et échanger des informations avec les autres [2]. Ce développement combine la capacité de collecter des données avec l'analyse efficace et intégrée de ces dernières, offrant une excellente opportunité d'utiliser intelligemment les données de surveillance des conditions dans le cadre de la maintenance prédictive.

La plus récente architecture de la maintenance prédictive est SMPI (Fig. 1), et ne comprend que trois processus : le processus de surveillance et de diagnostic, le processus prédictif (ou de pronostic) et le processus d'aide à la décision. La particularité de cette architecture réside dans le bouclage explicite entre les processus de pronostic et d'aide à la décision [3]. Par conséquent, le processus de prédiction est utilisé pour l'aide à la prise de décision lors de l'évaluation de la maintenance ou des alternatives opérationnelles pour prévenir les pannes.

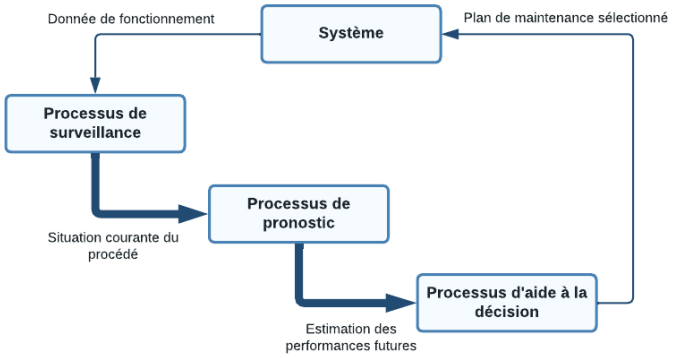


Fig. 1. L'architecture du système de maintenance prédictive intégrée"SMPI"

L'idée de la maintenance prédictive, ou maintenance prévisionnelle, est de projeter l'état actuel d'un système dans le futur, en se basant sur les données collectées en temps réel des équipements issues de l'environnement IOT, les algorithmes prédictifs permettant la prédiction de la panne sont développés. L'acquisition de données pertinentes pour les activités de maintenance se fait par un module d'acquisition à partir des instruments de mesure. La pertinence des données repose sur leur aptitude à décrire l'état normal, dégradé et défaillant de l'équipement à surveiller. Ensuite, l'étape de pré-traitement vient supprimer les bruits afin de pouvoir extraire les indicateurs d'état qui identifient les états sains ou défectueux. Les caractéristiques extraites vont être entraîner, d'une manière itérative, dans un environnement d'apprentissage automatique (Machine Learning) afin d'élaborer un modèle apte de détecter les anomalies, de classer les défauts et d'estimer la durée de vie utile restante (RUL) du composant. Ensuite, l'algorithme prédictif développé va être déployé et intégré dans le système de maintenance et de suivi de composants [4]. Ce processus est illustré à la Fig. 2.

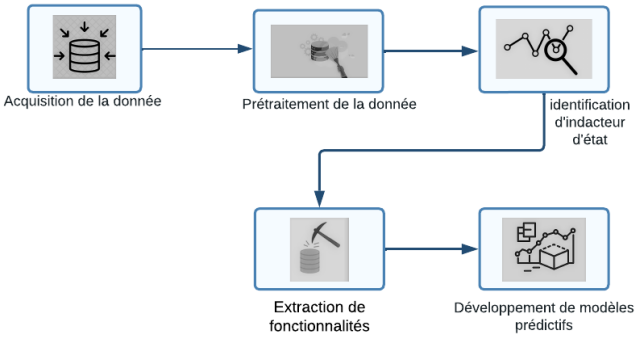


Fig. 2. Le processus de prédiction en utilisant l'IA

Pronostic et estimation de la durée de vie résiduelle RUL

La mise en œuvre de politiques de maintenance prédictive repose sur l'utilisation d'un "pronostic industriel", processus-clé qui détermine les états futurs du système surveillé. Selon la norme internationale ISO 13381-1 (2004) [5], Le pronostic est défini comme suit «Le pronostic est l'estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance» [6].

- **Les mesures de pronostic**

L'objectif principal du pronostic est de fournir des informations qui permettent de prendre les bonnes décisions, c'est-à-dire de choisir les actions de maintenance. Ainsi, le premier ensemble de métriques permet de quantifier les risques auxquels le système surveillé est exposé. Ce type de métrique correspond à des mesures prédictives dont le but est de mesurer le temps restant avant la défaillance (Time To Failure 'TTF' ou Remaining Useful Life 'RUL').En considérant que la dégradation est une grandeur à une dimension, le RUL peut être généralisé : sur la Fig. 3, TTxx est le temps restant avant que la limite de performance Perf / xx ne soit dépassée, tf est l'instant où la dégradation atteindra le seuil de défaillance, tc ou tD est l'instant courant (après détection de la dégradation).Il peut être calculé de la manière suivante [6]:

$$\mathbf{RUL = tf - tc} ;$$

III. Approches et modèles existants

L'Intelligence Artificielle, et notamment l'apprentissage automatique ou Machine Learning, s'illustre dans de nombreuses applications, aujourd'hui. Les plus connus sont la robotique, les véhicules autonomes, l'imagerie médicale et les systèmes de recommandation. D'autres domaines d'application sont moins médiatisés et jouent pourtant un rôle central dans la

