

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université A/Mira de Béjaïa
Faculté des Sciences Exactes
Département d'Informatique



Mémoire de fin d'études

En vue d'obtention du diplôme de Master en Informatique.
Spécialité : System d'information avancé .

Thème

La Maintenance prédictive des machines de l'industrie 4.0 : utilisation du Deep Learning pour la detection des anomalies

Réalisé par :

*M. MENASRIA Mohamed et Mlle. BAUCHE Alicia .
Évalué le 01/07/2024 devant le jury composé de :*

Président(e)	Mme ADEL Karima	U. A/Mira Béjaïa.
Examineur	Mr GOUDJIL Slimane.	U. A/Mira Béjaïa.
Encadrant(e)	Mme AIT KACI AZZOU Samira	U. A/Mira Béjaïa.

Année universitaire 2023/2024

Remerciements

Nous tenons tout d'abord à remercier en premier lieu "Allah" , le tout puissant, de nous avoir dotés d'un immense courage, d'une patience infinie afin de mener à bien ce projet.

Nous tenons à exprimer notre profonde gratitude à mon encadrante, **Mme.AIT KACIAZZOU (Epouse BOUKERRAM) Samira**, pour son soutien indéfectible, ses conseils avisés et son accompagnement tout au long de ce projet. Ses compétences, son dévouement et sa disponibilité ont été des éléments essentiels à la réussite de ce travail. Merci infiniment pour votre patience et vos encouragements constants.

Nous remercions aussi les membres du jury **Mme K. Adel et Mr S. Goudjil**, pour l'honneur qu'ils nous font en consacrant leur temps à examiner et évaluer ce travail.

Et enfin, que nos chers parents et familles, trouvent ici l'expression de nos remerciements les plus sincères et les plus profonds en reconnaissance de leurs sacrifices, aides, soutien et encouragement afin de nous assurer cette formation dans les meilleures conditions.

Dédicace

À *mes parents*, qui méritent tout le bonheur du monde, pour leur amour inconditionnel et leur soutien indéfectible.

À *ma petite sœur Melissa*, qui souhaitait ardemment cette dédicace, parce que tu es ma sœur et cela suffit.

À *mon petit frère Aïmed*, pour ne pas faire de jaloux et parce que tu comptes énormément pour moi.

À *ma Mamie, Jida, mes tantes, cousines, et cousins*, qui attendaient ce jour avec autant d'impatience que moi. En tant que première Graduate, merci pour votre amour et votre soutien inébranlable.

À *toutes les personnes qui m'ont soutenue et ont cru en moi*, même lorsque moi-même j'en doutais, en particulier à mon binôme Mooh.

À *la mémoire de mon Papy, mon grand-père et de mes oncles*, qui resteront à jamais dans mon cœur malgré leur absence.

Merci à vous tous de m'avoir accompagnée dans ce voyage. Vos encouragements et votre foi en moi ont rendu ce moment possible et inoubliable.

Alicia

Dédicace

À mes parents les plus chers, pour leur amour inconditionnel, leur soutien et leurs sacrifices.

À mes sœurs :

- *Imane*, ma grande sœur, pour son amour et sa sagesse.
- *Salma*, qui est au Canada et qui me manque terriblement, pour ses encouragements et son inspiration.
- *Nawal*, ma sœur et amie d'enfance, pour nos souvenirs partagés et son soutien indéfectible.
- *Ryma*, la plus petite, pour sa joie de vivre et son énergie contagieuse.

À mon grand frère Yacine, mon modèle et exemple supérieur, pour son leadership et son soutien constant.

À mon binôme Alicia , pour tout ce que nous avons traversé ensemble.

À mes meilleurs potes Zazou, Ramy, Noufel, Mohamed, Khalil, SAAD, Doudouche, monsef, Youba..... , pour leur amitié sincère et leur soutien précieux.

À ma grand-mère bien-aimée, pour son amour incommensurable et ses prières.

En hommage à mes grands-parents qui sont décédés, dont la mémoire continue de m'inspirer chaque jour.

Mohamed

Table des matières

Introduction générale	1
Problématique	2
Structure du mémoire	2
1 Généralités sur la maintenance industrielle	3
1.1 Introduction à la maintenance	3
1.1.1 Définition de la maintenance	3
1.1.2 Evolution historique des pratiques de maintenance	3
1.1.2.1 Maintenance Corrective	4
1.1.2.2 Maintenance Préventive	5
1.1.2.3 Maintenance Prédicative (Années 1990-à ce jour)	5
1.2 Évolution de l'Industrie et de ses Besoins en Maintenance	5
1.2.1 Révolution industrielle à l'industrie 4.0	6
1.2.1.1 La Première Révolution Industrielle (fin du 18e siècle - début du 19e siècle)	6
1.2.1.2 La Seconde Révolution Industrielle (fin du 19e siècle - début du 20e siècle)	6
1.2.1.3 La Troisième Révolution Industrielle (années 1970)	6
1.2.1.4 La Quatrième Révolution Industrielle (Industrie 4.0, depuis 2011)	7
1.2.2 Conclusion	7
1.3 La maintenance dans l'industrie	7
1.4 Comparaison des types de maintenance	8
1.4.1 Critères de comparaison	8
1.4.2 Tableau comparatif	9
1.5 Avantages et Inconvénients	9
1.6 Les étapes de la maintenance prédictive	11
1.7 Les approches de la maintenance prédictive	12
1.7.1 Conclusion	13

2	La maintenance prédictive dans l'Industrie 4.0 : Etat de l'art	15
2.1	Introduction	15
2.2	Utilisation de l'Internet des Objets (IoT) et de l'Internet Industriel des Objets (IIoT) pour la maintenance prédictive	15
2.2.1	Internet des objets (IoT)	15
2.2.2	Internet Industriel des objets (IIoT)	16
2.3	Exploitation du Big Data pour la maintenance prédictive	17
2.4	Application de l'Intelligence Artificielle (IA) dans la maintenance prédictive	18
2.4.1	Les techniques de ML classiques	18
2.4.1.1	Régression linéaire (RL)	18
2.4.1.2	Forêts aléatoires (Random Forest RF)	19
2.4.1.3	Les Machines à vecteurs de support (SVM)	20
2.4.2	Les techniques du DL	20
2.4.2.1	Les Auto-Encodeurs	21
2.4.2.2	Les Transformers	21
2.4.2.3	Réseaux de Neurones Convolutionnels (CNN)	23
2.4.2.4	Les Réseaux de Neurones Récurents (RNN)	24
2.4.2.5	Les Long Short-Term Memory (LSTM)	24
2.4.2.6	Les unités récurrentes à portes (GRU)	26
2.4.3	Techniques hybrides	27
2.4.3.1	Étude de D Kusumaningrum, et al. (2021)	27
2.4.3.2	Étude de Shoorkand et al. (2024)	28
2.4.3.3	Étude de Chia-Hung Yeh et al. (2019)	29
2.4.3.4	Étude de Xanthi Bampoula et al. (2021)	29
2.5	Synthèse	29
2.6	Etude comparative des techniques de maintenance prédictive dans l'Industrie 4.0	32
2.6.1	Définitions des Critères de Comparaison	32
2.6.1.1	Exactitude (Accuracy)	32
2.6.1.2	Temps d'Apprentissage (Learning Time)	32
2.6.1.3	Temps de Prédiction (Prediction Time)	33
2.6.1.4	Flexibilité	33
2.6.1.5	Facilité d'Interprétation	33
2.6.1.6	Utilisation des Ressources	33
2.6.2	Tableau comparatif	34
2.7	Conclusion	37

3	Conception et réalisation d'un modèle de la Maintenance Preductive pour détecter les anomalies	38
3.1	Introduction	38
3.2	Methodologie	39
3.2.1	Collecte de données	40
3.2.1.1	Concaténation des déférentes sources de données	40
3.2.1.2	Description de dataset	41
3.2.2	Prétraitement des données	41
3.2.3	Les métrique :	46
3.2.4	Modèles utilisés et proposés	46
3.2.4.1	Classification Binaire pour chaque Composant	47
3.2.4.2	Modèle de maintenance prédictive LSTM (Long Short-Term Memory)	47
3.2.4.3	Modèle de maintenance prédictive GRU (Gated Recurrent Unit)	52
3.2.4.4	Modèle de maintenance prédictive transformers :	54
3.2.4.5	Modèle de maintenance prédictive Hybride (GRU+LSTM) :	58
3.3	Évaluation des Modèles Prédictifs pour la Détection des Défaillances Composantes : Une Étude Comparative	61
3.3.1	Étude Comparative pour la Détection des Défaillances de Composant 1	61
3.3.1.1	Interprétation des Résultats	62
3.3.1.2	Choix du Meilleur Modèle	63
3.3.2	Étude Comparative pour la Détection des Défaillances de Composant 2	63
3.3.2.1	Interprétation des Résultats	64
3.3.2.2	Choix du Meilleur Modèle	64
3.3.3	Étude Comparative pour la Détection des Défaillances du Composant 3	65
3.3.3.1	Interprétation des Résultats	65
3.3.3.2	Choix du Meilleur Modèle	66
3.4	Conclusion	66
	Conclusion Générale et Perspectives	67

Table des figures

1.1	Résumé des types de maintenance [15]	4
1.2	Révolution industrielle [1]	6
1.3	Cycle de vie d'un produit [18]	8
1.4	Les étapes de la maintenance prédictive [26]	12
2.1	Résumé des méthodes de PdM dans l'industrie 4.0	16
2.2	Architecture de la methode proposée par [16]	16
2.3	Structure de RF [8]	19
2.4	Le model SVM[8]	20
2.5	Auto-Encodeur[8]	21
2.6	L'architecture des transformers[19]	22
2.7	CNN dan la PdM [36]	23
2.8	Les Réseaux de Neurones Récurrents(RNN) [8]	24
2.9	LSTM [8]	25
2.10	Architecture du model proposé par [14]	26
2.11	Architecture de GRU	27
2.12	L'architecture de la méthode proposée par [24]	28
2.13	L'architecture de la méthode proposée par [42]	29
3.1	La méthode adoptée	39
3.2	importation et concaténation des dataset	40
3.3	les différentes caractéristiques de dataset final	41
3.4	Exemple d'Encodage des caractéristiques de dataset	42
3.5	méthode adoptée pour le découpage	42
3.6	les capteur	43
3.7	le fenêtrage de dataset	44
3.8	Le fenêtrage chevauché	45
3.9	Nombre de classe 1(les pannes) avant et après fenêtrage	46
3.10	L'architecture générale :	47

Table des figures

3.11 l'architecture de la machine étudiée	47
3.12 l'architecture détaillée du model de LSTM	48
3.13 aperçu sur le code l'étape des tests	49
3.14 Matrice de confusion de LSTM	49
3.15 la courbe ROC de composant 1	50
3.16 la courbe ROC de composant 2	50
3.17 la courbe ROC de composant 3	50
3.18 la courbe ROC de composant 4	50
3.19 comparaison entre les vraies valeurs et les valeurs prédites	50
3.20 les résultat de LSTM avec 12 époques	51
3.21 l'architecture détaillée du model de GRU	52
3.22 matrice de confusion de GRU	53
3.23 la courbe ROC de composant 1	53
3.24 la courbe ROC de composant 2	53
3.25 la courbe ROC de composant 3	53
3.26 la courbe ROC de composant 4	53
3.27 comparaison entre les vraies valeurs et les valeurs prédites	54
3.28 l'architecture détaillée du model proposé	54
3.29 Matrice de confusion modèle de transformers	56
3.30 la courbe ROC de composant 1	56
3.31 la courbe ROC de composant 2	56
3.32 la courbe ROC de composant 3	57
3.33 la courbe ROC de composant 4	57
3.34 comparaison entre les vraies valeurs et les valeurs prédites	57
3.35 l'architecture détaillée du modele de hybride	58
3.36 matrice de confusion de model hybride	59
3.37 la courbe ROC de composant 1	60
3.38 la courbe ROC de composant 2	60
3.39 la courbe ROC de composant 3	60
3.40 la courbe ROC de composant 4	60
3.41 comparaison entre les vraies valeurs et les valeurs prédites	60
3.42 la comparaison des performances des modèles du composant 1	62
3.43 la comparaison des performances des modèles du composant 2	63
3.44 la comparaison des performances des modèles du composant 3	65

Liste des tableaux

1.1	Comparaison des types de maintenance	9
2.1	Récapitulatif des exemples d'applications des techniques de Maintenance Prédictive dans l'Industrie 4.0	31
2.2	Comparaison et évaluation des techniques de PdM dans l'industrie 4.0	35
2.3	Classement des techniques de PdM dans l'industrie 4.0	36
3.1	Descriptions des métriques de classification	46
3.2	Performances du modèle LSTM	49
3.3	Performances du modèle GRU	52
3.4	Performances du modèle de transformers	56
3.5	Performances du modèle d'hybride(LSTM et GRU	59

Liste des abréviations

AFNOR	Association Française de Normalisation
AUC	Area Under the Curve (Aire sous la courbe ROC)
CNN	Convolutional Neural Network
DL	Deep Learning (Apprentissage Profond)
EN	Norme Européenne
FD	Fascicule de Documentation
FN	False Negative (Faux négatif)
FP	False Positive (Faux positif)
GRU	Gated Recurrent Unit
IA	Intelligence Artificielle
IIoT	Internet Industriel des Objets
IoT	Internet des Objets
LSTM	Long Short-Term Memory
ML	Machine Learning (Apprentissage Automatique)
NF	Norme Française
PdM	Maintenance Prédictive
RF	Random Forests
RL	Régression Linéaire
RNN	Réseaux Neuronaux Récurrents
ROC	Receiver Operating Characteristic (Caractéristique de fonctionnement du récepteur)
SCADA	Supervisory Control and Data Acquisition
SVM	Support Vector Machine
TN	True Negative (Vrai négatif)
TP	True Positive (Vrai positif)

Introduction générale

L'industrie moderne, en constante évolution vers le paradigme de l'Industrie 4.0, repose sur des systèmes de production de plus en plus complexes et interconnectés. Cette transformation radicale est caractérisée par l'intégration intensive des technologies de l'information et de la communication dans les processus industriels. Les systèmes de production deviennent ainsi plus intelligents, autonomes et capables de s'adapter dynamiquement aux changements et aux exigences du marché. Dans ce contexte, la maintenance industrielle joue un rôle crucial non seulement dans la préservation des actifs, mais aussi dans l'optimisation de la performance opérationnelle et la réduction des coûts associés aux arrêts non planifiés. Une maintenance efficace peut significativement améliorer la durée de vie des équipements, assurer une production ininterrompue et optimiser les ressources. Cependant, les méthodes traditionnelles de maintenance, fondées sur des approches réactives et préventives basées sur des calendriers fixes, montrent leurs limites face aux exigences actuelles. Ces méthodes sont souvent inefficaces pour détecter précocement les anomalies et prévenir les défaillances critiques, ce qui entraîne des pertes économiques importantes et une diminution de la compétitivité industrielle. Face à ces défis, les nouvelles technologies émergentes telles que l'Internet des Objets (IoT), le Big Data et l'intelligence artificielle (IA) offrent des solutions potentielles en permettant une surveillance continue et une analyse en temps réel des équipements et des processus industriels. L'IoT permet la collecte massive de données à partir de capteurs intégrés dans les machines, tandis que le Big Data et l'IA permettent de traiter et d'analyser ces données pour en extraire des informations précieuses et prendre des décisions éclairées. Parmi ces avancées technologiques, les réseaux de neurones récurrents, notamment les LSTM (Long Short-Term Memory) et les GRU (Gated Recurrent Unit), se distinguent par leur capacité à modéliser des séquences temporelles complexes et à identifier des modèles anormaux avec une précision accrue. Ces modèles sont particulièrement adaptés pour la prédiction de séries chronologiques et la détection d'anomalies dans les données industrielles. Leur utilisation dans le cadre de la maintenance prédictive permet non seulement de prévoir les défaillances avant qu'elles ne se produisent, mais aussi d'optimiser les opérations de maintenance en fonction des besoins réels des équipements. Ainsi, dans cette étude, nous explorerons comment une approche hybride combinant les LSTM et les GRU peut être appliquée pour améliorer la maintenance prédictive, anticiper les défaillances et optimiser les opérations industrielles dans le cadre de l'Industrie 4.0. Nous aborderons les avantages et les défis de cette approche, ainsi que les implications pour les entreprises cherchant à adopter des pratiques de maintenance plus intelligentes et plus efficaces.

Problématique

Comment les technologies émergentes telles que les réseaux de neurones récurrents LSTM et GRU peuvent-elles être intégrées pour améliorer la maintenance prédictive dans le contexte de l'Industrie 4.0, en surmontant les limitations des méthodes traditionnelles et en optimisant la détection des anomalies et la prévention des défaillances critiques?

Structure du mémoire

Chapitre 1 : Généralités sur la maintenance industrielle : Ce premier chapitre introduit le concept de maintenance industrielle en explorant ses différentes formes historiques. Une comparaison détaillée des différents types de maintenance est présentée, soulignant leurs avantages et limitations respectifs.

Chapitre 2 : La maintenance prédictive dans l'Industrie 4.0 : État de l'art : Ce chapitre explore comment la révolution industrielle a impacté les besoins et les pratiques de maintenance, présente les différentes techniques et travaux réalisés pour améliorer la maintenance prédictive.

Chapitre 3 : Conception et réalisation d'un modèle de la Maintenance Prédictive pour détecter les anomalies : Ce chapitre est dédié au détail de nos modèles que nous avons proposés pour la résolution du problème ainsi que leurs expérimentations et aux résultats obtenus.

Conclusion Générale : Cette conclusion clôture notre travail en présentant l'apport essentiel réalisé ainsi que d'éventuels perspectives.

Chapitre 1

Généralités sur la maintenance industrielle

1.1 Introduction à la maintenance

La maintenance joue un rôle essentiel dans l'industrie, tant sur le plan technique qu'économique. Son objectif principal est d'optimiser la disponibilité des installations industrielles et de prolonger leur durée de vie. La maintenance assure également la sécurité des personnes et des biens en prévenant les incidents et les accidents. Dans ce chapitre, nous explorerons les concepts de base de la maintenance, retracerons son évolution historique et comparerons différents types de maintenance, avec un accent particulier sur la maintenance prédictive. Nous soulignerons ses avantages, sa diversité d'approche et les nombreuses technologies et outils utilisés, tout en décrivant sa mise en œuvre dans l'Industrie 4.0.

1.1.1 Définition de la maintenance

La maintenance peut être définie de manière exhaustive comme l'ensemble des démarches techniques et administratives orchestrées en vue de préserver ou rétablir l'intégrité fonctionnelle d'un objet, d'un système ou d'une machine, garantissant ainsi son aptitude à accomplir les tâches qui lui sont assignées. [17].