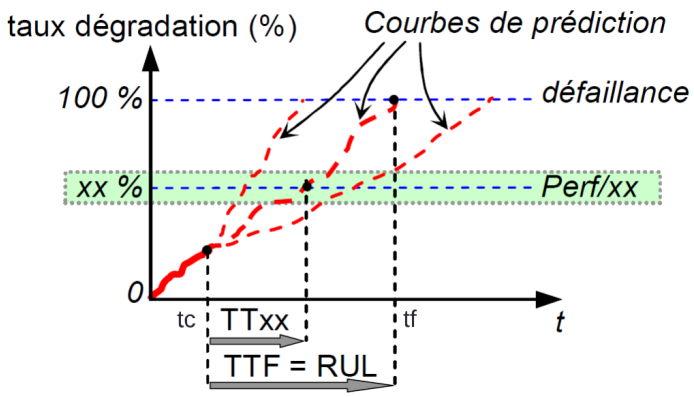


Fig. 3. La mesure de la durée de vie résiduelle RUL

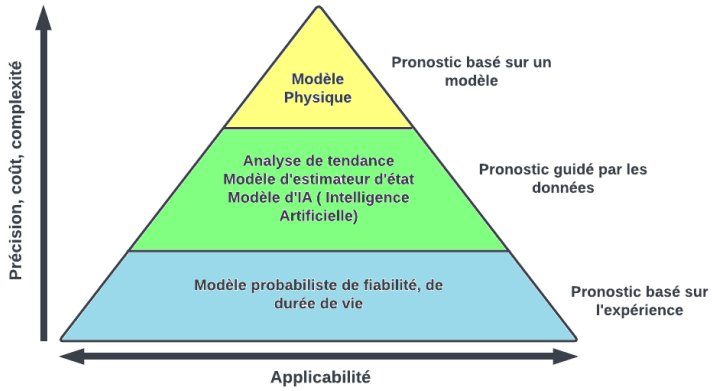


Fig. 4. Représentation hiérarchique des approches de pronostic

transformation de l'industrie. Nous allons nous concentrer sur l'un d'entre eux, la maintenance prédictive.

Au cours de la dernière décennie, de nombreux outils et méthodes de prédiction de défaillance ont été proposés. Les méthodes de prédiction dépendent généralement du type d'application considéré, mais les outils mis en œuvre dépendent avant tout du type de données et des connaissances disponibles pour modéliser le comportement du système réel, y compris le phénomène de dégradation. Aussi, ces méthodes et outils peuvent être regroupés en un nombre limité d'approches. Byington [7] propose une classification de l'ensemble des modèles et approches présents dans la littérature en trois grandes catégories :

- Les approches basées sur les modèles;
- Les approches guidées par les données;
- Les approches basées sur l'expérience ;

Pour dissocier ces trois types d'approches, les quatres critères suivants sont considérés : la complexité, le coût de développement, la précision des résultats obtenus et l'applicabilité des approches tel que présenté dans la Fig 4. Le principal défi dans le développement d'algorithmes prédictifs est de minimiser le coût et la complexité du développement du modèle tout en maximisant la précision du modèle [8].

A. Une taxonomie des approches de prédiction

1. Approches basées sur un modèle physique

L'implémentation de ce type d'approche (Fig.5) est généralement basée sur une représentation mathématique du mécanisme de dégradation se produisant sur un système, qui permet de construire la courbe d'évolution dynamique de niveau de dégradation du système (grâce aux processus de surveillance et de diagnostic) en fonction de la sollicitation du système et d'évaluer la durée de vie résiduelle avant la défaillance. Par conséquent, les résidus sont utilisés comme un outil mathématique. Les grands résidus indiquent la présence de défauts de fonctionnement, et les petits dénotent la présence de perturbations normales telles que le bruit et les erreurs de modélisation. Les techniques associées à cette approche prédictive sont basées sur l'espace de parité, l'observateur (filtre de Kalman) et l'estimation paramétrique [9], [10].

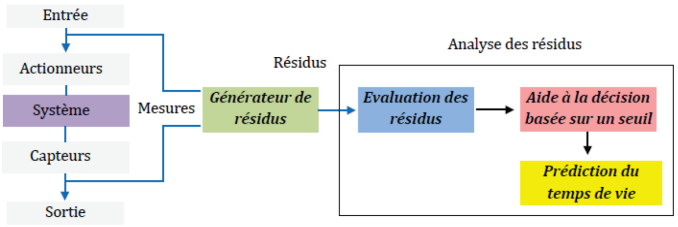


Fig. 5. Structure d'un système de pronostic à base d'un modèle.

- **L'approche de l'espace de parité :** L'espace de parité est une relation de redondance analytique (relation d'entrée/sortie ou de sortie/sortie) qui a pour propriété de ne liée que des grandeurs connues, disponibles en ligne. La création de telles relations permet de générer des résidus. En l'absence de défaut, le résidu est statistiquement nul. Lorsqu'un défaut se produit, son amplitude change considérablement [11], [3].
- **L'approche à base d'observateurs :** Générer des résidus à l'aide d'un estimateur d'état implique de reconstruire l'état ou, plus généralement, la sortie d'un processus à l'aide d'observateurs, et d'utiliser l'erreur d'estimation comme résidu [11], [3].
- **L'approche d'estimation paramétrique :** Le principe de cette méthode consiste à identifier en ligne et continu les divers paramètres du système et à comparer ses estimations aux valeurs de référence de l'état normal du procédé [11], [3].

2. Approches guidées par les données

Dans de nombreuses situations, les systèmes observés sont souvent complexes, ce qui rend impossible l'élaboration de modèles robustes et précis pouvant être utilisés à des fins de pronostic. Cependant, des données historiques qui enregistrent

le comportement du signal sont disponibles. Dans de tels cas, la génération des prédictions RUL est réalisée à l'aide d'une méthode basée sur les données qui modélise l'évolution de ces signaux mesurés [9], [10]. Ce type de prédiction montré dans la Fig. 6 est basé sur l'hypothèse que les caractéristiques statistiques des données sont relativement inchangées à moins qu'il y ait un défaut de fonctionnement dans le système. Dans ce contexte, la littérature distingue deux techniques : Celles issues de l'intelligence artificielle (IA) et les techniques statistiques.

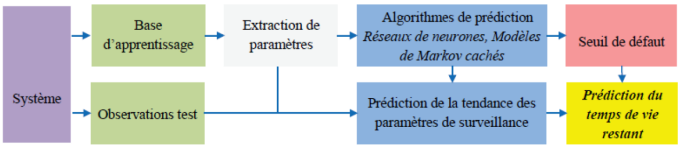


Fig. 6. Structure d'un système de pronostic guidé par les données.