1.1.2 Evolution historique des pratiques de maintenance

Au cours des dernières décennies, les pratiques de maintenance ont évolué de manière significative, passant d'une approche essentiellement réactive à des méthodologies plus préventives et prédictives comme le montre la figure 1.1. Comprendre cette évolution est essentiel pour saisir pleinement les défis et les opportunités auxquels sont confrontés les professionnels de la maintenance aujourd'hui. Les paragraphes suivants décrivent les trois principaux types de maintenance à savoir : la corrective, la préventive et la prédictive.

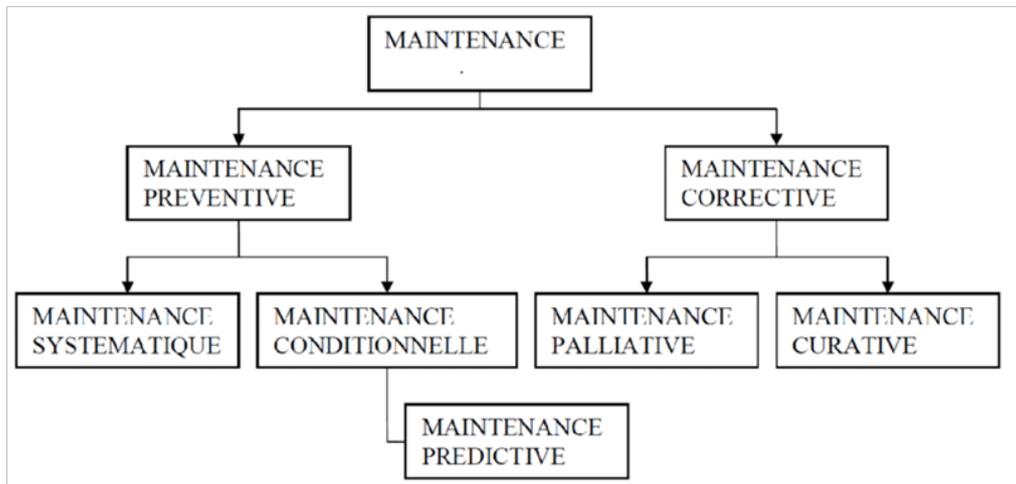


FIGURE 1.1 – Résumé des types de maintenance [15]

1.1.2.1 Maintenance Corrective

La maintenance corrective est définie par l'AFNOR (FD X 60-000) [41] comme « la maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise ». En d'autres termes, elle intervient après la survenue d'une défaillance pour restaurer l'équipement à son état opérationnel. Cette approche est essentielle pour assurer la continuité des opérations en minimisant les interruptions imprévues. La maintenance corrective se subdivise en deux formes principales :

Maintenance Curative (Avant les années 1950) Selon l'AFNOR (FD X60-000) [41], « la maintenance curative est une action de maintenance corrective ayant pour objet de rétablir un bien dans un état spécifié pour lui permettre d'accomplir une fonction requise ». Les interventions curatives visent à fournir des solutions permanentes pour réparer les pannes. Elles peuvent inclure des modifications ou des améliorations de l'équipement pour réduire la probabilité de récurrence de la défaillance ou en limiter les effets. Par exemple, si une machine présente une défaillance répétitive d'un composant spécifique, une action curative pourrait consister à remplacer ce composant par un modèle amélioré ou à modifier le design de l'équipement pour éliminer la cause de la panne.

Maintenance Palliative (Avant les années 1950) L'AFNOR (FD X60-000) [41] décrit la maintenance palliative comme « une action de maintenance corrective destinée à permettre à un bien d'accomplir provisoirement tout ou partie d'une fonction requise, appelée couramment dépannage ». Cette approche se compose principalement d'interventions temporaires, visant à maintenir l'équipement en état de fonctionnement jusqu'à ce qu'une solution curative puisse être mise en œuvre. Les actions palliatives sont souvent utilisées dans des situations d'urgence où une réparation immédiate n'est pas possible. Par exemple, un roulement endommagé peut être lubrifié de manière intensive pour prolonger son utilisation jusqu'à ce qu'il puisse être remplacé.

1.1.2.2 Maintenance Préventive

La maintenance préventive, selon l'AFNOR (FD X 60-000)[41], est « la maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien ». Cette approche proactive vise à éviter les pannes avant qu'elles ne surviennent, en effectuant des interventions planifiées pour maintenir les équipements en bon état. La maintenance préventive se divise en deux catégories distinctes :

Maintenance Systématique (Années 1950-1970) La maintenance systématique, telle que définie par l'AFNOR (FD X60-000)[41], est « une maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage sans contrôle préalable de l'état du bien ». Elle est déclenchée selon un calendrier basé sur des critères de temps ou d'utilisation (comme les heures de fonctionnement, les kilomètres parcourus, etc.). Les interventions consistent à nettoyer, réparer ou remplacer périodiquement des composants, sans évaluer l'état actuel de l'équipement. Par exemple, une machine peut être programmée pour une révision tous les 6 mois, indépendamment de son état réel, afin de prévenir les pannes potentielles.

Maintenance Conditionnelle (Années 1970-1990) Selon l'AFNOR (FD X60-000)[41], la maintenance conditionnelle est « une maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement et intégrant les actions qui en découlent ». Elle repose sur l'évaluation continue de l'état de l'équipement par le biais de la surveillance de paramètres clés (comme les vibrations, la température, la pression, etc.). Cette surveillance peut être exécutée selon un calendrier, à la demande ou de façon continue. Le principe de la maintenance conditionnelle est de déclencher des actions de maintenance lorsque des indicateurs spécifiques atteignent des seuils prédéfinis, signalant un risque accru de défaillance. Par exemple, si la température d'un moteur dépasse un certain seuil, une intervention de maintenance sera programmée pour éviter une panne imminente.

1.1.2.3 Maintenance Prédicative (Années 1990-à ce jour)

La maintenance prédictive, qui est une évolution de la maintenance conditionnelle, représente le type de maintenance le plus récent et a captivé l'attention tant des chercheurs que des industriels. Elle se distingue par son approche proactive et technologique, visant à anticiper et prévenir les pannes avant qu'elles ne surviennent. Selon la norme NF EN 13306 X 60-319[27], la maintenance prédictive est définie comme « une maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien ».

1.2 Évolution de l'Industrie et de ses Besoins en Maintenance

L'évolution de l'industrie au fil du temps est un témoignage puissant de l'innovation et du progrès technologique. La figure 1.2 présente une représentation visuelle succincte de cette évolution, offrant un aperçu captivant des tendances et des changements qui ont façonné le paysage industriel moderne.

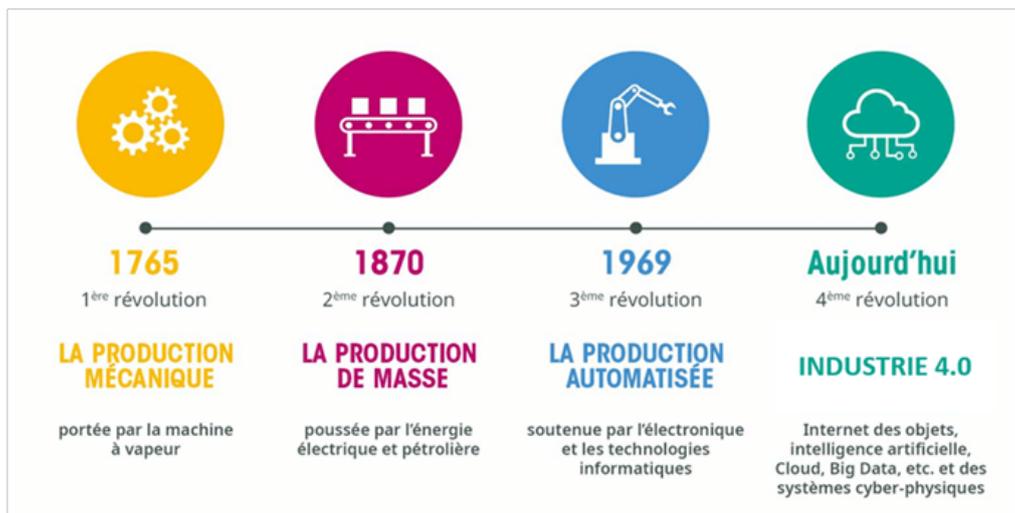


FIGURE 1.2 – Révolution industrielle [1]

1.2.1 Révolution industrielle à l'industrie 4.0

Depuis l'avènement de la première révolution industrielle au 18^e siècle jusqu'à l'émergence de l'Industrie 4.0 au 21^e siècle, l'industrie a connu une série de transformations majeures. De la mécanisation à l'automatisation, chaque étape a marqué un tournant dans l'histoire de la production. Les paragraphes suivants exploreront l'évolution de l'industrie, des premières usines à vapeur aux usines intelligentes de l'ère numérique [25].

1.2.1.1 La Première Révolution Industrielle (fin du 18^e siècle - début du 19^e siècle)

La première révolution industrielle marque une période de transformation majeure de l'industrie grâce à l'invention de machines qui remplacent les outils manuels. Cette révolution est souvent associée à l'introduction de la machine à vapeur, mais il est important de mentionner également le métier à tisser automatique introduit par Joseph-Marie Jacquard en 1789. Ce métier à tisser utilisait un système de programmation par cartes perforées, une innovation qui a révolutionné le secteur textile.

1.2.1.2 La Seconde Révolution Industrielle (fin du 19^e siècle - début du 20^e siècle)

La seconde révolution industrielle se situe entre la seconde moitié du 19^e siècle et le début du 20^e siècle. Cette période est caractérisée par l'utilisation de nouvelles sources d'énergie comme l'électricité et le pétrole. Elle a vu le développement massif de la production mécanique, chimique et la distribution de ces ressources. Les inventions majeures de cette époque incluent la radio, le téléphone, et les premiers ordinateurs, ainsi que les débuts des réseaux de neurones.

1.2.1.3 La Troisième Révolution Industrielle (années 1970)

La troisième révolution industrielle, amorcée dans les années 1970, introduit des avancées significatives dans les sciences et technologies. Cette période est marquée par l'utilisation de l'énergie nucléaire et le développement de l'électronique et de l'informatique. Ces

technologies ont permis la miniaturisation des équipements, l'automatisation avancée de la production, et le développement de produits de synthèse, des technologies spatiales, des biotechnologies, et de l'Internet. Cependant, cette ère est également associée à des préoccupations environnementales et sociales, notamment en raison de l'obsolescence programmée.

1.2.1.4 La Quatrième Révolution Industrielle (Industrie 4.0, depuis 2011)

L'Industrie 4.0, introduite par le gouvernement allemand en 2011, représente la quatrième révolution industrielle. Elle vise à promouvoir la numérisation de la fabrication pour renforcer l'industrie européenne face à la concurrence mondiale. L'Industrie 4.0 intègre des technologies avancées telles que l'Internet des objets (IoT), l'intelligence artificielle (IA), le big data, et la cyber-physique pour créer des usines intelligentes. Cette révolution se concentre sur l'amélioration de l'efficacité, la flexibilité, et la personnalisation des processus de production, tout en créant des emplois en Europe.

1.2.2 Conclusion

En conclusion, l'évolution de l'industrie à travers les différentes révolutions a été marquée par des avancées technologiques majeures qui ont façonné notre monde moderne. De la mécanisation à la numérisation, chaque étape a apporté son lot d'innovations et de défis. L'Industrie 4.0 représente une étape cruciale dans cette évolution, promettant des usines intelligentes et des processus de production optimisés grâce à l'intégration de technologies de pointe. Comprendre cette évolution est essentiel pour anticiper les futurs défis et opportunités dans le domaine de la maintenance industrielle.

1.3 La maintenance dans l'industrie

La maintenance industrielle, d'après l'Association Française de Normalisation (AFNOR) en 1994 [2], se définit comme suit : « L'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise ». Cette définition souligne l'importance d'un ensemble cohérent de mesures tout au long de la vie d'un équipement (voir la figure 1.3) pour assurer son bon fonctionnement et sa capacité à remplir sa fonction attendue.

Contrairement à la perception courante, la maintenance industrielle ne se limite pas à la simple réparation des pannes. Elle implique plutôt une approche proactive visant à anticiper et à éviter toute défaillance susceptible d'entraîner des pertes pour l'entreprise. Cela comprend la mise en place de programmes de maintenance préventive et prédictive, la surveillance continue de l'état des équipements, ainsi que des mesures correctives en cas de défaillance imminente. Dans ce contexte, le département de maintenance a pour mission de réaliser plusieurs objectifs essentiels. Cela inclut garantir la disponibilité et la durée de vie optimale des équipements en planifiant des interventions de maintenance régulières, maintenir un stock minimal de pièces de rechange pour réduire les temps d'arrêt, optimiser les coûts de maintenance en identifiant les interventions les plus efficaces, et assurer la sécurité des personnes et des biens en veillant à ce que les équipements soient conformes aux

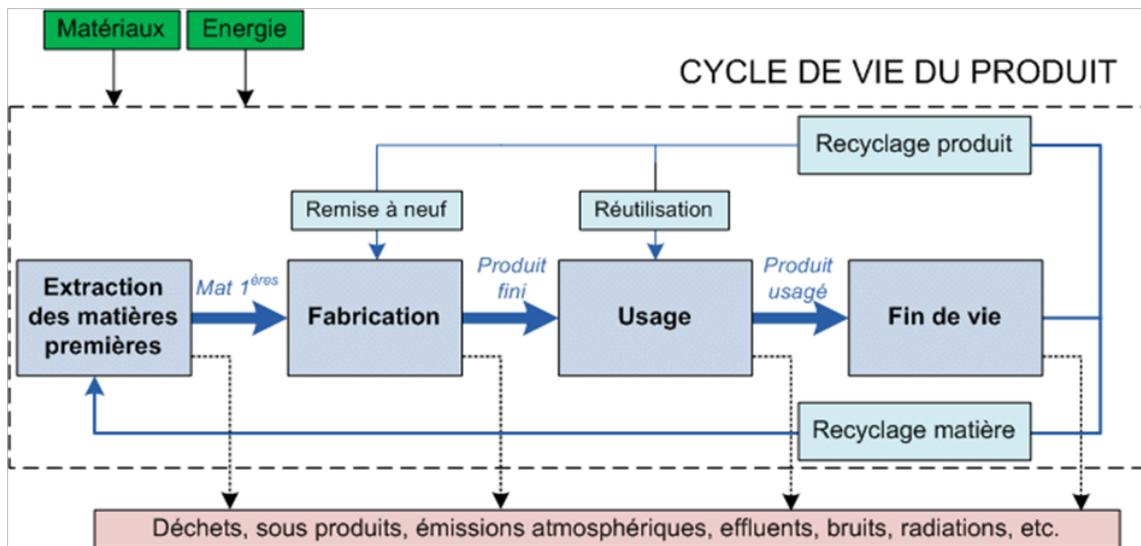


FIGURE 1.3 – Cycle de vie d'un produit [18]

normes de sécurité en vigueur.

Ainsi, la maintenance industrielle joue un rôle crucial dans la pérennité et la rentabilité des entreprises en assurant le bon fonctionnement des équipements tout en minimisant les risques et les coûts associés. Elle contribue également à améliorer la productivité et la compétitivité de l'entreprise en garantissant la disponibilité des équipements nécessaires à la production.

1.4 Comparaison des types de maintenance

Dans cette section nous allons présenter un tableau comparatif entre les différentes techniques de maintenance selon les différents critères cités ci-dessous.

1.4.1 Critères de comparaison

Dans le domaine de la maintenance industrielle, le choix du type de maintenance à adopter est crucial pour assurer la fiabilité opérationnelle des équipements tout en optimisant les coûts et les ressources. Cette section explore les critères essentiels utilisés pour évaluer et comparer les stratégies de maintenance, permettant ainsi aux professionnels de prendre des décisions éclairées basées sur les objectifs de performance, les contraintes financières et les exigences opérationnelles spécifiques de leur organisation.

- **Objectif principal** : L'objectif fondamental que chaque type de maintenance cherche à accomplir.
- **Moment de l'intervention** : Le moment spécifique où les actions de maintenance sont réalisées.
- **Méthodologie** : Les approches et techniques spécifiques employées dans chaque type de maintenance.
- **Coût** : Les coûts associés à la mise en œuvre et à la gestion de chaque type de maintenance.
- **Impact sur la production** : L'effet de chaque type de maintenance sur la continuité et l'efficacité de la production.

- **Exigences en termes de ressources :** Les besoins spécifiques en termes de main-d'œuvre, d'outils, de technologies, et d'autres ressources.
- **Niveau de complexité :** La complexité associée à la mise en œuvre et à la gestion de chaque type de maintenance.

1.4.2 Tableau comparatif

Le tableau 1.1 compare les différents types de maintenance selon les critères énumérés dans la section 2.5.1.

Critère	Maintenance corrective	Maintenance préventive systématique	Maintenance prédictive
Définition	Actions effectuées après la détection d'une panne [41]	Interventions planifiées à intervalles réguliers [41]	Interventions basées sur des prévisions analytiques [27]
Objectif principal	Réparer après la survenue d'une panne [26]	Prévenir les pannes par des interventions périodiques [26]	Anticiper les pannes grâce aux analyses de données [20]
Moment de l'intervention	Après la survenue d'une panne [26]	À intervalle régulier [26]	Avant la panne prévue [20]
Méthodologie	Réparations et remplacements [26]	Calendrier fixe de maintenance [26]	Analyse avancée des données et apprentissage automatisé [20]
Coût	Généralement élevé à long terme [26]	Coût régulier et prévisible [26]	Variable, dépend de la condition de l'équipement [20]
Impact sur la production	Arrêts imprévus fréquents [26]	Arrêts planifiés réguliers [26]	Minimisation des arrêts imprévus [26]
Exigences en termes de ressources	Main-d'œuvre et pièces de rechange disponibles [26]	Main-d'œuvre et pièces de rechange planifiées [26]	Technologies avancées et experts en analyse [20]
Niveau de complexité	Relativement simple [26]	Modérément complexe [26]	Très complexe, nécessite des technologies avancées [20]
Technologies utilisées	Outils de réparation [26]	Calendriers et check-list [26]	IoT, Big Data, IA [20]
Exemples d'application	Toutes industries, en cas de panne [26]	Industries avec équipements critiques [26]	Industries à forte automatisation (ex. fabrication avancée) [38]

TABLE 1.1 – Comparaison des types de maintenance

1.5 Avantages et Inconvénients

Chaque type de maintenance présente des avantages qui contribuent à la fiabilité et à la disponibilité des équipements, mais également des limitations à prendre en compte lors de la planification et de l'exécution des activités de maintenance [28]. Ces derniers seront récapitulés dans le tableau 1.2 :

Type de maintenance	Avantages	Inconvénients
Maintenance corrective	<ul style="list-style-type: none"> — Réactivité à résoudre les pannes existantes. — Permet de remettre rapidement les équipements en état de fonctionnement requis. — Interventions ciblées sur les problèmes identifiés. 	<ul style="list-style-type: none"> — Peut entraîner des interruptions de production significatives. — Coûts imprévus dus aux pannes non planifiées. — Risque de réapparition des mêmes problèmes sans solution permanente.
Maintenance préventive systémique	<ul style="list-style-type: none"> — Planification des interventions basée sur des calendriers prédéfinis. — Réduction de la probabilité de défaillance grâce à des actions régulières. — Facilité de gestion et de suivi des activités de maintenance. 	<ul style="list-style-type: none"> — Risque d'interventions inutiles sur des équipements en bon état. — Coûts associés aux interventions régulières, même si elles ne sont pas toujours nécessaires. — Potentiellement moins efficace pour prévenir les pannes imprévues.
Maintenance préventive conditionnelle	<ul style="list-style-type: none"> — Intervention basée sur l'état réel des équipements. — Réduction des coûts en n'intervenant que lorsque cela est nécessaire. — Prévention des pannes imprévues grâce à une surveillance continue. 	<ul style="list-style-type: none"> — Complexité de la mise en œuvre des systèmes de surveillance. — Besoin de compétences spécialisées pour interpréter les données. — Risque de ne pas détecter certains problèmes potentiels si les critères de déclenchement ne sont pas bien définis.