Les techniques de l'intelligence artificielle IA

- **L'approche basée sur l'apprentissage automatique**

a. Définition

L'apprentissage automatique ou artificiel (en anglais, Machine-Learning) est l'une des disciplines de l'intelligence artificielle, qui fait référence à l'aptitude d'un système à acquérir et à intégrer d'une manière autonome des connaissances. Son principe de base consiste en la recherche de relation entre les données historiques et inférer les connaissances extraites sur les nouvelles données. Cet apprentissage permet d'avoir un système qui s'optimise en fonction de l'environnement, des expériences et des résultats observés. Les tâches de Machine-Learning peuvent être des tâches de classification, de régression ou de détection d'anomalies.

b. Les modèles d'apprentissage machine

Les algorithmes d'apprentissage artificiel sont classés selon le mode d'apprentissage utilisé (Fig.7) : [12], [13]

Supervisé : Lorsque les classes sont prédéterminées et les exemples sont connus, le système apprend à classer les données nouvelles selon un modèle de classement; on parle alors d'Apprentissage Supervisé (ou d'analyse discriminante). Les algorithmes d'Apprentissage Supervisé analysent la base de données et apprennent à classifier les données en fonction de leurs caractéristiques. Il consiste donc à prédire l'étiquette (classe) d'une nouvelle donnée. L'ensemble de données résultant est appelé données d'apprentissage. Par exemple, si des données indicateurs d'état sain et défectueux sont disponibles, une approche d'apprentissage supervisé ou semi-supervisé pourrait être utilisée. On distingue deux grandes familles de problèmes de l'apprentissage supervisé :

- La classification supervisée : lorsque la variable cible (à prédire) est discrète, cela revient à affecter une étiquette (ou une classe) à chaque entrée.
- La régression : lorsque la variable à prédire est continue.

Non supervisé : Dans ce mode d'apprentissage, le système ne dispose que d'exemples (pas d'étiquettes/classes prédéterminées) c'est-à-dire que la base de données d'apprentissage ne contient pas de variable cible (comme dans le cas de l'apprentissage supervisé); on parle alors d'apprentissage non supervisé (ou clustering). Il consiste à diviser un ensemble de données en sous-ensembles (clusters) similaires. L'algorithme doit alors découvrir par lui-même la structure en fonction des données.

Semi-supervisé : Il s'agit d'un mixe entre les deux modes d'apprentissage précédents (supervisé et non supervisé) en utilisant des données étiquetées et non-étiquetées pour le même ensemble de données. Il est mis en œuvre lorsque des données ou une étiquette sont manquantes.

L'apprentissage par renforcement : Ce type d'apprentissage se fait sans supervision en interagissant avec l'environnement (principe d'essai / erreur) et en observant les résultats des actions prises. Chaque action de la séquence est associée à une récompense. Il s'agit soit d'une récompense pour un bon choix, soit d'une pénalité pour une mauvaise action. Le but est alors de savoir quelle stratégie (ou choix d'actions) maximise le cumul de récompenses.

En apprentissage supervisé, plusieurs modèles existent et peuvent être implémentés sous forme d'algorithmes, ils diffèrent dans la manière d'aborder l'entraînement sur les données mais aussi dans le type de label à prédire (valeur continue, classe, etc). Dans ce qui suit, un bref aperçu de divers algorithmes d'apprentissage automatique supervisé.

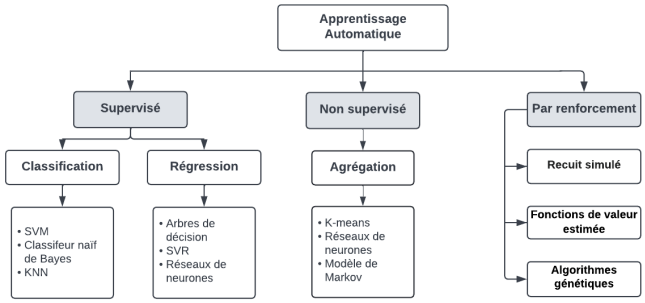


Fig. 7. Les modèles et les algorithmes d'apprentissage machine.

c. Algorithmes d'apprentissage automatique

Régression linéaire

Le modèle de régression linéaire désigne un modèle qui cherche à établir une relation linéaire entre une variable cible ou une variable à expliquer et une ou plusieurs variables dites explicatives ou prédictives. Autrement dit, il consiste à rechercher la droite permettant d'expliquer le comportement comme le montre la Fig. 8. En Apprentissage Automatique, l'algorithme de régression linéaire est un algorithme d'apprentissage supervisé utilisé pour prédire une variable quantitative, tandis que la variable prédictive peut être quantitative ou qualitative.

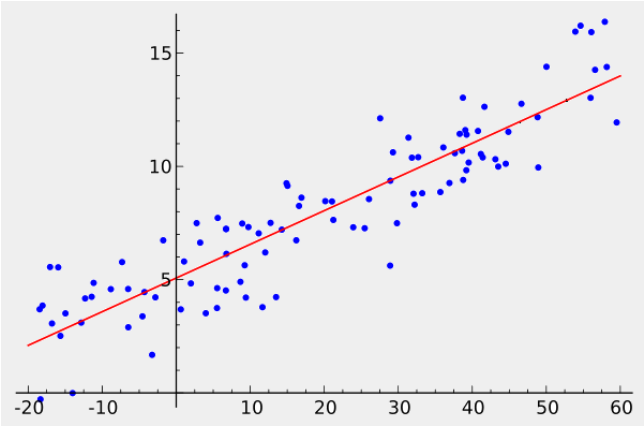


Fig. 8. La régression Linéaire.

Les réseaux de neurones

Les réseaux de neurones, communément appelés réseaux de neurones artificiels "RNA", sont les intelligences artificielles qui apprennent de leur expérience (de manière supervisée ou non) pour atteindre un objectif défini (reconnaissance d'image, de texte, prédictions, etc.), sont simplement des imitations de la fonction des neurones dans le cerveau humain pour résoudre des problèmes d'apprentissage automatique. Ils se composent d'une couche d'entrée, qui a pour fonction de recevoir les données d'entrée, d'une couche de sortie qui fournit les résultats du système, et d'une ou plusieurs couches cachées (souvent appelée «boîte noire») [13], comme montré dans la Fig. 10. Le réseau neuronal est un réseau inter-connecté de neurones artificiels, chaque neurone possède une valeur spécifique qui détermine l'information pouvant être transmise au système [14]. La valeur de sortie de chaque neurone est calculée par une fonction appelée "fonction d'activation "(Fig. 9).Ce calcul détermine le nombre de neurones qui doivent être activés pour résoudre le problème. Un algorithme est

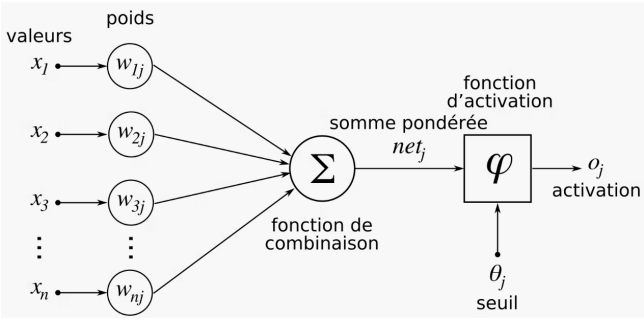


Fig. 9. Structure d'un neurone formel.

ensuite créé. Il attribue un résultat à chaque entrée. Si ces réseaux de neurones sont constitués de plusieurs couches, on parlera d'apprentissage profond ou de réseaux de neurones numériques profonds.

- **Deep Learning**
  Le Deep Learning, ou apprentissage profond, est une branche de l'apprentissage machine, basé sur des réseaux de neurones artificiels. Le processus d'apprentissage est dit profond car la structure d'un réseau de neurones artificiels se compose de plusieurs entrées, sorties et couches cachées. Chaque couche contient une unité qui transforme les données d'entrée en informations que la couche suivante peut utiliser pour une tâche prédictive particulière. Grâce à cette structure, les machines peuvent apprendre en traitant leurs propres données [15].

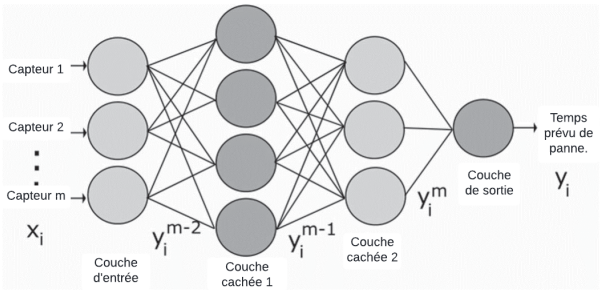


Fig. 10. Un simple RNA avec deux couches cachées. L'entrée est constituée de données multivariées provenant de divers capteurs. La sortie est le temps de panne prévu pour l'instrument de mesure.

Méthode des K plus proches voisins La méthode des k plus proches voisins, en abrégé KNN (Fig. 11), de l'anglais 'k-Nearest Neighbors', est une méthode d'apprentissage supervisé. C'est un algorithme de reconnaissance des formes

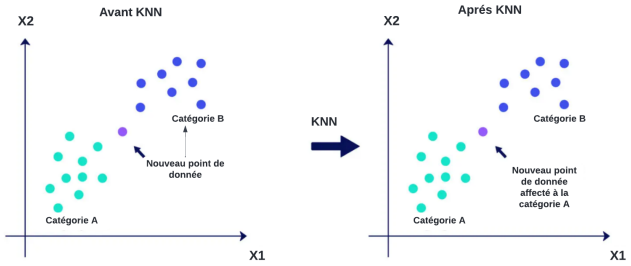


Fig. 11. Algorithme des K plus proches voisins KNN

qui peut être utilisé autant pour la classification que pour la régression. Dans ce cadre, on dispose d'une base de données d'apprentissage constituée de N couples « entrée/sortie ». Pour estimer la sortie associée à une nouvelle entrée x, la méthode des k Plus Proches Voisins consiste à considérer (de la même manière) les k échantillons d'apprentissage dont l'entrée est la plus proche de la nouvelle entrée x, selon une distance à définir [16].

Classification Naive de Bayes

C'est un classifieur probabiliste simple, qui fait partie de la famille des classifieurs Linéaires, basé sur le théorème de Bayes illustré dans la Fig. 12, avec une indépendance naïve (forte) entre les caractéristiques [13]. L'implémentation de ce mode d'apprentissage est très facile, et il donne généralement

d'excellents résultats lorsque le nombre de dimensions en entrée est élevé.

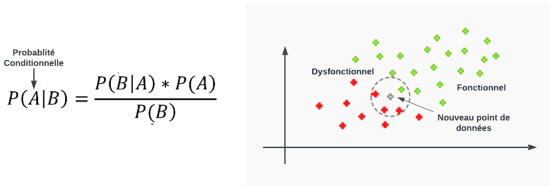


Fig. 12. a. Le théorème naïf de bayes b.Le classifieur naïf de Bayes.

Les arbres de décision

Les arbres de décision sont l'une des techniques d'apprentissage supervisé non paramétrique les plus largement utilisées dans la classification et la régression. D'une part, ceci revient au fait que les algorithmes sont simples, et d'autre part, ils sont faciles à interpréter et à expliquer les résultats produits. Le but est de créer un modèle qui prédit la valeur de la variable cible en apprenant les règles de décision. Un exemple illustratif dans la Fig. 13 qui montre un arbre de décision qui calcule l'état du réseau de capteurs sur la base de l'ensemble des données transmises par les capteurs, en comparant les mesures des capteurs avec les prédicats précédemment obtenus lors de la formation du modèle. Cette comparaison se poursuit jusqu'à ce qu'on atteint la feuille de l'arbre avec la valeur de l'état particulier du système [17].

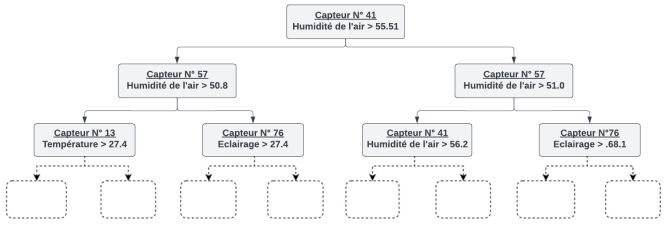


Fig. 13. L'arbre de décision (les 3 premiers niveaux) obtenu lors d'entraînement des données issues des capteurs.