<i>Type de maintenance</i>	Avantages	Inconvénients
Maintenance prédictive	<ul style="list-style-type: none"> — Anticipation des pannes grâce à l'analyse des données. — Planification précise des interventions. — Minimisation des arrêts de production et des coûts de maintenance. — Maximisation de la durée de vie des équipements. 	<ul style="list-style-type: none"> — Nécessite des technologies avancées et des compétences spécialisées. — Coûts élevés de mise en œuvre et de maintenance des systèmes de surveillance. — Complexité de l'interprétation des données.

La comparaison des différentes stratégies de maintenance met en évidence l'importance et la diversité des approches disponibles, chacune avec ses avantages et ses limites. Cependant, la maintenance prédictive se distingue par son caractère proactif et son utilisation de technologies avancées telles que l'analyse de données. En permettant une surveillance continue des équipements et une anticipation des pannes, elle offre la possibilité de réduire les temps d'arrêt, d'optimiser les coûts de maintenance et d'améliorer la fiabilité opérationnelle. Ainsi, la maintenance prédictive représente un élément crucial de la gestion des actifs industriels, offrant des avantages significatifs en termes de performance et de rentabilité. Son adoption croissante témoigne de son importance croissante dans le paysage industriel contemporain.

1.6 Les étapes de la maintenance prédictive

Les étapes de la Maintenance Prédictive (PdM) représentent un processus stratégique crucial pour la gestion proactive des équipements industriels. Ce processus, résumé de manière illustrative dans la Figure 1.4, englobe la collecte de données à partir de divers systèmes comme MES et ERP, leur analyse à travers des algorithmes d'IA et d'analyse prédictive, ainsi que la génération d'alertes et de tableaux de bord pour une gestion efficace des opérations de maintenance [26].

- **Collecte des Données :** Les données sont collectées en continu à partir de la ligne de production à l'aide de capteurs installés sur les équipements. Ces capteurs mesurent divers paramètres tels que la température, la pression, les vibrations, les niveaux de fluides, etc. Les données sont également extraites des systèmes MES (Manufacturing Execution System), ERP (Enterprise Resource Planning) et des systèmes de gestion de la qualité pour obtenir une vue complète de l'état de la production.
- **Stockage des Données :** Les données collectées sont stockées dans un Data Store centralisé ou dans un Data Historian. Ce stockage centralisé permet d'accumuler un historique détaillé des performances des équipements et des processus au fil du temps. Les données peuvent être structurées et enrichies avec des métadonnées pour faciliter leur analyse ultérieure.

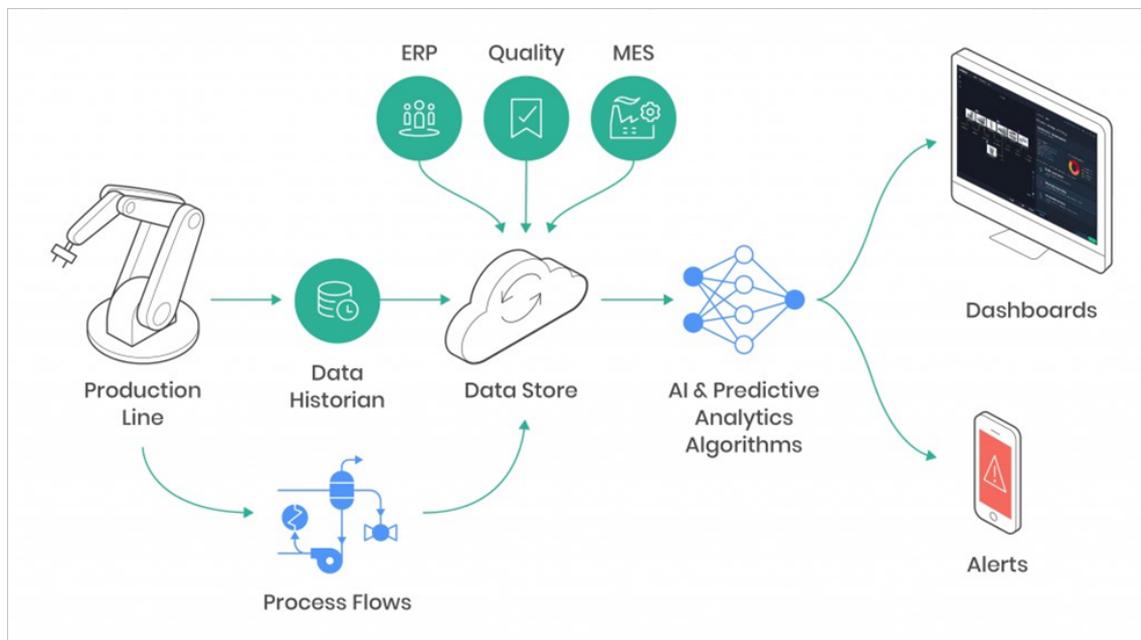


FIGURE 1.4 – Les étapes de la maintenance prédictive [26]

- **Prétraitement des Données :** Avant l'analyse, les données subissent un processus de prétraitement. Cela inclut le nettoyage des données pour éliminer les valeurs aberrantes et les erreurs de mesure, la normalisation pour mettre à l'échelle les différentes variables, et l'imputation pour remplir les données manquantes. Ce processus garantit que les données sont de haute qualité et prêtes pour l'analyse avancée.
- **Analyse des Données :** Les données prétraitées sont soumises à des algorithmes avancés d'intelligence artificielle et d'analyse prédictive. Ces algorithmes comprennent des techniques telles que les réseaux de neurones, les arbres de décision, les méthodes de clustering, et les modèles probabilistes comme les modèles de Markov cachés. L'objectif est d'identifier des modèles de comportement normal et d'anomalies potentielles, ainsi que de prédire les défaillances avant qu'elles ne se produisent.
- **Génération d'Alertes :** Sur la base des résultats de l'analyse, des alertes sont générées automatiquement lorsque des conditions anormales sont détectées. Ces alertes peuvent être des notifications en temps réel envoyées aux opérateurs ou intégrées dans des systèmes de gestion des alarmes pour une action immédiate. Elles aident à prévenir les pannes imprévues et à minimiser les temps d'arrêt non planifiés.
- **Visualisation et Reporting :** Les résultats de l'analyse sont visualisés à travers des tableaux de bord interactifs. Ces dashboards fournissent des graphiques, des diagrammes et des indicateurs clés de performance (KPIs) qui permettent aux utilisateurs de surveiller efficacement l'état des équipements et des processus. Les rapports détaillés générés à partir des données analysées offrent des insights précieux pour optimiser les opérations et planifier la maintenance proactive.

1.7 Les approches de la maintenance prédictive

Dans ce qui suit, nous explorerons les approches de la maintenance prédictive, qui comprennent les modèles basés sur la connaissance, la physique, les données, ainsi que

les approches hybrides. Ces méthodologies jouent un rôle crucial dans la gestion proactive des équipements industriels en anticipant les défaillances et en optimisant les stratégies de maintenance.

- **Modèles basés sur la Connaissance :** Les modèles basés sur la connaissance reposent sur l'expertise accumulée des professionnels du domaine. Ces systèmes utilisent une base de connaissances qui comprend des règles et des cas spécifiques collectés au fil du temps. Ils sont capables d'appliquer ces connaissances pour diagnostiquer et prédire les défaillances des équipements. Cette approche peut être catégorisée en algorithmes basés sur des règles, des cas, et des connaissances floues, permettant une adaptation flexible aux conditions opérationnelles variées [3] [4].
- **Modèles basés sur la Physique :** Les modèles basés sur la physique utilisent des représentations mathématiques explicites pour formaliser la compréhension des processus de dégradation des équipements. Ces modèles exigent une expertise approfondie en mathématiques et en physique pour leur développement et leur application. Ils incluent des approches telles que les modèles mathématiques, les modèles de Markov caché, les modèles de distribution de probabilité, et les modèles de filtre, permettant une modélisation précise des phénomènes physiques complexes [20] [38] [5].
- **Modèles basés sur les Données :** Les modèles basés sur les données exploitent l'abondance croissante de données provenant des capteurs installés sur les équipements. Avec l'avancement des technologies de calcul, ces modèles utilisent des techniques d'apprentissage automatique avancées pour extraire des informations utiles à partir de ces données. Ils sont classés en techniques d'apprentissage automatique (ML) et techniques statistiques, permettant une analyse proactive des tendances et des anomalies dans les données de performance des équipements [38] [6].
- **Modèles Hybrides :** Les modèles hybrides combinent différentes approches de maintenance prédictive pour capitaliser sur leurs avantages respectifs. Cette approche émergente vise à créer des modèles intégrés qui maximisent la précision et la flexibilité tout en minimisant les limitations individuelles des approches spécifiques. Les modèles hybrides représentent une évolution vers des solutions de prédiction plus robustes et adaptatives [7].

1.7.1 Conclusion

La maintenance industrielle a évolué de manière significative, passant d'approches réactives à des méthodologies préventives et prédictives, reflétant l'innovation technologique et l'amélioration continue des pratiques. La maintenance prédictive, en particulier, représente une avancée majeure grâce à l'intégration de technologies avancées telles que l'Internet des objets (IoT), l'intelligence artificielle (IA) et le Big Data. Cette approche permet non seulement d'anticiper et de prévenir les pannes, mais aussi d'optimiser les coûts et de maximiser la durée de vie des équipements. Comparée à la maintenance corrective et préventive, la maintenance prédictive offre des avantages significatifs en termes de réduction des temps d'arrêt, d'amélioration de la fiabilité des équipements et de gestion proactive des opérations. Cependant, elle nécessite des investissements importants en technologies et en compétences spécialisées. Malgré ces défis, l'adoption croissante de la maintenance prédictive dans l'industrie moderne témoigne de ses bénéfices potentiels.

Dans le contexte de l'industrie 4.0, caractérisée par une interconnectivité accrue et une optimisation des processus grâce à l'automatisation et à l'analyse de données en temps réel,

la maintenance prédictive revêt une importance stratégique. Elle permet non seulement de répondre aux exigences croissantes de fiabilité et de disponibilité des équipements, mais aussi de soutenir une gestion proactive des actifs pour optimiser les performances globales des installations industrielles. C'est précisément cette convergence de technologies avancées et de nécessités opérationnelles dans l'industrie 4.0 qui motive notre étude approfondie sur la maintenance prédictive.

Chapitre 2

La maintenance prédictive dans l'Industrie 4.0 : Etat de l'art

2.1 Introduction

La quatrième révolution industrielle, ou Industrie 4.0, a introduit des transformations significatives dans les processus de fabrication et de maintenance. La maintenance prédictive, en particulier, a gagné en importance en permettant aux industries d'anticiper les pannes et de maximiser l'efficacité opérationnelle grâce à l'utilisation de technologies avancées comme l'Internet des Objets (IoT), le Big Data et l'Intelligence Artificielle (IA). Ce chapitre explore l'état de l'art de la maintenance prédictive dans le cadre de l'industrie 4.0, en détaillant les diverses approches, techniques et technologies utilisées. Les différentes méthodes sont résumées dans la figure 2.1 :

2.2 Utilisation de l'Internet des Objets (IoT) et de l'Internet Industriel des Objets (IIoT) pour la maintenance prédictive

2.2.1 Internet des objets (IoT)

L'Internet des objets (IoT) [13] fait référence à l'interconnexion d'appareils physiques via Internet pour permettre la collecte et l'échange de données. Dans la maintenance prédictive, les capteurs IoT sont utilisés pour surveiller l'état des machines et transmettre des données en temps réel aux systèmes de gestion centralisés. L'approche IoT comporte plusieurs étapes : collecter des données via des capteurs, transmettre ces données via des réseaux de communication, les stocker dans une base de données centralisée et analyser ces données à l'aide de l'apprentissage automatique pour prédire les pannes potentielles et planifier les interventions de maintenance préventive .

Par exemple Elkateb et al. (2024) [16] ont développé une approche de maintenance prédictive basée sur l'IoT et le machine learning pour les machines circulaires à tricoter. Comme le montre la figure 2.2 leur système utilise des capteurs IoT pour collecter des données sur les arrêts de machine, qui sont ensuite analysées pour classer les types d'arrêts et identifier les causes sous-jacentes. Cette méthode permet d'améliorer l'efficacité de la maintenance en prévoyant les défaillances avant qu'elles ne se produisent, réduisant ainsi les temps d'arrêt imprévus et optimisant la performance des machines.

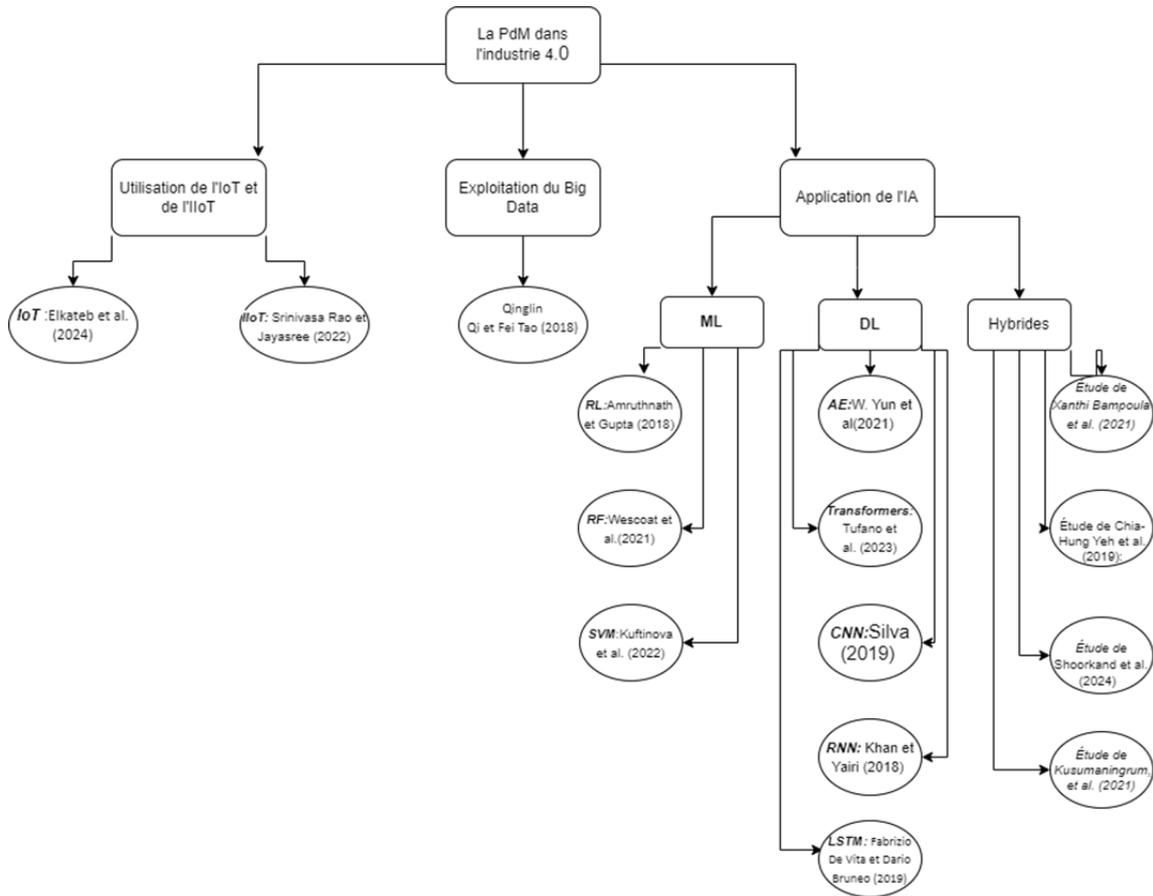


FIGURE 2.1 – Résumé des méthodes de Pdm dans l'industrie 4.0

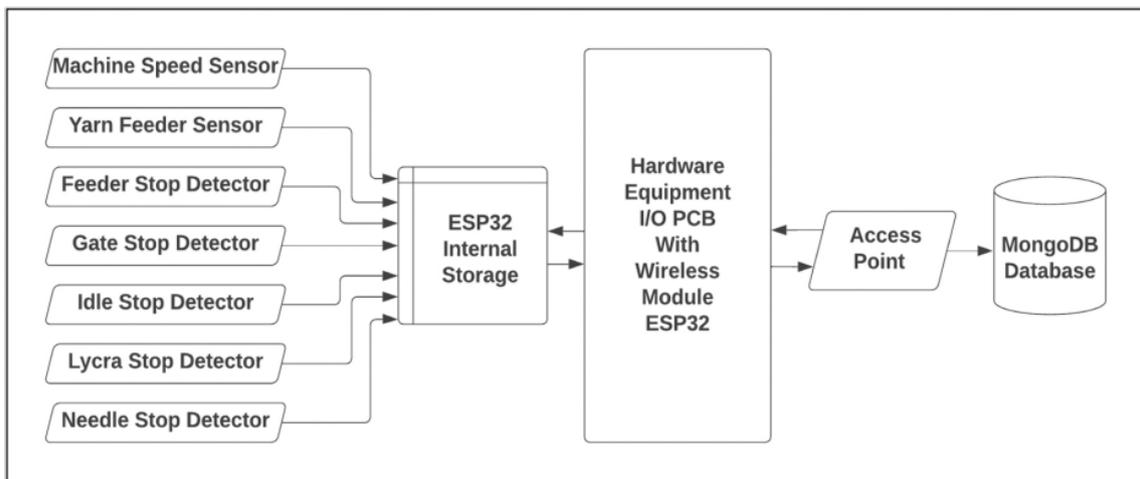


FIGURE 2.2 – Architecture de la methode proposée par [16]

2.2.2 Internet Industriel des objets (IIoT)

L'Internet industriel des objets (IIoT) est une extension de l'Internet des objets spécifiquement adaptée aux environnements industriels. Il intègre la technologie IoT dans des

applications industrielles telles que la surveillance des équipements, la gestion de la chaîne d'approvisionnement et l'optimisation des processus de fabrication. IIoT est conçu pour améliorer l'efficacité opérationnelle, réduire les coûts de maintenance et permettre une prise de décision plus précise en fournissant des données en temps réel sur les performances des machines et des systèmes industriels. L'approche IIoT commence par le déploiement de capteurs et de dispositifs de surveillance sur les équipements industriels. Ces capteurs collectent ensuite des données en temps réel sur les performances et les conditions de fonctionnement de la machine. Les données sont transmises sur un réseau sécurisé vers un système de gestion centralisé. Enfin, des algorithmes d'analyse de données sont appliqués pour détecter les modes de défaillance et prédire les défaillances potentielles, permettant ainsi une maintenance et une optimisation proactives des processus industriels[13]. Par exemple, PNV Srinivasa Rao et PVY Jayasree [31] proposent une méthode de maintenance prédictive en tant que service (PdMaaS) utilisant l'Internet industriel des objets (IIoT) dans le domaine de la construction navale. En exploitant l'IIoT, il est possible de recueillir et d'analyser de vastes quantités de données sur l'équipement des navires, ce qui améliore l'efficacité des opérations et de la maintenance. Cette approche intègre des analyses de fiabilité et de criticité pour élaborer un plan de maintenance basé sur la criticité et la fiabilité (RCBM). L'objectif est d'améliorer la sécurité et la fiabilité des systèmes, de réduire les coûts de maintenance et d'optimiser l'utilisation des ressources en profitant des avantages de l'IIoT, tels que la surveillance conditionnelle, l'analyse systématique et le support à la décision.