Random Forest

Random Forest ou forêts d'arbres décisionnels aléatoires est un algorithme d'Apprentissage Automatique supervisé [16]. Il est très utilisé dans les problèmes de régression et de classification. Il se repose sur l'apprentissage par arbre de décision pour faire ce qui suit : il construit des arbres de décision (Fig. 14) sur différents échantillons; pour le classement, il prend leur vote majoritaire et pour la régression, il prend leur moyenne. Il permet de donner de meilleurs résultats pour les problèmes de classification [13].

Machine à Vecteurs de Support ou Séparateur à Vaste Marge

Les SVM (Fig. 15), de l'anglais Support Vectors Machines, sont un ensemble de techniques d'apprentissage un algorithme d'apprentissage supervisé destinées à résoudre des problèmes de classification ou de régression. Elles reposent sur deux

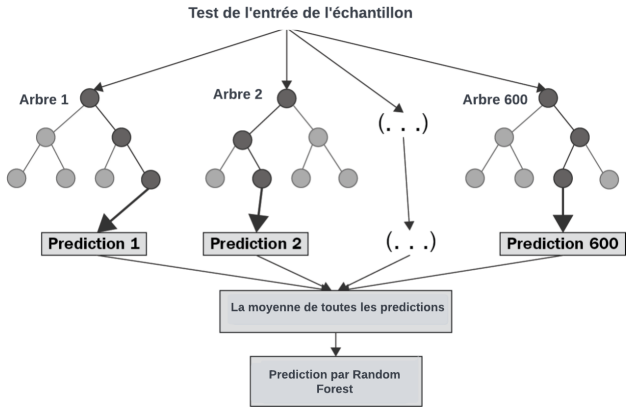


Fig. 14. L'algorithme de la forêt aléatoire

concepts : la marge maximale et la fonction noyau permettant ainsi de traiter les problèmes linéaires et non linéaires. La marge maximale permet de trouver la frontière séparatrice optimale des données à partir d'un ensemble d'apprentissage. Quant aux données non séparables linéairement, on utilise la fonction noyau qui utilise l'hypothèse qu'une probable séparation linéaire existe dans un plan dimensionnel plus grand et donc transforme les données en des données de plus grande dimensionnalité (peut arriver jusqu'à une dimensionnalité infinie) [18], [19].

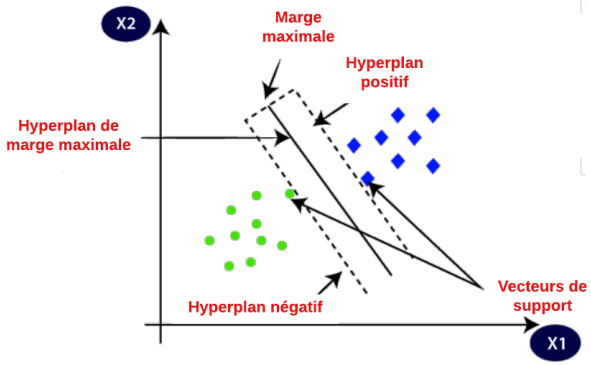


Fig. 15. Machine à Vecteurs de Support

Les techniques statistiques

- **L'approche statistique**

a. ***Définition***

C'est une approche qui utilise des formules mathématiques et des techniques exploitées dans l'analyse statistique pour résoudre des tâches d'apprentissage machine. L'application de méthodes statistiques extrait des informations à partir de données de recherche brutes et fournit une variété de méthodes d'évaluation de la robustesse des résultats de la recherche.

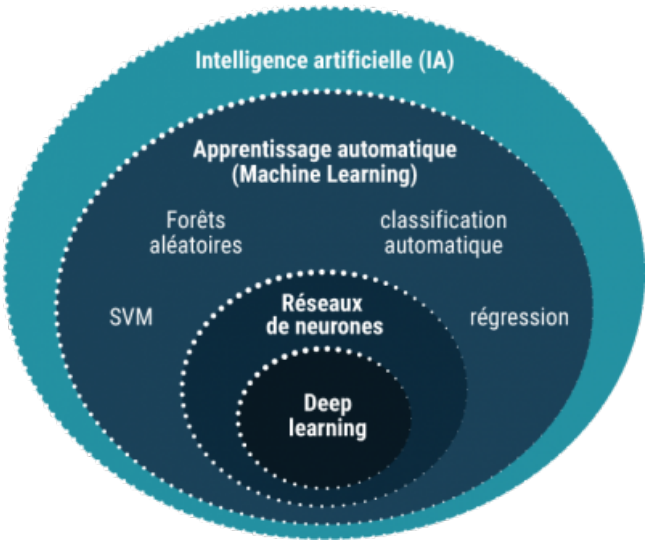


Fig. 16. Intelligence Artificielle, Machine Learning, Deep Learning.

Cette approche permet, en particuliers, l'évaluation de la fiabilité et l'efficacité de modèles en phase de conception, la détermination des tendances et l'établissement des pronostics. Elle utilise deux méthodes, la première est le système expert et la deuxième méthode est la corrélation qui se concentre sur le calcul du coefficient de corrélation ainsi que le concept de la corrélation linéaire afin de déterminer la fiabilité des prévisions.

Le système expert

Un système expert, "Expert System" en anglais, est un ensemble de logiciels exploitant dans un domaine spécifique de connaissances explicites et organisées, qui se base sur des données statistiques pour retourner un résultat d'inférence qui prédit, par exemple, une panne d'un actif, il est capable de reproduire les mécanismes cognitifs d'un expert. C'est l'une des voies tentant d'atteindre l'intelligence artificielle. [20], [13]. Ce système utilise une base de faits, une base de règles et un moteur d'inférence comme montré dans la Fig. 17. Ce moteur a pour but de rechercher des faits à découvrir, et de remonter à des faits connus. C'est un peu

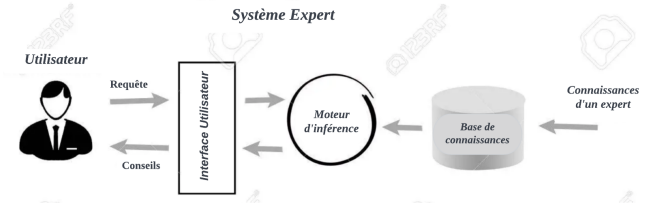


Fig. 17. L'architecture du Système Expert

le principe d'acquisition des connaissances : on essaye grâce à l'expérience de prévoir l'attitude à adopter et les décisions à prendre face à des faits dont on ne connaît pas encore la nature, et grâce au résultat obtenu, d'enrichir la connaissance. C'est le principe de tout système intelligent.