2.3 Exploitation du Big Data pour la maintenance prédictive

Les Big Data sont des ensembles de données massives et complexes, caractérisés par leur volume important, leur grande variété et leur vitesse de génération rapide. Ces données proviennent de diverses sources telles que les appareils mobiles, les capteurs IoT, les réseaux sociaux, etc. La gestion de ces données dépasse souvent les capacités des outils de données traditionnels en raison de leur taille et de leur complexité, nécessitant des technologies et des méthodes spécifiques pour les collecter, les stocker, les gérer, les partager, les analyser et les calculer efficacement[30]. La mise en œuvre de l'exploitation du Big Data dans la maintenance prédictive suit une méthodologie structurée en plusieurs étapes. Tout d'abord, la collecte des données est cruciale. Cela implique l'utilisation de capteurs IoT pour recueillir des données en temps réel à partir d'équipements divers dans l'usine, ainsi que la récupération de données historiques à partir de sources telles que les systèmes SCADA et les bases de données de maintenance. Ensuite, les données collectées sont stockées en utilisant divers modèles de stockage, tels que les systèmes de fichiers distribués et les bases de données documentaires, en fonction de leur nature et de leur structure. Le prétraitement des données est une étape essentielle, comprenant le nettoyage des données pour éliminer les erreurs, l'intégration des données provenant de différentes sources et la transformation des données pour les rendre compatibles avec les outils d'analyse. Une fois les données prêtes, l'analyse des données est effectuée en utilisant des techniques de traitement du Big Data telles que le traitement par lots, le traitement en continu et l'analyse hybride pour extraire des informations utiles. Enfin, la mise en œuvre de la maintenance prédictive implique le déploiement de modèles prédictifs, la gestion des alertes et l'optimisation des opérations de maintenance. Dans le cadre de leur recherche sur la maintenance prédictive dans le secteur ferroviaire, Qinglin Qi et Fei Tao (2018) [30] ont mis en place une méthodologie qui commence par la collecte de données à l'aide de capteurs embarqués dans les trains pour recueillir des données en temps réel sur les performances des composants critiques. Les

données ainsi collectées sont prétraitées pour nettoyer et normaliser les données, puis intégrées pour l'analyse. En utilisant des techniques d'analyse de Big Data telles que le clustering et la régression, ils ont réussi à identifier les schémas de défaillance potentiels. Les modèles prédictifs ainsi construits sont intégrés dans les systèmes de gestion de la maintenance ferroviaire pour surveiller en temps réel l'état des composants critiques et planifier proactivement les interventions de maintenance.

2.4 Application de l'Intelligence Artificielle (IA) dans la maintenance prédictive

L'application de l'intelligence artificielle (IA) à la maintenance prédictive révolutionne la façon dont les entreprises gèrent leurs opérations en permettant une approche proactive de la maintenance des équipements industriels. L'intelligence artificielle, en particulier les technologies d'apprentissage automatique (ML) classiques et d'apprentissage profond (DL), offre un énorme potentiel pour analyser les grandes quantités de données générées par les équipements et prédire les pannes avant qu'elles ne surviennent. Dans cette section, nous explorons comment les techniques de ML classiques et le DL peuvent être utilisés dans le domaine de la maintenance prédictive.

2.4.1 Les techniques de ML classiques

Pour appliquer les techniques d'apprentissage automatique à la maintenance prédictive, plusieurs méthodes ont été utilisées pour analyser les données et faire des prédictions précises sur les pannes d'équipement. Dans ce qui suit, nous allons aborder quelques-unes des plus pertinentes :

2.4.1.1 Régression linéaire (RL)

La régression linéaire est une technique de machine learning utilisée pour modéliser la relation entre une variable dépendante et une ou plusieurs variables indépendantes. En maintenance prédictive, elle permet de prévoir les pannes d'équipements en analysant les tendances des données historiques. Les données historiques, comme les heures de fonctionnement et les paramètres de température et de vibration, sont utilisées pour créer un modèle de régression linéaire. Ce modèle établit une relation entre ces variables indépendantes et la probabilité de panne (variable dépendante). Amruthnath et Gupta (2018)[9] ont mené une étude sur l'utilisation des algorithmes de machine learning pour la détection précoce des défauts dans la maintenance prédictive, en se concentrant sur la régression linéaire et cela sur des données collectées dans une usine de fabrication où la maintenance des équipements est cruciale pour minimiser les temps d'arrêt imprévus. La collecte des données historiques s'est faite sur les températures et les vibrations des machines. En appliquant la régression linéaire à ces données, ils ont pu modéliser les tendances et prévoir les pannes potentielles. Les résultats ont montré une amélioration significative de la capacité à identifier les signes avant-coureurs de défaillances, permettant ainsi une intervention proactive. Cette méthode a conduit à une réduction notable des arrêts non planifiés et à une optimisation de la performance globale des machines.

2.4.1.2 Forêts aléatoires (Random Forest RF)

Random Forest (RF) [24] est une technique d'apprentissage automatique supervisée qui se base sur la construction de multiples arbres de décision [10]. Chaque arbre est entraîné sur des échantillons aléatoires de données et utilise un sous-ensemble aléatoire de caractéristiques, ce qui permet de réduire le surajustement et d'améliorer la robustesse du modèle. Pour les prédictions, RF combine les résultats des arbres en utilisant un vote majoritaire pour la classification et une moyenne des prédictions pour la régression (voir la figure 2.3). Dans le contexte de la maintenance prédictive (PDM), RF est utilisé pour analyser les données des capteurs et anticiper les défaillances des équipements. Grâce à sa capacité à traiter des données complexes et variées, RF peut identifier précocement les anomalies et prédire les pannes potentielles, permettant ainsi des interventions de maintenance proactives et réduisant les temps d'arrêt imprévus, tout en optimisant la performance et la fiabilité des machines industrielles.

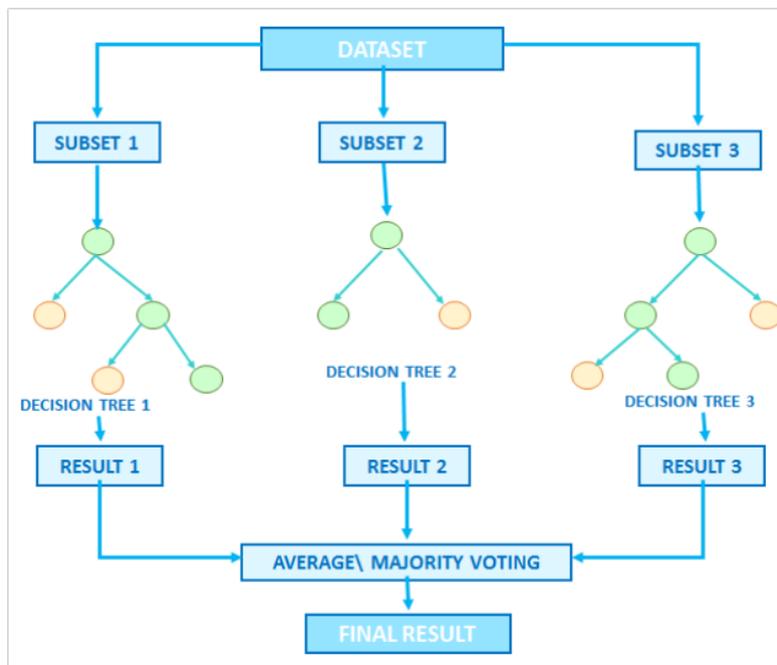


FIGURE 2.3 – Structure de RF [8]

D'après l'étude menée par Wescoat, Krugh et Mears (2021)[40], l'utilisation de l'algorithme Random Forest dans le contexte de la maintenance prédictive a été explorée, en se concentrant spécifiquement sur le cobot UR10 dans un environnement industriel. Cette recherche s'est déroulée dans une usine de fabrication où les robots collaboratifs jouent un rôle crucial dans la production continue. Les chercheurs ont collecté des données de capteurs de vibration situés à l'extrémité du bras du cobot. Grâce à l'application de l'algorithme Random Forest, ils ont analysé ces données pour détecter les anomalies et prévoir les conditions de défaillance potentielles. Les résultats ont démontré que le modèle Random Forest offre une précision élevée dans la prédiction des dysfonctionnements, facilitant ainsi la mise en œuvre d'interventions de maintenance proactives. Cette approche a significativement réduit les arrêts imprévus et amélioré l'efficacité opérationnelle de l'usine.

2.4.1.3 Les Machines à vecteurs de support (SVM)

Les machines à vecteurs de support (SVM)[24] sont des modèles d'apprentissage automatique utilisés pour la classification et la régression. Contrairement à d'autres méthodes, les SVM ne se contentent pas de séparer linéairement les classes de données, mais comme le montre la figure 2.4 cherchent à trouver un hyperplan qui maximise la marge entre ces classes. Ils sont adaptés à la maintenance prédictive en raison de leur capacité à traiter des données complexes comme la température, la pression, la vitesse et les vibrations des équipements industriels. En utilisant des données historiques, les SVM identifient des modèles pour prédire les défaillances des équipements, améliorant ainsi la planification de la maintenance et réduisant les temps d'arrêt imprévus.

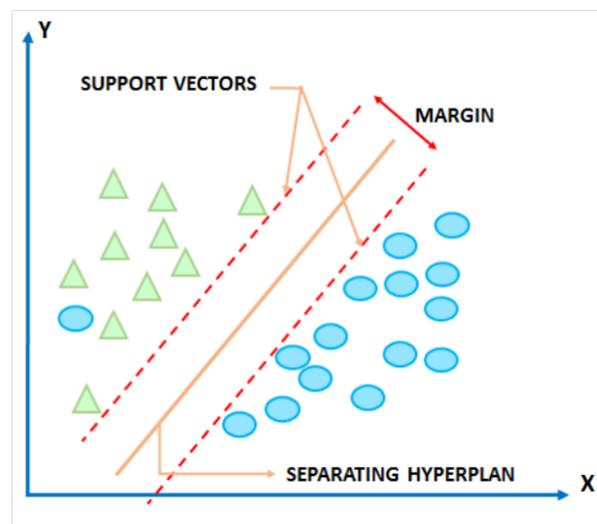


FIGURE 2.4 – Le model SVM[8]

Kuftinova et al. (2022)[23] ont étudié l'application des machines à vecteurs de support (SVM) à la maintenance prédictive dans le secteur manufacturier, où la stabilité opérationnelle est essentielle. Leur recherche s'est focalisée sur l'analyse des données de capteurs installés sur les équipements pour anticiper les pannes potentielles. En utilisant diverses fonctions de noyau avec les SVM, les chercheurs ont réussi à classer efficacement les données et à détecter les premiers signes de défaillance. Les résultats ont souligné que les SVM, grâce à leur aptitude à traiter des données complexes et multidimensionnelles, sont particulièrement performants pour prédire les pannes. Cette approche a permis d'améliorer la programmation des maintenances préventives et de réduire les coûts liés aux interruptions imprévues, renforçant ainsi l'efficacité et la fiabilité des équipements industriels.

2.4.2 Les techniques du DL

L'apprentissage profond (DL) est une sous-catégorie de l'apprentissage automatique (ML) qui se distingue par l'utilisation de réseaux de neurones artificiels complexes, inspirés du fonctionnement du cerveau humain. Ces réseaux, appelés réseaux de neurones profonds, sont capables de modéliser des relations non linéaires complexes dans les données et d'extraire des caractéristiques à différents niveaux d'abstraction. Dans le domaine de la maintenance prédictive, les techniques DL offrent des capacités avancées pour analyser des

volumes massifs de données et détecter des patterns subtils associés aux défaillances des équipements. Dans ce qui suit, nous allons aborder quelques-unes des techniques DL les plus pertinentes utilisées dans la maintenance prédictive.

2.4.2.1 Les Auto-Encodeurs

L'auto-encodeur (AE) [34] est une architecture de réseau de neurones utilisée en apprentissage non supervisé pour réduire la dimensionnalité des données tout en préservant leurs caractéristiques essentielles. Il se compose de deux composants principaux (voir la figure 2.5) : l'encodeur, qui transforme les données d'entrée en une représentation compressée dans un espace latent, et le décodeur, qui reconstruit les données originales à partir de cette représentation. L'objectif principal de l'AE est de minimiser l'erreur de reconstruction entre les données d'entrée et de sortie, ce qui permet d'extraire efficacement les motifs et les structures sous-jacents des données. En contexte de maintenance prédictive, les AE sont utilisés pour analyser les données de capteurs comme les vibrations ou la température, afin de détecter les signes avant-coureurs de défaillance des équipements industriels. Cette capacité à compresser les données tout en conservant les informations pertinentes en fait un outil précieux pour améliorer la fiabilité opérationnelle et optimiser les stratégies de PdM.

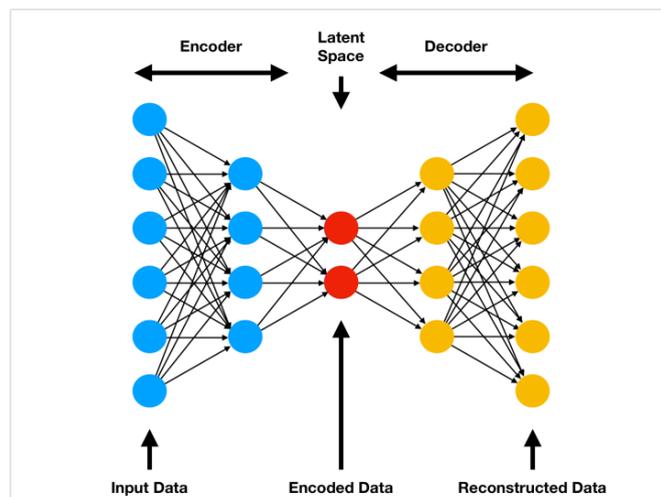


FIGURE 2.5 – Auto-Encodeur[8]

W. Yun et al(2021) [43] proposent une approche intéressante basée sur les AE en particulier les AE supervisés(SAE) pour la détection et le diagnostic des défauts dans les systèmes de chauffage, ventilation et climatisation (HVAC) des bâtiments. Utiliser les SAE permet de mieux détecter et diagnostiquer les défauts et les anomalies donc une fiabilité élevée pour la maintenance des systèmes HVAC. Cependant, cette approche dépend de données étiquetées pour l'apprentissage, ce qui peut limiter sa capacité à généraliser et à détecter des défauts qui n'ont pas été explicitement représentés dans les données d'apprentissage.

2.4.2.2 Les Transformers

Les transformers [19] sont des architectures de réseaux de neurones profonds qui utilisent un mécanisme d'auto-attention pour comprendre les relations contextuelles au sein

de données séquentielles. Contrairement aux réseaux neuronaux traditionnels, les transformers permettent à chaque élément de la séquence d'interagir avec tous les autres éléments, en attribuant des poids aux connexions entre eux. Ce mécanisme leur permet de capturer les dépendances à longue portée entre les éléments de la séquence, ce qui les rend particulièrement efficaces pour un large éventail de tâches, telles que le traitement du langage naturel, la vision par ordinateur et bien d'autres. L'architecture des transformers comme le montre la 2.6 est composée de blocs d'encodeurs et de décodeurs, qui fonctionnent en parallèle et traitent simultanément l'ensemble de la séquence d'entrée. Ces blocs utilisent des couches d'auto-attention multi-têtes pour extraire les caractéristiques importantes des données, ce qui permet aux transformers de gérer efficacement les dépendances à long terme et de faciliter le traitement parallèle. En PdM, les transformers peuvent analyser des séquences de données de capteurs pour identifier des schémas complexes et prédire des défaillances futures. Leur capacité à traiter simultanément l'ensemble de la séquence permet de gérer efficacement les grandes quantités de données générées par les équipements industriels, offrant ainsi des prédictions précises et en temps réel sur l'état des machines. Cette approche permet de planifier des interventions de maintenance proactives, réduisant ainsi les temps d'arrêt imprévus et optimisant les opérations industrielles.