La corrélation

La corrélation est un outil mathématique d'aide à la prévision qui mesure la relation entre deux variables ou plus, elle est linéaire lorsqu'on constate un lien entre elles (si l'une augmente l'autre aussi et inversement) [21], [20]. Le coefficient de corrélation doit avoir une valeur qui se situe dans l'intervalle [-1, 1]. Une valeur de +1,00 (ou -1,00) représente une corrélation positive (ou négative) parfaite , c'est-à-dire que connaître la valeur d'une mesure nous permet de connaître exactement la valeur de l'autre. La valeur 0,00 signifie une totale absence de corrélation (ou une indépendance entre les variables) comme le montre la Fig. 18. Le coefficient de corrélation linéaire, quantifie la force du lien linéaire entre les deux caractères d'une distribution. Pour le déterminer, on peut effectuer une estimation de son allure graphique ou une formule mathématique, plus sa valeur est près de 1 ou -1, plus le lien linéaire entre les deux variables est fort, et plus elle est proche de zéro, plus la relation linéaire est faible.

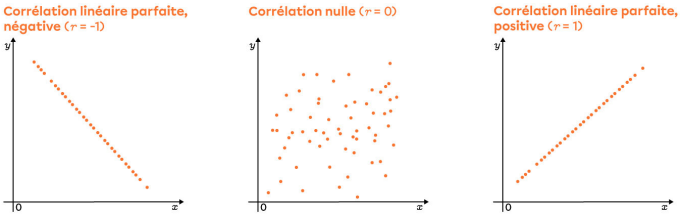


Fig. 18. Illustration de différents coefficients de corrélation linéaire. Gauche : r = -1,00, milieu : r = 0,00, droite : r = 1,00

L'approches basée sur les données utilise des données réelles issues en ligne des capteurs ou par des mesures de l'opérateur pour estimer et suivre les propriétés montrant la dégradation des composants et prédire le comportement global d'un système. En effet, dans de nombreuses applications, les données d'E/S mesurées sont la source d'une meilleure compréhension de la dégradation du système.

3. Approches basées sur l'expérience

Les méthodes de pronostic qui se basent sur l'expérience reposent sur l'utilisation d'ensembles de données de retour d'expérience de maintenance ou d'inspection recueillies sur une période de temps significative. celles-ci représentent les conditions opérationnelles pendant tout le processus de dégradation jusqu'à la panne [22]. En général, elles peuvent être classées en deux catégories d'approches : Les approches basées sur la fiabilité et celles basées sur la similarité [23], [10].

- **L'approche basée sur la fiabilité**

Utilise une distribution statistique des défaillances (c'est-à-dire la loi de Weibull) afin de s'adapter aux données collectées. Des mises à jour périodiques des paramètres de cette distribution de pannes sont effectuées pour ajuster ces paramètres en fonction de l'expérience acquise lors des travaux de maintenance en cours (ou actuels). La distribution de la défaillance construite

est utilisée pour l'estimation RUL des composants ayant des caractéristiques similaires [23].

- **L'approche basée sur la similarité**

Cette approche utilise une bibliothèque de modèles de dégradation d'un groupe composants dans différentes conditions de fonctionnement. Chaque modèle de dégradation d'un composant représente la progression de sa dégradation jusqu'à ce qu'il tombe en panne dans des conditions de fonctionnement spécifiques. Les données collectées sur les conditions de fonctionnement des composants dans la période sont comparées au modèle de dégradation et le meilleur modèle correspondant aux données dans la période est sélectionné. Ensuite, à l'aide du modèle de dégradation sélectionné, la durée de vie utile restante pourrait être estimée.

Les méthodes de pronostic basées sur l'expérience sont efficaces lorsque l'historique de dégradation du système est disponible sur une longue période. L'historique de dégradation prend en compte les données et les connaissances accumulées par l'expérience pendant toute la période d'exploitation du système industriel depuis l'état sain jusqu'à l'état de panne (c'est-à-dire représenter son exécution jusqu'à la panne). L'approche basées sur la fiabilité n'est pas adaptée aux composants qui présentent un comportement de dégradation complexe en fonction des conditions de fonctionnement et d'environnement. En effet, ceci revient au fait qu'ils n'utilisent pas les données opérationnelles en ligne pour estimer la durée de vie résiduelle. L'approche basée sur la similarité nécessite également un historique des données d'exécution du système jusqu'à la défaillance de la même unité ou du même composant. Par rapport à l'approche de fiabilité, l'approche basée sur la similarité utilise des données de surveillance en ligne pour les comparer avec l'historique de dégradation et estimer le RUL [23]. L'approche basée sur l'expérience comprend les étapes suivantes (illustrées à la Fig. 19) [24]:

– Extraction de connaissances.
– Modélisation des indicateurs de santé.
– Prédiction RUL.

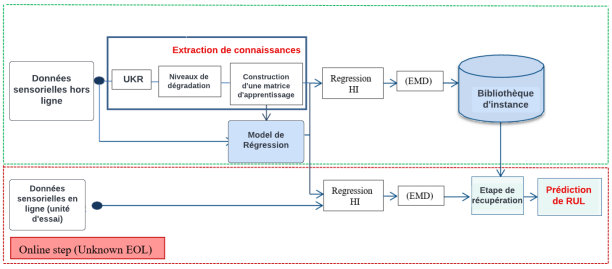


Fig. 19. Structure d'un système de pronostic basé sur l'expérience.

Le principal avantage de ce type d'approche est qu'elle ne nécessite pas une connaissance approfondie des mécanismes physiques de dégradation, et est relativement simple à mettre en œuvre, mais nécessite des données issues d'historiques ou de retours d'expériences sur le nombre de défaillances détectées, de composants remplacés, réparés, etc.

B. Méthodologie de choix d'une approche de prédiction

1. Les avantages et les inconvénients des approches de pronostic

D'après la littérature sur le temps résiduel avant la défaillance, il n'existe pas de meilleur modèle bien accepté pour la prédiction du RUL, et chaque modèle se caractérise par ses propre avantages et inconvénients. Comme nous le savons tous, avec le développement de la technologie de détection, divers capteurs sont devenus largement utilisés pour la surveillance de l'état des outils, et il est devenu très facile d'obtenir une grande quantité de données à partir d'un processus [25]. Le tableau1 résume certaines approches présentées dans la littérature pour les pronostics [9], [3].

2. La méthodologie de choix

Pour le bon choix d'une approche qui permet la prédiction de la durée de vie utile restante 'RUL' pour un équipement, il faut s'assurer de la disponibilité des données appropriées. Avec la disponibilité de modèles suffisamment descriptifs d'un processus de dégradation du système, on opte pour la première approche qui se base sur un modèle physique. Par contre, la deuxième approche, qui se fonde sur les données, requière peu de connaissances intrinsèques de l'équipement [8], les modèles sont souvent considérés comme des modèles de type « boîtes noires », il est difficile de comprendre la relation logique entre les données d'entrée consommées par le modèle et les sorties renvoyées [26], cette approche se base alors sur les données mesurées issues des capteurs représentant l'état actuel du processus. En outre, lorsque l'historique de défaillances est disponible, il est plus facile d'appliquer les approches de prédiction basées sur l'expérience afin de déterminer la probabilité de défaillance à un moment donné dans le futur.
Un schéma illustratif de la méthodologie à suivre pour réussir le choix de l'approche de pronostic est montré à la Fig. 20 [3].

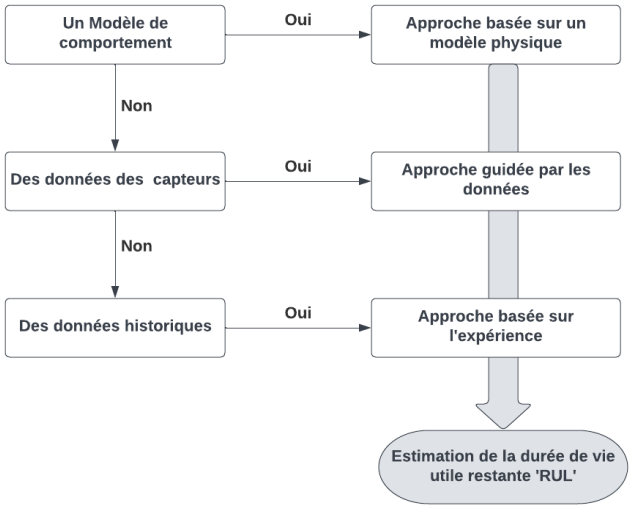


Fig. 20. Méthodologie de choix d'une approche.

TABLE I
LES APPROCHES DE PRONOSTIC

Approches	*Méthodes*	*Application*	*Avantages*	*Inconvénients*
Approche basée sur un modèle physique	Espace de parité	Un modèle de suspension de voiture et les roulements de boîte de vitesses.	Précision dans la prédiction de RUL. Flexibilité de l'approche. Facile à interpréter.	Le développement des modèles est extrêmement coûteux. Les systèmes complexes sont très difficiles à modéliser. La nécessité de connaître les mécanismes de dégradation.
	Observateurs			
	Estimation paramétrique			
Approche guidée par les données	Les approches basées sur L'IA	Roulements à billes et la machine tournante.	Facile à mettre en œuvre. Adaptée à tout type d'application instrumentée comprenant des données en quantité et en qualité. Aucune connaissance de modèles analytique des dégradations n'est requise.	Son efficacité dépend fortement de l'existence de ces données opérationnelles. Moins précis dans la prédiction de RUL des systèmes complexes.
	Les approches statistiques			
Approche basée sur l'expérience	L'approche basée sur la fiabilité	Les moteurs et les batteries.	Applicabilité très large. Simple et facile à mettre en œuvre.Peu coûteuses. Elles ne nécessitent pas de connaissance pointue du (des) mécanismes physique(s) de dégradation. Permet la surveillance de l'état de santé actuel du système. Bonne précision au niveau du composant si les données historiques adéquates sont disponibles.	Dépend de l'historique de dégradation. Non adapté aux systèmes complexes en raison de plusieurs composants en interaction et de conditions variables. La précision sera réduite si les données de surveillance ne sont pas utilisées.
	L'approche basée sur la similarité			

IV. CONCLUSION

Maintenir les systèmes industriels en condition opérationnelle à moindre coût est devenu un enjeu critique quant à la performance des milieux industriels pour assurer la disponibilité, la sécurité et la performance des équipements durant toute la phase d'exploitation. Le pronostic, qui représente la deuxième étape dans l'architecture de SIMP, fait l'objet d'une norme internationale récente et est désormais considéré comme un processus clé dans les stratégies de maintenance.

L'analyse de la littérature montre a priori qu'il existe de nombreuses options pour soutenir l'activité prédictive : les approches basées sur un modèle physique, les approches guidées par les données issues des capteurs et les approches basées sur l'expérience. La plus grande partie de l'article se concentre sur une approche basée sur l'intelligence artificielle (IA), l'une des approches de pronostic guidée par les données. Ce qui a conduit à privilégier cette approche est le fait que l'acquisition de données n'est plus un verrou technologique fort, ainsi que son adaptation à tout type d'application disposant de données opérationnelles, et le fait qu'elle ne requiert pas la connaissance formelle de mécanisme de dégradation, ou encore de connaissances et d'expériences passées qui sont difficiles voire impossibles à obtenir dans des systèmes complexes.

REMERCIEMENTS

Nous tenons à remercier toute l'équipe pédagogique de l'Ecole Nationale Supérieure de Technologie (ENST) et les intervenants professionnels responsables de la formation de la filière Automatique et Informatique Industrielle, en particulier nos encadrants pour leurs conseils, leurs orientations précieuses et leurs remarques constructives qui ont permis d'enrichir ce travail.