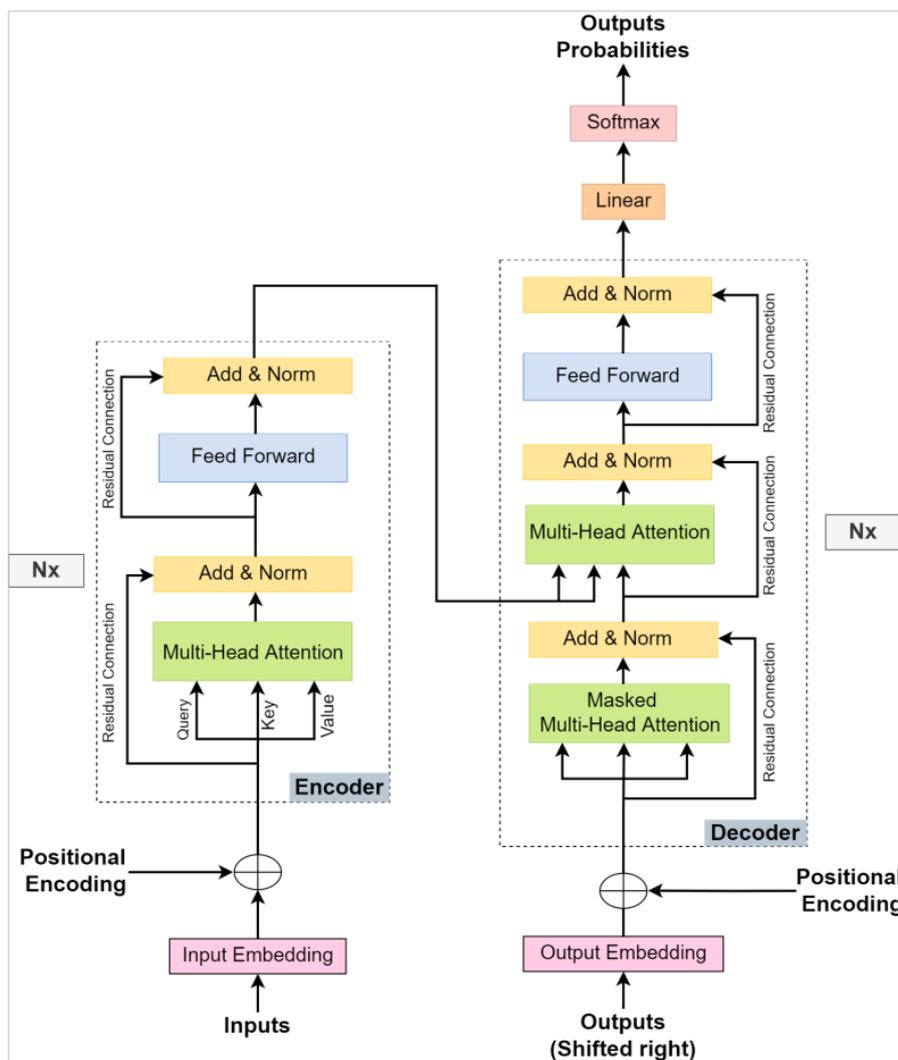


FIGURE 2.6 – L'architecture des transformers[19]

Tufano et al. (2023) [39] ont proposé d'utiliser des modèles de la famille des Transformers, notamment le modèle T5, dans le domaine de l'automatisation des tâches liées au code informatique. Ils ont étudié l'impact de la préformation sur la performance de ces modèles. Leur méthodologie a impliqué l'utilisation du modèle T5 pour mener des expériences de résumé de code et de complétion de code. Les résultats ont montré que la préformation des modèles était particulièrement bénéfique lorsque les ensembles de données de fine-tuning étaient de petite taille, conduisant à une amélioration significative des performances dans ces cas. De plus, ils ont observé que le choix des objectifs de préformation avait un impact majeur sur les performances des modèles, avec différentes combinaisons d'objectifs donnant des performances sensiblement différentes.

2.4.2.3 Réseaux de Neurones Convolutionnels (CNN)

Les réseaux de neurones convolutionnels (CNN) [25] sont des modèles de réseau neuronal profond utilisés principalement pour l'analyse d'images et de signaux. Inspirés par le fonctionnement du cortex visuel des animaux, ils sont conçus pour extraire automatiquement des caractéristiques significatives à partir de données complexes (voir la figure 2.7). Dans le domaine de la Maintenance Prédictive (PdM), les CNN sont appliqués pour analyser les données collectées par des capteurs IoT et IIoT sur les machines industrielles. En utilisant des filtres de convolution, les CNN identifient des motifs et des anomalies dans les données, permettant ainsi de prédire les pannes potentielles avant qu'elles ne surviennent. Cette capacité à détecter et à interpréter les signaux des équipements en temps réel contribue à améliorer la fiabilité opérationnelle en minimisant les interruptions non planifiées et en optimisant la gestion des ressources de maintenance.

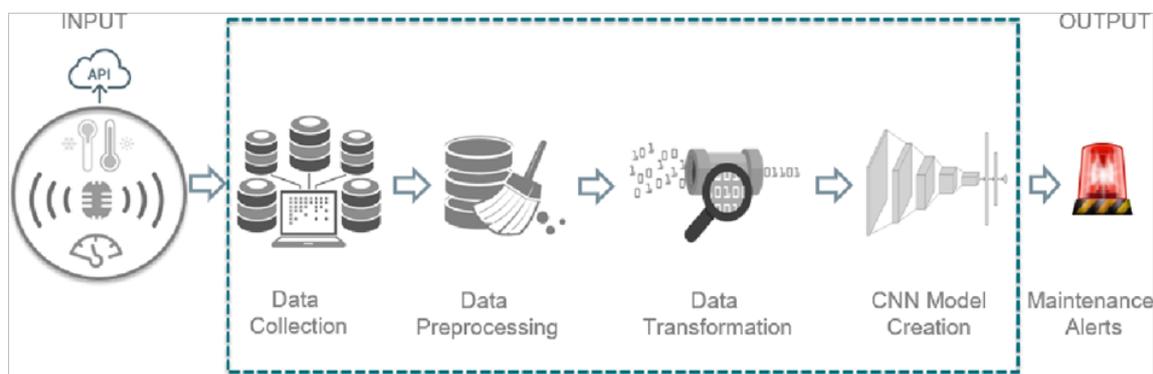


FIGURE 2.7 – CNN dans la PdM [36]

Par exemple, Silva (2019)[36] utilise les réseaux de neurones convolutionnels (CNN) dans le contexte de la maintenance prédictive des actifs. L'approche se base sur l'utilisation de capteurs pour mesurer des indicateurs de santé des actifs, détectant des anomalies comme une augmentation des vibrations d'un moteur ou une consommation d'énergie plus élevée, souvent précurseurs de défaillances. La méthodologie de Silva inclut la transformation de données unidimensionnelles en une représentation bidimensionnelle semblable à une image, suivie de l'application d'un classificateur optimisé. Les résultats obtenus montrent que le cadre CNN-PdM surpasse les techniques d'apprentissage automatique traditionnelles.

2.4.2.4 Les Réseaux de Neurones Récurrents (RNN)

Les Réseaux de Neurones Récurrents (RNN) [33] sont des modèles d'apprentissage automatique capables d'analyser des séquences de données en maintenant une mémoire des informations passées (Figure 2.8). Contrairement aux réseaux de neurones classiques, les RNN exploitent cette capacité de mémoire pour prendre en compte les dépendances temporelles et séquentielles dans les données. Dans le contexte de la PdM, les RNN sont utilisés pour modéliser et prédire les comportements des équipements au fil du temps. Grâce à leur capacité à détecter les changements subtils et les patterns inhabituels dans les données de capteurs, les RNN peuvent identifier les signes avant-coureurs d'anomalies ou de défaillances imminentes. Cette approche permet aux entreprises d'anticiper les pannes et d'effectuer des interventions de maintenance préventive, réduisant ainsi les coûts d'arrêts imprévus et améliorant la fiabilité des systèmes industriels.

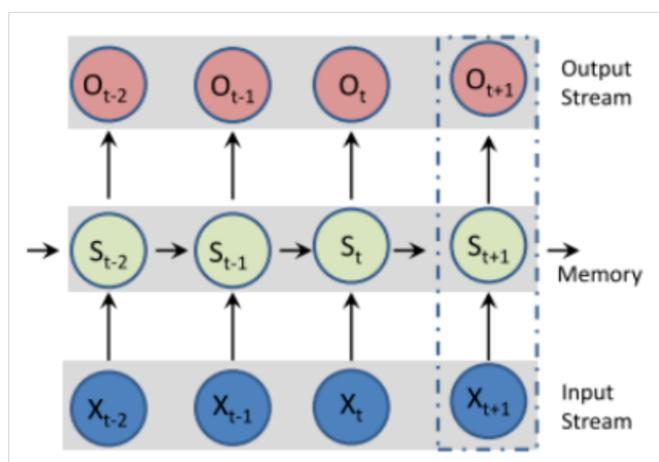


FIGURE 2.8 – Les Réseaux de Neurones Récurrents (RNN) [8]

Khan et Yairi (2018) [22] ont appliqué les RNN dans la gestion de la santé des systèmes industriels, leur but est d'explorer comment les RNN peuvent être utilisés pour améliorer la PdM et la fiabilité des équipements. La méthodologie employée consiste à appliquer diverses architectures de RNN sur des données analysées, collectées de capteurs sur les équipements industriels, pour modéliser les relations temporelles présentes dans ces données. Les résultats obtenus montrent que les RNN sont particulièrement efficaces pour capturer les dépendances temporelles complexes, permettant ainsi une détection précoce des anomalies et une prédiction précise des défaillances potentielles. Cette approche conduit à une amélioration significative de la fiabilité des équipements et à une réduction des temps d'arrêt non planifiés, optimisant ainsi l'efficacité opérationnelle globale.

2.4.2.5 Les Long Short-Term Memory (LSTM)

LSTM [37] sont un type avancé de RNN conçu pour surmonter les problèmes de gradient évanescent et explosif des RNN traditionnels. Grâce à leur mémoire (voir la figure 2.9) interne et leurs portes multiplicatives, les LSTM peuvent maintenir des dépendances temporelles à long terme, ce qui les rend particulièrement efficaces pour les applications de séquences temporelles. Dans le cadre de la maintenance prédictive (PDM), le LSTM est utilisé

pour analyser les données des capteurs des équipements industriels. Leur capacité à mémoriser de longues séquences d'informations pertinentes leur permet de détecter les signes avant-coureurs d'une défaillance imminente. En appliquant le LSTM, les tendances et les anomalies sur de longues périodes peuvent être identifiées, permettant une prévision précise des pannes. Cette approche augmente la fiabilité des équipements et réduit les temps d'arrêt imprévus, maximisant ainsi l'efficacité opérationnelle.

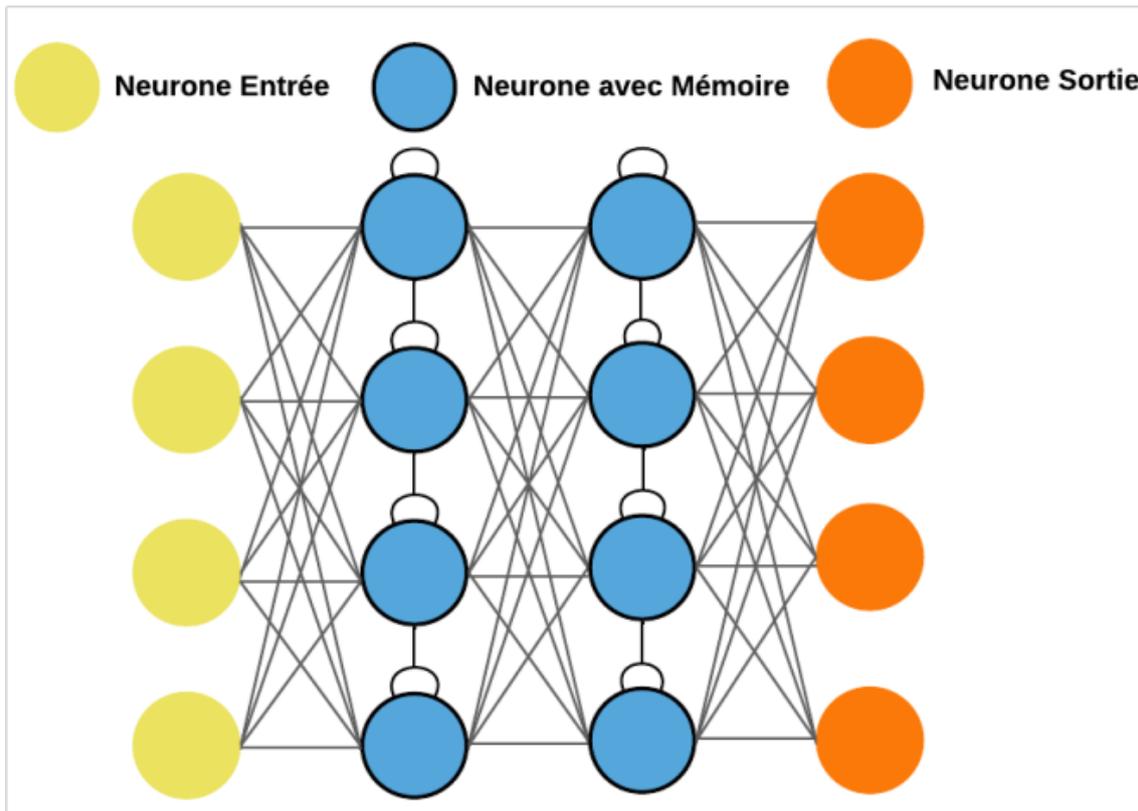


FIGURE 2.9 – LSTM [8]

Fabrizio De Vita et Dario Bruneo (2019) [14] appliquent les réseaux LSTM dans le domaine de la maintenance prédictive pour les industries intelligentes afin d'estimer la Durée de Vie Restante (RUL) des équipements. Leur méthodologie (2.10) implique l'entraînement de modèles LSTM sur des données historiques de capteurs provenant de machines, permettant ainsi de capturer les dépendances temporelles et de prédire les pannes potentielles avant qu'elles ne surviennent. En comparant les performances des LSTM avec des techniques traditionnelles d'apprentissage machine telles que les SVM et les DNN, ils démontrent que les LSTM sont supérieurs pour exploiter les données séquentielles afin d'estimer précisément la DVR. Leurs résultats révèlent que les réseaux LSTM atteignent une erreur quadratique moyenne racine (RMSE) et un pourcentage d'erreur significativement plus faibles par rapport aux autres modèles, mettant en évidence l'efficacité des LSTM pour améliorer l'efficacité de la maintenance et réduire les temps d'arrêt dans les applications industrielles. L'architecture du modèle LSTM utilisé dans leur étude est présentée dans la Figure 2.10, illustrant comment les différentes couches interagissent pour traiter les données séquentielles des capteurs.

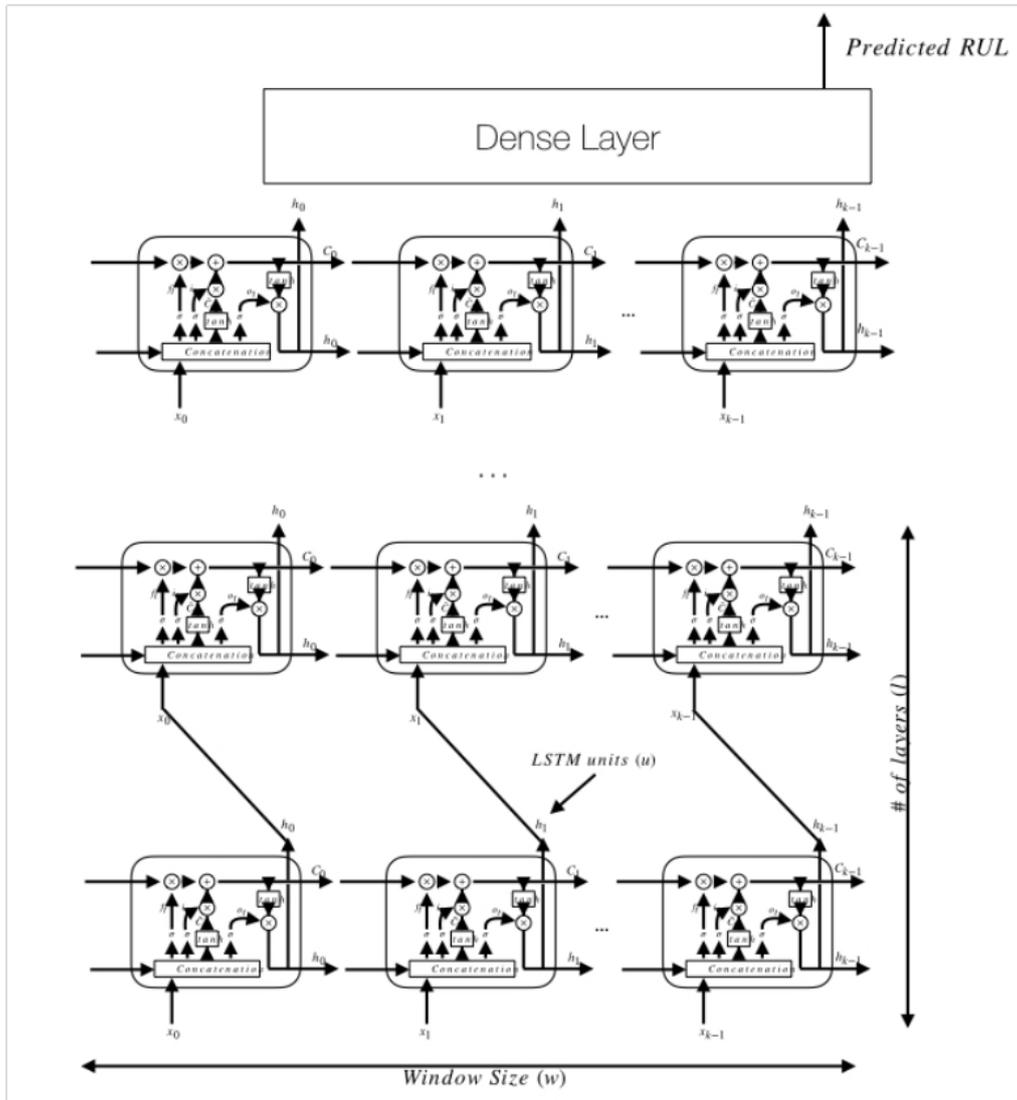


FIGURE 2.10 – Architecture du model proposé par [14]

2.4.2.6 Les unités récurrentes à portes (GRU)

Les unités récurrentes à portes (GRU) (voir figure 2.11) sont un type de réseau de neurones récurrents (RNN) conçu pour améliorer la capacité des RNN classiques à capturer des dépendances à long terme tout en étant moins complexe que les réseaux de mémoire à long court terme (LSTM). Introduites par Cho et al. en 2014 [], les GRU simplifient la structure de l'unité de LSTM en combinant les cellules d'entrée et de sortie en une seule cellule, et en fusionnant les portes d'entrée et d'oubli en une seule porte de mise à jour. Dans le contexte de la maintenance prédictive (PDM), les GRU sont utilisées pour analyser les données de capteurs provenant des équipements industriels. Leur capacité à gérer des séquences de données complexes et à capturer les dépendances temporelles les rend particulièrement efficaces pour prédire les pannes des machines avant qu'elles ne surviennent. Les GRU peuvent modéliser les comportements des équipements en tenant compte des variations temporelles des paramètres opérationnels tels que les vibrations, la température, et la pression, permettant ainsi une détection précoce des anomalies et une optimisation des

stratégies de maintenance.

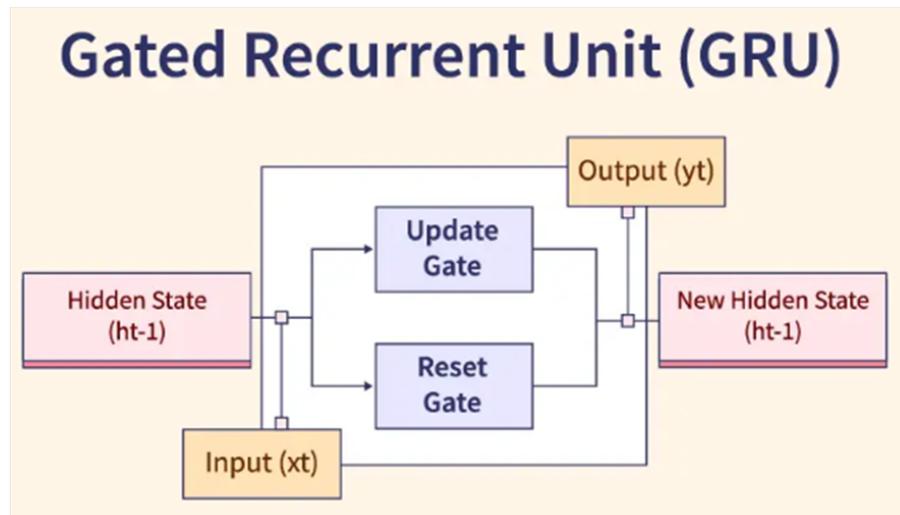


FIGURE 2.11 – Architecture de GRU

2.4.3 Techniques hybrides

Le terme "hybride" dans le contexte de l'intelligence artificielle fait référence à l'intégration de plusieurs techniques ou modèles pour combiner leurs forces et améliorer les performances globales. Dans le domaine de la maintenance prédictive (PDM), les approches hybrides combinent souvent différents types de modèles d'apprentissage automatique ou d'apprentissage profond pour exploiter leurs avantages respectifs. Ces synergies visent à optimiser la précision des prévisions tout en adaptant les modèles aux défis spécifiques des données industrielles. Dans les sections suivantes, nous examinons certaines études récentes qui adoptent des approches hybrides en maintenance prédictive.

2.4.3.1 Étude de D Kusumaningrum, et al. (2021)

Dwi Kusumaningrum, Nani Kurniati et Budi Santosa (2021) [24], dans leur recherche, utilisent à la fois les algorithmes SVM et Random Forest pour déterminer lequel est le plus efficace dans la construction d'un modèle de maintenance prédictive. Leur étude propose un modèle structuré en plusieurs phases critiques : l'acquisition des données, le prétraitement des données, la sélection des caractéristiques, la construction du modèle de classification et la validation (voir la figure 2.12).

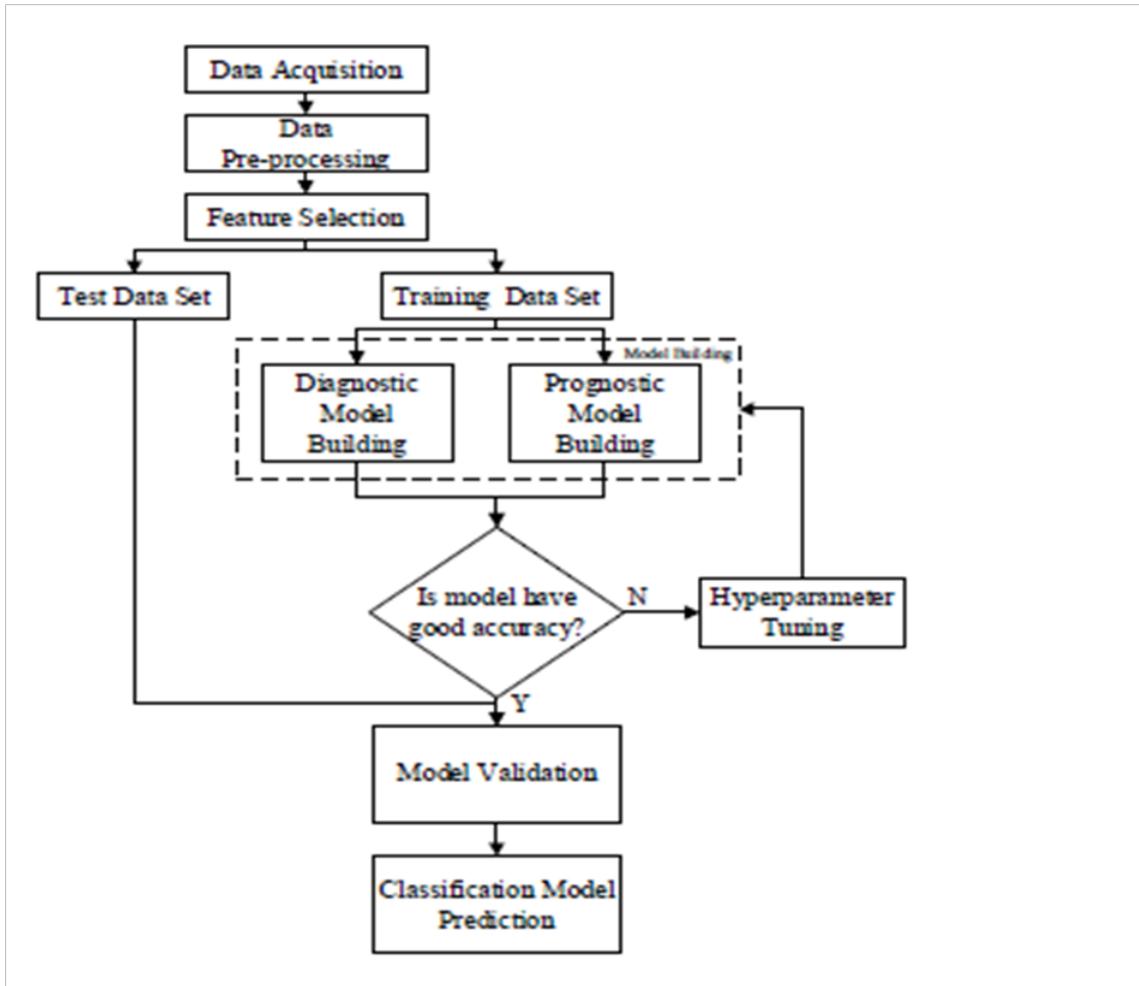


FIGURE 2.12 – L’architecture de la méthode proposée par [24]

Chaque algorithme a démontré une bonne précision pour les modèles diagnostiques et pronostiques. Cependant, la précision et le rappel les plus élevés ont été obtenus avec l’algorithme Random Forest (RF). Les résultats de la recherche montrent que le réglage des paramètres n’entraîne pas de différences significatives dans la précision du modèle, en particulier pour l’algorithme RF, que ce soit pour le pronostic ou le diagnostic.

2.4.3.2 Étude de Shoorkand et al. (2024)

Shoorkand et al. (2024) [35] ont développé une approche novatrice qui combine les réseaux de neurones convolutionnels (CNN) et les réseaux de neurones récurrents à mémoire à long terme (LSTM) dans le domaine complexe de la maintenance prédictive et de la planification de la production. L’objectif principal de leur étude est d’optimiser simultanément ces deux aspects critiques en tenant compte des limitations courantes des données prédictives industrielles. La méthodologie adoptée repose sur l’utilisation des CNN pour extraire efficacement les caractéristiques pertinentes à partir des données de production, tandis que les LSTM sont employés pour capturer les relations temporelles et séquentielles. Les résultats obtenus démontrent une amélioration significative des performances, marquée par une

réduction notable des coûts de maintenance et une augmentation substantielle de la disponibilité des systèmes de production.

2.4.3.3 Étude de Chia-Hung Yeh et al. (2019)

Chia-Hung Yeh et al. (2019) [42] proposent une méthode hybride combinant un réseau de neurones convolutionnels (CNN) et une machine à vecteurs de support (SVM) dans le contexte de la prédiction du temps de maintenance à long cycle des éoliennes. L'objectif de l'article est d'améliorer l'efficacité de la gestion des éoliennes en prédisant précisément leur temps de maintenance à partir de données opérationnelles, de données de temps de maintenance et de codes d'événement collectés auprès de 31 éoliennes sur une période de 941 jours consécutifs. Comme illustrer dans la figure 2.13 le modèle hybride utilise deux couches de CNN pour extraire des caractéristiques invariantes des données et les utilise comme entrée pour un SVM avec noyau RBF, assurant ainsi une classification précise (Figure2). Les résultats expérimentaux montrent que la précision de prédiction de leur méthode dépasse 70% pour les temps de maintenance à moins de 100 jours, ce qui pourrait considérablement améliorer la gestion des turbines éoliennes par les entreprises d'énergie.

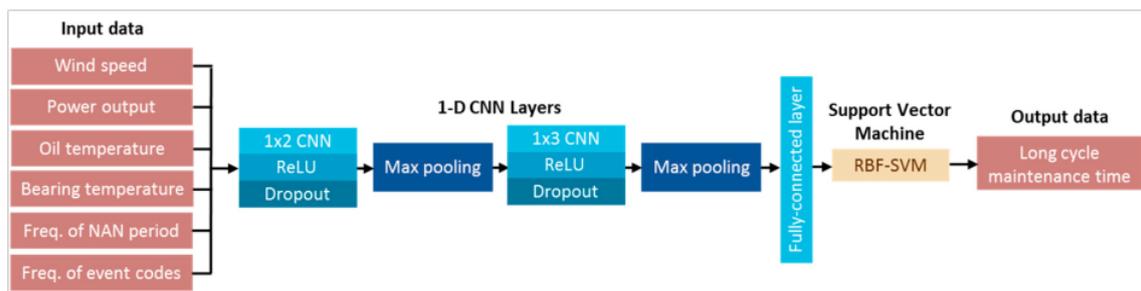


FIGURE 2.13 – L'architecture de la méthode proposée par [42]

2.4.3.4 Étude de Xanthi Bampoula et al. (2021)

Dans leur étude, Xanthi Bampoula et ses collègues [11] ont intégré les LSTM (Long Short-Term Memory) et les autoencodeurs de manière novatrice. Les LSTM ont été spécifiquement employés pour capturer et actualiser les informations sur des périodes temporelles étendues, ce qui permet une analyse fine des séquences complexes de données de production. Parallèlement, les autoencodeurs ont été utilisés pour leur capacité à comprimer et reconstruire les données, une technique essentielle pour détecter les anomalies en comparant les reconstructions avec les données d'entrée réelles. Ce choix stratégique des LSTM autoencodeurs s'est avéré crucial pour modéliser avec précision les comportements normaux et anormaux des équipements. Ainsi, leur approche a permis non seulement une détection précoce des défaillances, mais aussi une optimisation significative des opérations de maintenance dans les systèmes de production cyber-physiques.

2.5 Synthèse

La maintenance prédictive dans l'Industrie 4.0 repose sur l'intégration stratégique de technologies avancées pour optimiser la disponibilité et l'efficacité des équipements industriels. L'utilisation généralisée de l'Internet des objets (IoT) et de l'Internet industriel des objets (IIoT) permet la collecte en temps réel de données provenant de capteurs répartis

sur les machines, tandis que l'analyse du Big Data permet de détecter de manière proactive les pannes. L'intelligence artificielle (IA), y compris l'apprentissage automatique (ML) classiques et l'apprentissage profond (DL), joue un rôle essentiel dans la prévision des pannes à l'aide de modèles tels que les réseaux neuronaux récurrents (RNN) et LSTM, GRU améliorant ainsi la fiabilité opérationnelle dans l'industrie moderne et réduisant les imprévus. Environnements de temps d'arrêt. Pour exemplifier l'application variée des techniques de maintenance prédictive (PdM) dans l'industrie 4.0, plusieurs cas concrets ont été présentés précédemment, le tableau 2.1 synthétise ces exemples :

Technique	Article	Description	Limitation	Référence
Internet des Objets (IoT)	PNV Srinivasa Rao et al. (2024)	Utilisation de l'IIoT pour la maintenance des navires.	Nécessite des infrastructures IoT robustes	[8]
Internet Industriel des Objets (IIoT)	Qinglin Qi et Fei Tao (2018)	Utilisation du Big Data pour la maintenance dans le secteur ferroviaire.	Besoin de capacités de stockage importantes.	[9]
Big Data	Amruthnath et Gupta (2018)	Application de la régression linéaire pour la maintenance prédictive dans une usine de fabrication.	Limité aux relations linéaires entre variables.	[10]
Régression Linéaire	Amruthnath et Gupta (2018)	Application de la régression linéaire pour la maintenance prédictive dans une usine de fabrication.	Limité aux relations linéaires entre variables.	[11]
Forêts Aléatoires	Wescoat, Krugh et Mears (2021)	Utilisation des Random Forests pour la maintenance prédictive des cobots UR10.	Besoin d'un grand nombre d'échantillons d'entraînement	[15]
Machines à Vecteurs de Support (SVM)	Kuftinova et al. (2022)	Application des SVM pour la maintenance prédictive dans le secteur manufacturier.	Sensible aux données bruitées et non linéaires.	[16]
Auto-Encodeur (AE)	W. Yun et al. (2021)	Utilisation d'Auto-Encodeurs supervisés pour la maintenance des systèmes HVAC.	Dépendance aux données étiquetées.	[18]
Transformers	Tufano et al. (2023)	Application de modèles de Transformers pour l'automatisation des tâches de codage.	Complexité des architectures à gérer.	[20]

Réseaux de Neurones Convolutionnels (CNN)	Silva (2019)	Application des CNN pour la maintenance prédictive des équipements industriels.	Nécessite une étape de transformation des données.	[22]
Réseaux de Neurones Récurrents (RNN)	Khan et Yairi (2018)	Utilisation des RNN pour la gestion de la santé des systèmes industriels.	Problèmes de vanishing/exploding gradient.	[24]
Long Short-Term Memory (LSTM)	Fabrizio De Vita et Dario Bruneo (2019)	Application des LSTM pour l'estimation de la Durée de Vie Restante des équipements industriels.	Besoin d'un grand nombre de données séquentielles.	[26]
Unités Récurrentes à Portes (GRU)	Zhang et al. (2018)	Utilisation des GRU pour prédire la durée de vie restante des équipements industriels.	Peut être moins performante pour les séquences très longues par rapport aux LSTM.	[28]
CNN + LSTM	Shoorkand et al. (2024)	Combinaison de CNN pour l'extraction de caractéristiques et de LSTM pour la capture des relations temporelles.	Complexité des architectures à gérer	[29]
SVM + Random Forest	D Kusumaningrum et al. (2021)	Utilisation combinée de SVM et Random Forest pour améliorer la prédiction de maintenance.	Sensibilité aux paramètres et à la qualité des données	[30]
LSTM + Auto-encodeurs	Xanthi Bampoula et al. (2021)	Intégration de LSTM pour la modélisation temporelle et d'auto-encodeurs pour la détection d'anomalies.	Besoin de données annotées pour la formation	[31]
CNN + SVM	Chia-Hung Yeh et al. (2019)	Combinaison de CNN pour l'extraction de caractéristiques et de SVM pour la classification précise du temps de maintenance des éoliennes.	Nécessite une phase de transformation des données	[32]

TABLE 2.1: Récapitulatif des exemples d'applications des techniques de Maintenance Prédictive dans l'Industrie 4.0

2.6 Etude comparative des techniques de maintenance prédictive dans l'Industrie 4.0

Cette étude vise à comparer de manière approfondie les technologies étudiées, largement utilisées dans divers domaines industriels et technologiques. L'objectif principal est d'évaluer ces techniques selon des critères essentiels, en fournissant une analyse comparative rigoureuse. Nous utiliserons des notations standardisées pour évaluer chaque technique. Cette approche permettra de quantifier objectivement les performances de chaque technologie et de faciliter ainsi une compréhension claire de leurs avantages et limitations.

2.6.1 Définitions des Critères de Comparaison

Cette section établit les principaux critères utilisés pour évaluer les différentes technologies étudiées. Chaque critère a été sélectionné en fonction de sa pertinence et de sa capacité à quantifier la performance technologique de manière objective [8].

2.6.1.1 Exactitude (Accuracy)

Elle représente le rapport entre le nombre de prédictions correctes et le nombre total d'échantillons dans l'ensemble de données. Il s'agit d'une mesure fondamentale des performances du modèle, indiquant sa capacité à produire des résultats corrects par rapport aux données réelles.

- 1 : Très faible exactitude, les prédictions sont rarement correctes. [1%-20%]
- 2 : Faible exactitude, les prédictions sont souvent incorrectes. [20%-40%]
- 3 : Exactitude modérée, les prédictions sont généralement correctes mais avec quelques erreurs. [40%-60%]
- 4 : Bonne exactitude, les prédictions sont majoritairement précises avec peu d'erreurs. [60%-80%]
- 5 : Très haute exactitude, les prédictions sont extrêmement précises dans la plupart des cas. [80%-100%]

2.6.1.2 Temps d'Apprentissage (Learning Time)

C'est le temps nécessaire à l'algorithme pour apprendre des données fournies. Cela dépend de la complexité des données, de la taille de l'ensemble de données et de l'architecture de l'algorithme utilisé.

- 1 : Temps d'apprentissage long, nécessitant beaucoup de temps pour entraîner le modèle.
- 2 : Temps d'apprentissage moyen, prend un temps raisonnable pour entraîner le modèle.
- 3 : Temps d'apprentissage court, rapide pour entraîner le modèle.
- 4 : Temps d'apprentissage très court, le modèle s'entraîne très rapidement.

2.6.1.3 Temps de Prédiction (Prediction Time)

C'est le temps nécessaire à un modèle pour générer une prédiction ou une estimation basée sur les données d'entrée. Cela dépend de la taille des données, de la complexité du modèle et des ressources informatiques disponibles.

- 1 : Temps de prédiction élevé, les prédictions prennent beaucoup de temps à générer.
- 2 : Temps de prédiction moyen, les prédictions sont générées à un rythme acceptable.
- 3 : Temps de prédiction rapide, les prédictions sont générées rapidement.
- 4 : Temps de prédiction très rapide, les prédictions sont instantanées ou quasi-instantanées.

2.6.1.4 Flexibilité

Elle fait référence à sa capacité à s'adapter et à généraliser à différents types de données ou à des conditions variables sans nécessiter de modifications majeures de sa structure ou de ses paramètres.

- 1 : Faible flexibilité, le modèle est rigide et ne s'adapte pas bien à différentes données ou conditions.
- 2 : Flexibilité limitée, le modèle peut s'adapter à certains changements mineurs mais pas à tous.
- 3 : Bonne flexibilité, le modèle peut généraliser à différents types de données avec quelques ajustements mineurs.
- 4 : Très grande flexibilité, le modèle est extrêmement adaptable et peut fonctionner efficacement dans divers scénarios sans nécessiter de modifications majeures.

2.6.1.5 Facilité d'Interprétation

Elle se réfère à la compréhensibilité du modèle et à la clarté avec laquelle il est possible d'expliquer ses prédictions. Un modèle facile à interpréter permet de comprendre comment il prend des décisions et pourquoi il produit certaines prédictions.

- 1 : Difficile à interpréter, les décisions du modèle sont obscures et difficiles à expliquer.
- 2 : Moyennement interprétable, la logique du modèle peut être comprise avec une certaine difficulté.
- 3 : Facile à interpréter, les décisions du modèle sont claires et peuvent être expliquées avec facilité.
- 4 : Très facile à interpréter, les décisions du modèle sont transparentes et compréhensibles sans ambiguïté.

2.6.1.6 Utilisation des Ressources

L'utilisation des ressources englobe la quantité de mémoire et de puissance de calcul requise par un modèle pour l'entraînement et les prédictions. Cela inclut la taille de mémoire nécessaire pour stocker les paramètres du modèle et les exigences en termes de temps de calcul.