REFERENCES

[1] M. Lebold, K. Reichard, et D. Boylan, « Utilizing dcom in an open system architecture framework for machinery monitoring and diagnostics », in 2003 IEEE Aerospace Conference Proceedings (Cat. No.03TH8652), Big Sky, Montana, USA, 2003, vol. 3, p. 3_1227-3_1236. doi: 10.1109/AERO.2003.1235237.

[2] D. Cardoso et L. Ferreira, « Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools », Appl. Sci., vol. 11, no 1, p. 18, déc. 2020, doi: 10.3390/app11010018.

[3] A. Motrani et R. Noureddine, « METHODOLOGIE DE CHOIX D'UNE APPROCHE DE PRONOSTIC », p. 7.

[4] Daniyan, K. Mpofu, M. Oyesola, B. Ramatsetse, et A. Adeodu, « Artificial intelligence for predictive maintenance in the railcar learning factories », Procedia Manuf., vol. 45, p. 13-18, 2020, doi: 10.1016/j.promfg.2020.04.032.

[5] ISO 13381-1. Condition monitoring and diagnostics of machines - prognostics - part1 : General guidelines. International Standard ISO, 2004.

[6] R. Gouriveau, K. Medjaher, et N. Zerhouni, Du concept de PHM à la maintenance prédictive 1: Surveillance et pronostic. ISTE Group, 2017.

[7] C. S. Byington, M. J. Roemer, M. J. Watson, T. R. Galie, et C. Savage, « Prognostic Enhancements to Diagnostic Systems (PEDS) Applied to Shipboard Power Generation Systems », in Volume 2: Turbo Expo 2004, Vienna, Austria, janv. 2004, p. 825-833. doi: 10.1115/GT2004-54135.

[8] H. M. Elattar, H. K. Elminir, et A. M. Riad, « Prognostics: a literature review », Complex Intell. Syst., vol. 2, no 2, p. 125-154, juin 2016, doi: 10.1007/s40747-016-0019-3.

[9] Z. Bouzidi, « Pronostic des systèmes industriels basé sur l'intelligence artificielle Maintenance prédictive », p. 168.

[10] M. E. Koujok, « Contribution au pronostic industriel: inté- gration de la confiance à un modèle prédictif neuro-flou », p. 152, 2010.

[11] H. Id, « Contribution au pronostic de défaillances par réseau neuro-flou: maîtrise de l'erreur de prédiction. », p. 162.

[12] C. Janiesch, P. Zschech, et K. Heinrich, « Machine learning and deep learning », Electron. Mark., vol. 31, no 3, p. 685-695, sept. 2021, doi: 10.1007/s12525-021-00475-2.

[13] Ibtissem, « Artificial intelligence applied to the predictive maintenance of intelligent solar inverters », 26 août 2019.

[14] S. Namuduri, B. N. Narayanan, V. S. P. Davuluru, L. Burton, et S. Bhansali, « Review—Deep Learning Methods for Sensor Based Predictive Maintenance and Future Perspectives for Electrochemical Sensors », J. Electrochem. Soc., vol. 167, no 3, p. 037552, févr. 2020, doi: 10.1149/1945-7111/ab67a8.

[15] « Une nouvelle approche à base de deep learning pourestimer la durée de vie utile pour la maintenance conditionnelle011.pdf ».

[16] M. Jemmali, « MONTRÉAL, LE 17 DÉCEMBRE 2021», p. 136.

[17] M. N. Yuldashev, A. I. Vlasov, et A. N. Novikov, « Energy-efficient algorithm for classification of states of wireless sensor network using machine learning methods », J. Phys. Conf. Ser., vol. 1015, p. 032153, mai 2018, doi: 10.1088/1742-6596/1015/3/032153.

[18] « st-m-app-svm.pdf ». Consulté le: 10 juin 2022. [En ligne]. Disponible sur: https://www.math.univ-toulouse.fr/ besse/Wikistat/pdf/st-m-app-svm.pdf

[19] sce Marref Nadia. « Apprentissage Incrémental Machines à Vecteurs Supports », 18 décembre 2013.

[20] Lotfi Nabli, « CoursSystmeExpert »,September 2010, doi: https://www.researchgate.net/publication/322740806.

[21] R. M. Hasani, G. Wang, et R. Grosu, « An Automated Auto-encoder Correlation-based Health-Monitoring and Prognostic Method for Machine Bearings ». arXiv, 18 mars 2017. Consulté le: 25 juin 2022. [En ligne]. Disponible sur: http://arxiv.org/abs/1703.06272

[22] M. E. Koujok, « Contribution au pronostic industriel: inté- gration de la confiance à un modèle prédictif neuro-flou », p. 152, 2010.

[23] K. Abid, M. Sayed Mouchaweh, et L. Cornez, « Fault Prognostics for the Predictive Maintenance of Wind Turbines: State of the Art », in ECML PKDD 2018 Workshops, vol. 967, A. Monreale, C. Alzate, M. Kamp, Y. Krishnamurthy, D. Paurat, M. Sayed-Mouchaweh, A. Bifet, J. Gama, et R. P. Ribeiro, Éd. Cham: Springer International Publishing, 2019, p. 113-125. doi: 10.1007/978-3-030-14880-5_10.

[24] R. Khelif, B. Chebel-Morello, et N. Zerhouni, « Experience Based Approach for Li-ion Batteries RUL PredictionÕ », IFAC-Pap., vol. 48, no 3, p. 761-766, 2015, doi: 10.1016/j.ifacol.2015.06.174.

[25] M. Liu, X. Yao, J. Zhang, W. Chen, X. Jing, et K. Wang, « Multi-Sensor Data Fusion for Remaining Useful Life Prediction of Machining Tools by IABC-BPNN in Dry Milling Operations », Sensors, vol. 20, no 17, p. 4657, août 2020, doi: 10.3390/s20174657.

[26] K. Javed, R. Gouriveau, et N. Zerhouni, « State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels », Mech. Syst. Signal Process., vol. 94, p. 214-236, sept. 2017, doi: 10.1016/j.ymssp.2017.01.050.