- 1 : Utilisation très élevée des ressources, nécessite une grande quantité de mémoire et de puissance de calcul.
- 2 : Utilisation élevée des ressources, nécessite une quantité significative de mémoire et de puissance de calcul.
- 3 : Utilisation modérée des ressources, nécessite une quantité raisonnable de mémoire et de puissance de calcul.
- 4 : Utilisation faible des ressources, nécessite une petite quantité de mémoire et de puissance de calcul.
- 5 : Utilisation minimale des ressources, nécessite très peu de mémoire et de puissance de calcul.

2.6.2 Tableau comparatif

Pour bien illustrer les évaluations des techniques étudiées, le tableau 2.2 compare de manière concise et efficace leurs performances selon les critères cités ci-dessus :

Techniques/Critères	IoT	IIoT	Big Data	Régression linéaire	Random Forest	SVM
IoT	4	3	2	4	3	3
IIoT	5	2	2	5	3	3
Big Data	5	4	3	4	2	4
Régression linéaire	4	3	2	4	3	3
Random Forest	5	2	2	5	3	3
SVM	5	4	3	4	2	4
Auto-Encodeurs	4	3	2	4	3	3
Transformers	5	2	2	5	3	3
CNN	5	4	3	4	2	4
RNN	4	3	2	4	3	3
LSTM	5	2	2	5	3	3
GRU	5	4	3	4	2	4
Hybride (CNN+LSTM)	4	3	2	4	3	3
SVM vs RF	5	4	3	4	2	4
Hybride (CNN+SVM)	5	2	2	5	3	3
Hybride (LSTM+AE)	5	4	3	4	2	4

TABLE 2.2 – Comparaison et évaluation des techniques de PdM dans l'industrie 4.0

À partir du tableau 2.2, nous agrégeons les scores attribués à chaque technique afin de calculer un classement représentatif (tableau 2.3). Ce processus permet d'identifier la technique la plus performante selon les critères établis :

Classement	Techniques	Score
1er	LSTM	25
2ème	Hybride (CNN+LSTM)	25
3ème	GRU	24
4ème	Hybride (LSTM+AE)	23
5ème	CNN	23
6ème	Hybride (CNN+SVM)	22
7ème	Transformers	22
8ème	Auto-Encodeurs	22
9ème	IoT	22
10ème	Big Data	21
11ème	RNN	20
12ème	IIoT	20
13ème	Random Forest	19
14ème	SVM vs RF	19
15ème	SVM	15
16ème	Régression linéaire	14

TABLE 2.3 – Classement des techniques de PdM dans l'industrie 4.0

Explication du classement :

LSTM (Long Short-Term Memory) et le modèle hybride (CNN + LSTM) occupent respectivement la première et la deuxième place avec un score de 25. Ces techniques se distinguent par leur capacité à combiner précision élevée (exactitude 5) avec un temps d'apprentissage court à moyen (temps d'apprentissage 4), un temps de prédiction rapide à moyen (temps de prédiction 3), une grande flexibilité (flexibilité 5), une facilité d'interprétation élevée (facilité d'interprétation 4), et une utilisation modérée des ressources (utilisation des ressources 4). LSTM excelle particulièrement dans la modélisation des séquences temporelles complexes, tandis que le modèle hybride bénéficie de la capacité de CNN à extraire des caractéristiques spatiales complexes combinées à la capacité de LSTM à gérer les dépendances temporelles à long terme.

GRU (Gated Recurrent Unit) se classe troisième avec un score de 24, juste derrière LSTM et le modèle hybride. Il offre une exactitude élevée (5) similaire à LSTM, mais peut avoir un temps de prédiction légèrement plus élevé (temps de prédiction 3). GRU est apprécié pour son temps d'apprentissage court (temps d'apprentissage 4) et une bonne flexibilité (flexibilité 5), bien que sa facilité d'interprétation (facilité d'interprétation 4) puisse être légèrement inférieure à celle de LSTM en raison de mécanismes internes moins complexes.

LSTM + Auto-Encodeurs et CNN se classent respectivement quatrième et cinquième avec un score de 23. LSTM combiné à des auto-encodeurs bénéficie d'une précision élevée et d'une bonne flexibilité, tandis que CNN excelle dans l'extraction de caractéristiques spatiales mais peut nécessiter plus de ressources pour la prédiction par rapport aux modèles récurrents.

Les modèles hybrides (CNN + SVM), Transformers, Auto-Encodeurs, IoT et Big Data occupent les places suivantes avec des scores de 22, montrant une performance solide mais légèrement inférieure en termes de précision, flexibilité ou facilité d'interprétation par rapport aux premiers du classement.

Les techniques RNN, IIoT, Random Forest, SVM vs Random Forest, SVM et Régression linéaire se trouvent plus bas dans le classement en raison de leur précision relativement inférieure, de leur flexibilité limitée ou de leur utilisation plus élevée des ressources, ce qui les rend moins adaptées pour les applications de maintenance prédictive dans des environnements complexes comme l'industrie 4.0.

2.7 Conclusion

À la lumière de cette étude comparative approfondie des techniques de maintenance prédictive dans l'industrie 4.0, il est clair que les modèles basés sur les réseaux neuronaux récurrents tels que LSTM, GRU, ainsi que les architectures hybrides comme LSTM combiné à des CNN, ont émergé comme des leaders incontestés. Leur capacité à gérer efficacement des données séquentielles complexes, en offrant à la fois une précision élevée et une flexibilité adaptative, répond parfaitement aux exigences variées et dynamiques des environnements industriels modernes. En parallèle, les modèles basés sur l'apprentissage profond, tels que les Transformers, commencent à se faire une place en raison de leur capacité à capturer efficacement les dépendances à long terme dans les séquences de données.

Les approches traditionnelles comme SVM, Random Forest et la régression linéaire, bien que toujours pertinentes, montrent des performances relativement inférieures dans des contextes de données dynamiques et complexes propres à l'industrie contemporaine.

Pour répondre à ces défis, notre étude propose une approche novatrice basée sur l'hybridation de LSTM et GRU pour la détection des anomalies. Ces modèles, détaillés dans le chapitre 3, visent à améliorer significativement la détection d'anomalies à partir de données collectées par des capteurs industriels. Cette hybridation stratégique vise également à optimiser la fiabilité opérationnelle, à réduire les coûts de maintenance imprévus, et à permettre une prise de décision plus proactive pour nos partenaires industriels. Cette initiative représente une avancée significative vers une maintenance prédictive plus efficace et adaptable, parfaitement alignée avec les besoins croissants de l'industrie 4.0 pour une production continue et optimisée.

Chapitre 3

Conception et réalisation d'un modèle de la Maintenance Predictive pour détecter les anomalies

3.1 Introduction

La prédiction des anomalies des machines dans une Entreprise est très importante pour éviter d'éventuels pannes et pouvoir faire les maintenances nécessaires sans que l'entreprise ne s'arrête. Les techniques avancées de réseaux de neurones sont les plus appropriés pour résoudre ce genre de problème. Nous avons exploité des architectures tels que Long Short-Term Memory (LSTM), Gated Recurrent Units (GRU) et Transformers pour apporter une solution à notre problème. Nous avons également proposé une architecture hybride, combinaison des modèles LSTM et GRU. Notre objectif est de déterminer la méthode la plus efficace pour détecter les anomalies, en exploitant les avantages spécifiques de chaque modèle et en optimisant leurs performances. Nous avons comparé les capacités de chaque architecture à capturer les dépendances temporelles et les patterns complexes dans les séquences de données générées par les machines.

3.2 Methodologie

Pour atteindre cet objectif, nous allons suivre le processus de développement d'un modèle prédictif. La figure 3.1 montre la méthode adoptée afin de développer et de tester un modèle de prédiction performant.

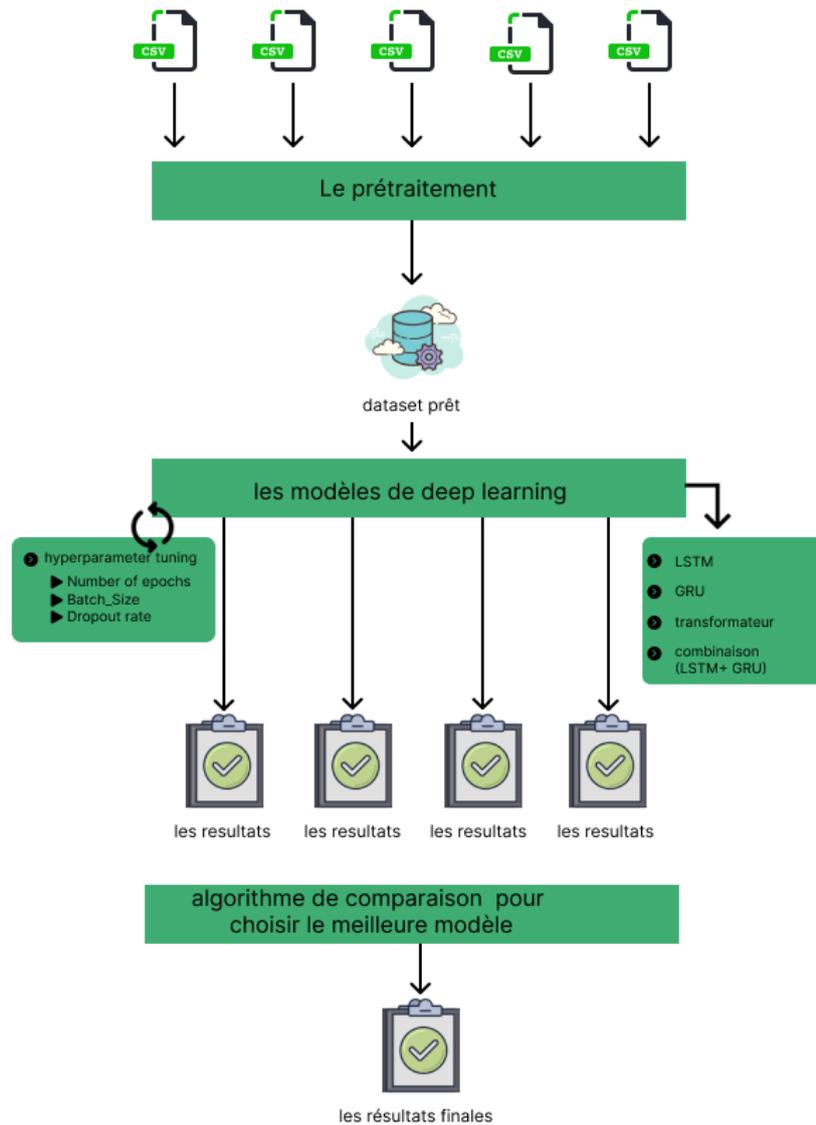


FIGURE 3.1 – La méthode adoptée

3.2.1 Collecte de données

Le dataset utilisé durant notre étude est « Microsoft Azure Predictive Maintenance » [12] qui contient différentes caractéristiques de 100 différentes machines de l'entreprise de Microsoft ce dataset dans sa première version se retrouve en 5 datasets :

- **PDM errors** : C'est ensemble de données représente les différentes informations sur les erreurs survenues sur chaque machine au cours d'une année. Il existe 5 types d'erreurs. Cependant, le jeu de données ne précise pas la nature exacte de chaque type d'erreur.
- **PDM Failures** : C'est un ensemble de données qui représente les différentes informations sur les pannes de chaque machine avec la date et le type de la panne
- **PDM Machine** : C'est un ensemble de données qui représente les différentes informations sur les machine comme le model et l'âge de chaque machine
- **PDM telemetry** : c'est l'ensemble de données capturées sur l'état de la machine (Machine ID, Voltage, Rotate, Pressure, Vibration) collecté chaque une heure pendant une année.
- **PDM main** : c'est l'ensemble des données collectées sur chaque maintenance effectuée pour chaque machine pendant une année.

3.2.1.1 Concaténation des différentes sources de données

Dans cette étape nous avons concaténé les 5 datasets (PDM errors, PDM Failures, PDM Machine, PDM telemetry, PDM main) pour obtenir un dataset prêt pour être prétraité. (Voir la figure 3.2)

```
#code de importation et concaténation
data1 = pd.read_csv('/kaggle/input/microsoft-azure-predictive-maintenance/PdM_errors.csv')
data2 = pd.read_csv('/kaggle/input/microsoft-azure-predictive-maintenance/PdM_telemetry.csv')
data3= pd.read_csv('/kaggle/input/microsoft-azure-predictive-maintenance/PdM_failures.csv')
data4= pd.read_csv('/kaggle/input/microsoft-azure-predictive-maintenance/PdM_machines.csv')
data5 = pd.read_csv ('/kaggle/input/microsoft-azure-predictive-maintenance/PdM_maint.csv')
output1 = pd.merge(data2, data1 ,on=['datetime','machineID'],how='left')#concaténation entre les fichiers 1 et 2
output2 = pd.merge(output1, data3 ,on=['datetime','machineID'],how='left')#concaténation entre le resultat et fichier 3
output3 = pd.merge(output2, data5 ,on=['datetime','machineID'],how='left')#concaténation entre le resultat et fichier 5
final_output = pd.merge(output3, data4 ,on='machineID',how='left') #concaténation entre le resultat et fichier 4
final_output = final_output.replace(np.nan, 0)# remplacer les cases vides par 0
final_output = final_output.groupby(['machineID','datetime']).max()# regrouper les données selon les colonnes spécifiées.
final_output=final_output.reset_index()#réinitialise l'index du DataFrame final_output

final_output
```

FIGURE 3.2 – importation et concaténation des dataset

Après avoir concaténé les différents fichiers, la figure 3.3 présentons la version finale de notre dataset

ieID	datetime	volt	rotate	pressure	vibration	error1	error2	error3	error4	error5	comp1_fail	comp2_fail	comp3_fail	comp4_fail	comp1_maint	comp2_maint	comp3_maint	comp4_maint	age	
1	2015-01-01 06:00:00	176.217853	418.504078	113.077935	45.087686	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18
1	2015-01-01 07:00:00	162.879223	402.747490	95.480525	43.413973	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18
1	2015-01-01 08:00:00	170.989902	527.349825	75.237905	34.178847	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18
1	2015-01-01 09:00:00	162.462833	346.149335	109.248561	41.122144	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18
1	2015-01-01 10:00:00	157.610021	435.376873	111.886648	25.990511	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18
...
100	2016-01-01 02:00:00	179.438162	395.222827	102.290715	50.771941	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5
100	2016-01-01	189.617555	446.207972	98.180607	35.123072	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5

FIGURE 3.3 – les différentes caractéristiques de dataset final

3.2.1.2 Description de dataset

Cet ensemble de données (Voir la figure 3.3) représente les informations relatives aux pannes survenues sur différentes machines sur une période d'un an. Composé de 876 100 lignes et 20 colonnes, ce jeu de données volumineux capture de manière détaillée les conditions de fonctionnement des machines ainsi que les pannes et les interventions de maintenance associées. Les données sont sensibles et confidentielles, et doivent être traitées avec soin pour protéger les informations relatives aux machines et à l'entreprise, voici la description de chaque caractéristique :

- **machineID** : Identifiant unique de chaque machine.
- **datetime** : Date et heure de l'enregistrement des données.
- **volt** : Tension mesurée (en volts) pour la machine à ce moment précis.
- **rotate** : Vitesse de rotation (en tours par minute) de la machine.
- **pressure** : Pression mesurée (en unités de pression) à ce moment précis.
- **vibration** : Niveau de vibration mesuré (en unités de vibration) pour la machine.
- **error1 à error5** : Indicateurs pour cinq types d'erreurs différents. Une valeur de 1 indique qu'une erreur spécifique s'est produite, tandis qu'une valeur de 0 indique l'absence de cette erreur.
- **comp1 fail à comp4 fail** : Indicateurs de défaillance pour quatre composants différents de la machine. Une valeur de 1 indique qu'une défaillance du composant s'est produite, tandis qu'une valeur de 0 indique l'absence de défaillance. (durant cette étude ces colonnes sont les classes à prédire)
- **comp1 maint à comp4 maint** : Indicateurs de maintenance pour quatre composants différents de la machine. Une valeur de 1 indique qu'une maintenance du composant a été effectuée, tandis qu'une valeur de 0 indique l'absence de maintenance.
- **age** : Âge de la machine (en années) au moment de l'enregistrement des données.

3.2.2 Prétraitement des données

Après la collecte et la concaténation de données, nous passons au prétraitement qui est effectué comme suit :

1. **Suppression des valeurs manquantes :** Lors de cette étape, nous avons utilisé l'outil RapidMiner [32] pour vérifier et pallier au problème de la présence de valeurs manquantes dans notre dataset concaténé.
2. **Encodage des caractéristiques catégorielles :** Dans cette étape, nous avons effectué un encodage pour les caractéristiques catégorielles en utilisant la technique « one-hot encoding » [21] pour convertir des variables catégorielles en une représentation binaire, où chaque catégorie unique de la variable est représentée par une nouvelle colonne. (Voir la figure 3.4)

```
# appliquer la technique 'One-hot encoding' pour maintenance csv
data5 = data5[data5['datetime'] >= '2015']
data5['comp1_maint']=0
data5['comp2_maint']=0
data5['comp3_maint']=0
data5['comp4_maint']=0
counter=0
for itera in data5.comp:
    if itera=="comp1":
        data5.at[counter, 'comp1_maint']=1
    elif itera=="comp2":
        data5.at[counter, 'comp2_maint']=1
    elif itera=="comp3":
        data5.at[counter, 'comp3_maint']=1
    elif itera=="comp4":
        data5.at[counter, 'comp4_maint']=1
    counter=counter+1
data5=data5.drop(columns=['comp'])
```

FIGURE 3.4 – Exemple d'Encodage des caractéristiques de dataset

3. Découpage de dataset :

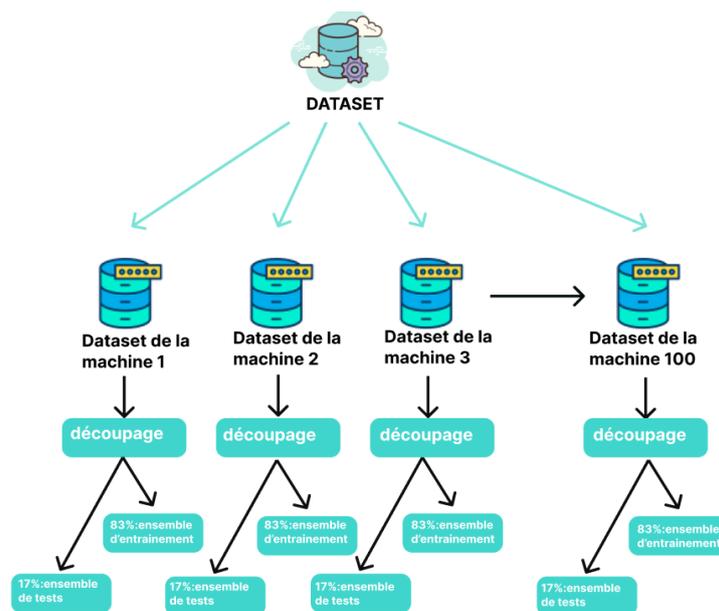


FIGURE 3.5 – méthode adopté pour le découpage

Étant donné que nos données sont séquentielles, nous avons découpé notre ensemble de données en segments spécifiques pour l'entraînement et le test. Chaque machine a 8760 lignes de données correspondant à des enregistrements horaires sur une année. Pour garantir une continuité temporelle et une représentativité de l'ensemble des données, nous avons utilisé les 10 premiers mois de données pour l'entraînement (305 jours) et les 2 derniers mois pour le test (60 jours). Cette approche permet de préserver l'ordre chronologique des données, ce qui est crucial pour les modèles de séquences tels que les modèles de mémoire à long terme (LSTM). En respectant l'ordre temporel, nous assurons que le modèle est testé sur des données qu'il n'a pas vues pendant l'entraînement, ce qui permet une évaluation plus réaliste de sa performance en conditions réelles. (Voir la figure 3.5)

4. Normalisation des caractéristiques :

Dans cette étape, nous utilisons le MinMaxScaler de la bibliothèque sklearn.preprocessing [29] pour normaliser les caractéristiques des capteurs de Voltage, Rotate, Pressure et Vibration de notre ensemble de données (Voir la figure 3.6). La normalisation consiste à transformer les valeurs de chaque caractéristique pour qu'elles se situent dans une plage spécifique généralement entre 0 et 1. Cela est essentiel pour s'assurer que toutes les caractéristiques contribuent de manière équitable à l'apprentissage du modèle, particulièrement pour les algorithmes sensibles à l'échelle des données tels que les réseaux de neurones.

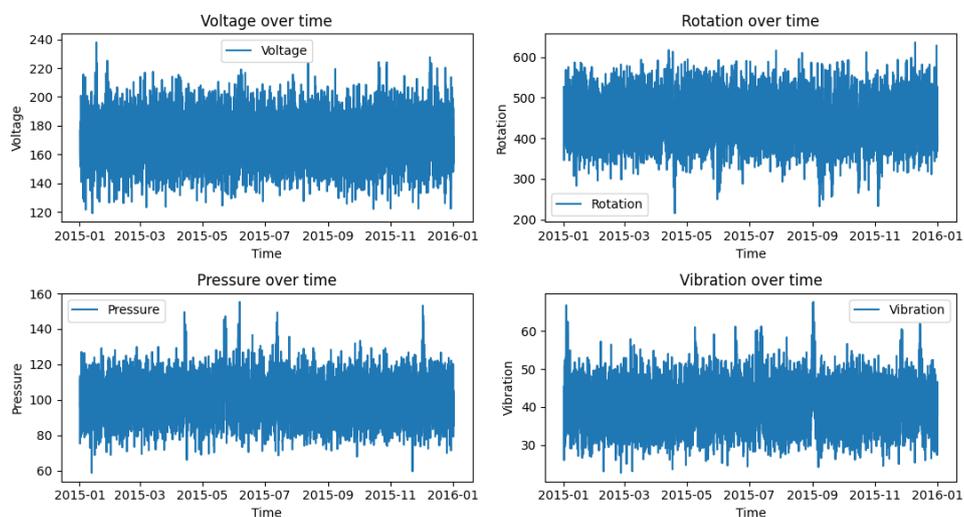


FIGURE 3.6 – les capteur

5. Fenêtrage des données séquentielles (Sliding Window) :

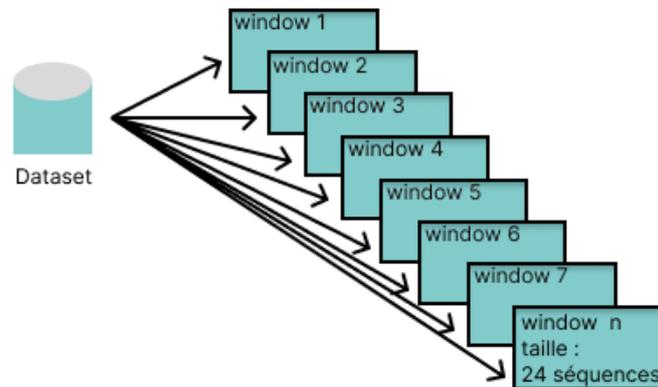


FIGURE 3.7 – le fenêtrage de dataset

Le Fenêtrage est une technique utilisée pour transformer des données séquentielles en un format qui peut être utilisé pour l'entraînement de modèles de machine learning. Le fenêtrage des données consiste à créer des séquences de données à partir des observations temporelles de chaque machine. Cette technique permet de capturer les dépendances temporelles entre les observations successives, ce qui est important pour les modèles de séries temporelles tels que les LSTMs. (Voir la figure 3.7)

a. **Préparation des Fenêtres de Données pour l'Entraînement :**

Le code parcourt les lignes de l'ensemble de données d'entraînement (`X_train_df`) et crée des fenêtres chevauchantes de longueur fixe (24 heures) pour chaque machine (`machineID`). Nous avons utilisé le chevauchement des fenêtres (Voir la figure 3.8) parce que c'est une technique puissante pour l'analyse de séries temporelles, en particulier pour la détection d'anomalies. Il permet de capturer des dépendances temporelles complexes, d'enrichir le jeu de données d'entraînement, et de réduire le risque de surapprentissage. Ces avantages sont cruciaux pour assurer une surveillance prédictive efficace et fiable dans les applications industrielles.

b. **Conversion en Matrices 2D :**

- Les fenêtres créées sont converties en matrices 2D afin de les rendre compatibles avec les modèles de machine learning.
- Les données sont ensuite transformées en Matrice pour une manipulation efficace .

c. **Création des Étiquettes de Fenêtres :**

- Le processus de fenêtrage est répété pour les étiquettes de défaillance (`comp1_fail`, `comp2_fail`, `comp3_fail`, `comp4_fail`), en veillant à ce que chaque fenêtre de données ait une étiquette correspondante.
- Les étiquettes sont assignées en fonction des fenêtres de 24 heures, en prenant le maximum des étiquettes de défaillance dans chaque fenêtre.
- Pour chaque fenêtre de 24 heures, nous identifions les occurrences des différentes pannes (`comp1_fail` à `comp4_fail`). Ces occurrences sont enregistrées sous forme d'étiquettes binaires (0 ou 1) indiquant si une panne particulière s'est pro-

duite au moins une fois dans la fenêtre.

- Pour chaque fenêtre de 24 heures, l'étiquette finale de défaillance est déterminée en prenant le maximum des étiquettes de défaillance observées dans cette période. Autrement dit, si une panne s'est produite à n'importe quel moment dans la fenêtre de 24 heures, l'étiquette pour cette fenêtre sera 1 pour cette panne. Cela permet de garantir que toute occurrence de panne est capturée dans l'analyse de cette période.

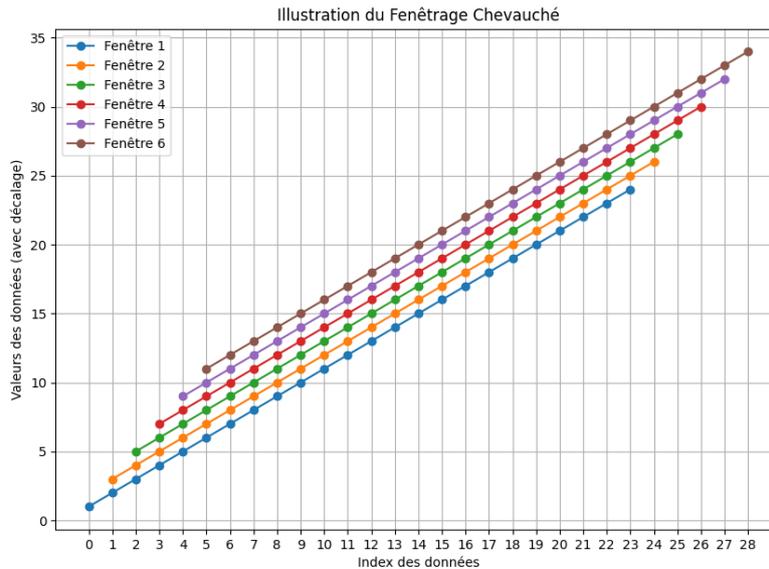


FIGURE 3.8 – Le fenêtrage chevauché

6. Problème de Déséquilibre des Données :

lors de notre étude nous avons rencontré un déséquilibre significatif dans les données. La majorité des enregistrements représentent un fonctionnement normal (classe 0), tandis que les cas de défaillance (classe 1) sont beaucoup plus rares. Ce déséquilibre peut poser des défis lors de la formation des modèles de Deep learning, car les algorithmes peuvent devenir biaisés vers la classe majoritaire, ce qui réduit leur capacité à détecter correctement les anomalies.

7. Utilisation de la Fonction max pour Augmenter la Classe 1 (les pannes) :

Pour atténuer le problème de déséquilibre, nous avons utilisé **une stratégie de fenêtrage avec chevauchement combinée à la fonction Max** pour étiqueter nos fenêtres de données. Voici une explication détaillée de cette approche : En créant des fenêtres glissantes de 24 observations, chaque fenêtre chevauche la précédente, nous avons ensuite étiqueté chaque fenêtre en utilisant la fonction **Max()**. Si une défaillance est présente dans une fenêtre, celle-ci est étiquetée comme contenant une défaillance. Cette méthode augmente la proportion de fenêtres étiquetées comme classe 1, contribuant à équilibrer les données et améliorant ainsi la capacité du modèle à détecter les anomalies. (Voir la figure 3.9)

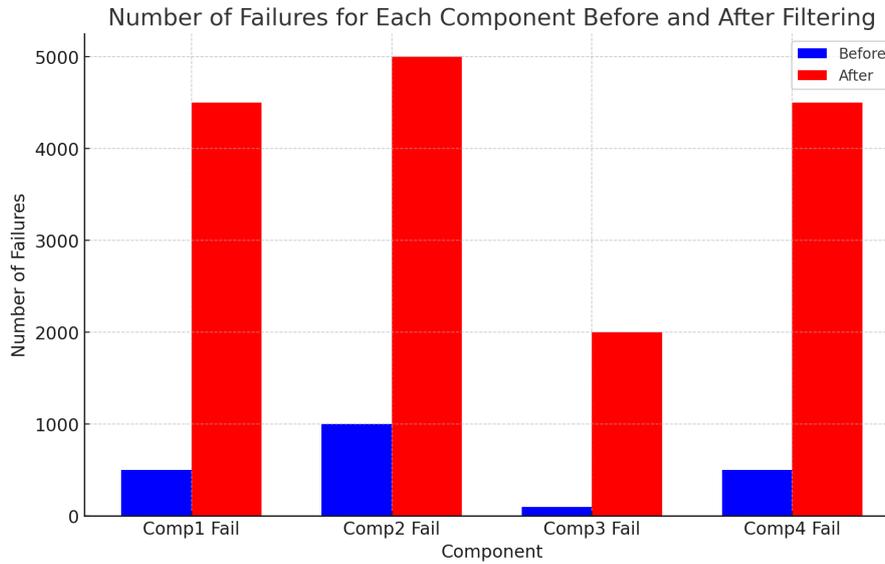


FIGURE 3.9 – Nombre de classe 1 (les pannes) avant et après fenêtrage

3.2.3 Les métriques :

Afin de pouvoir Évaluer nos modèles des métriques sont nécessaires. Le tableau (TABLE 3.1), nous présenterons les plus utilisées dans les classification dans la maintenance prédictive.

La métrique	La description
Accuracy	$\frac{VP+VN}{VP+VN+FP+FN}$
Précision	$\frac{VP}{VP+FP}$
F1-Score	$\frac{2 \cdot \text{Précision} \cdot \text{Rappel}}{\text{Précision} + \text{Rappel}}$
Rappel	$\frac{VP}{VP+FN}$
Courbe ROC	La courbe ROC évalue la performance des modèles de classification en représentant le taux de vrais positifs par rapport au taux de faux positifs pour différents seuils de classification.
AUC	$\int_0^1 TPR(fpr) d(fpr)$

TABLE 3.1 – Descriptions des métriques de classification

3.2.4 Modèles utilisés et proposés

Nous allons pour chaque modèle LSTM, GRU, Transformers et le modèle Hybride, définir l'architecture, l'algorithme et les résultats de prédictions obtenues après entraînement et test. (Voir la figure 3.10)

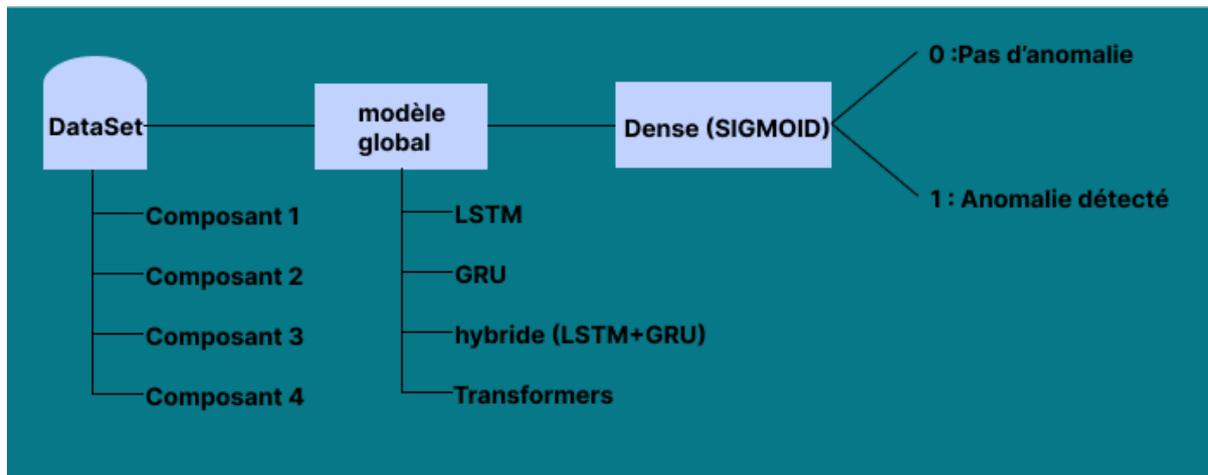


FIGURE 3.10 – L'architecture générale :

3.2.4.1 Classification Binaire pour chaque Composant

Au lieu de faire une prédiction multi class pour indiquer quel composant pourrait échouer, nous avons choisi une classification binaire. Chaque composant (comp1, comp2, comp3, comp4) a son propre modèle de classification binaire. Cela signifie que, pour chaque fenêtre de données, nous effectuons quatre prédictions binaires séparées, une pour chaque composant, indiquant si ce composant va échouer (1) ou non (0).

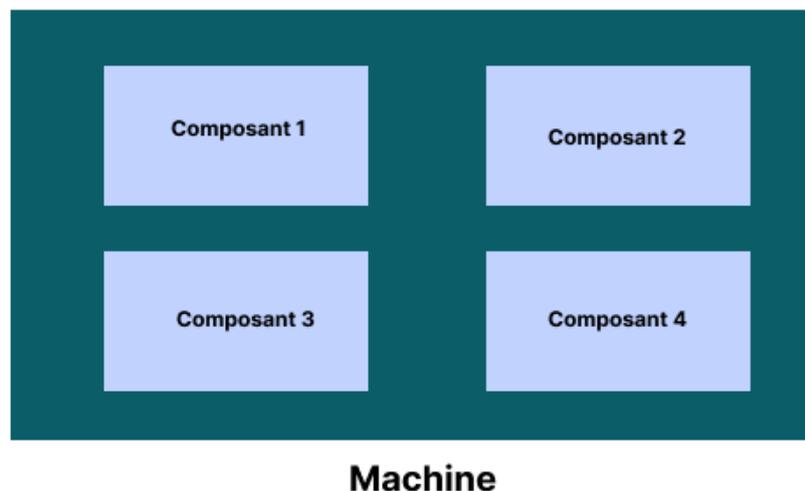


FIGURE 3.11 – l'architecture de la machine étudiée

3.2.4.2 Modèle de maintenance prédictive LSTM (Long Short-Term Memory)

Les LSTM sont une variante des réseaux de neurones récurrents (RNN) qui sont capables de modéliser des séquences temporelles avec des dépendances à long terme. Ils sont particulièrement adaptés aux données séquentielles. (Voir la figure 3.12)

— **Architecture du modèle :**

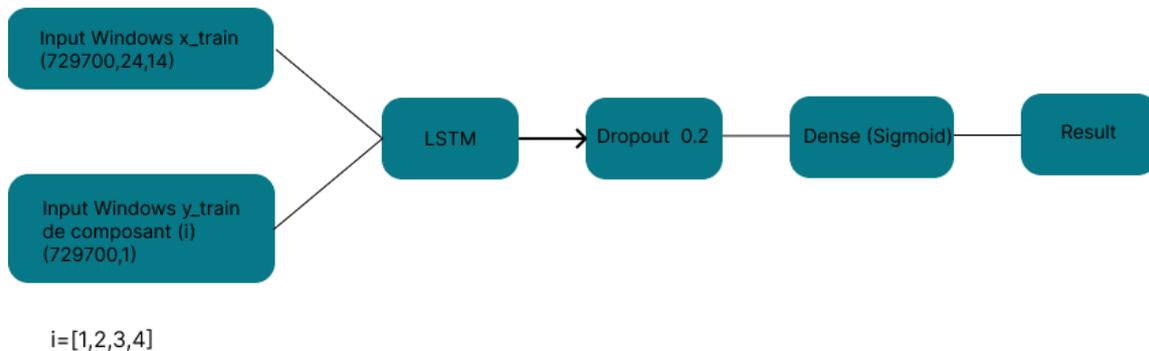


FIGURE 3.12 – l'architecture détaillée du model de LSTM

— **Algorithme :**

l'algorithme suivant résume les différentes étapes suivies pour la résolution de notre problème.

1. **Préparation des données :**

- Les données séquentielles sont découpées en fenêtres glissantes de taille fixe (par exemple, 24 heures) afin de capturer les dépendances temporelles.
- Les données sont normalisées pour s'assurer que chaque caractéristique contribue de manière égale à l'apprentissage.

2. **Architecture du modèle :**

- L'architecture LSTM est définie avec une seule couche de LSTM et de Dropout pour éviter le surapprentissage.
- La dernière couche de LSTM est connectée à une couche dense avec une activation sigmoïde pour produire des prédictions binaires (0 ou 1).

3. **Compilation du modèle :**

- Le modèle est compilé avec une fonction de perte binaire (binary cross-entropy) et un optimiseur (Adam).

4. **Entraînement :**

- Le modèle est entraîné sur les données d'entraînement avec un certain nombre d'époques et une taille de batch définie.

5. **Tests et évaluation :**

- Après l'entraînement des modèles, nous avons procédé à la phase de test pour évaluer la performance du modèle sur des données non vues auparavant. Cette phase est cruciale pour comprendre comment le modèle généralise à de nouvelles données et pour s'assurer qu'il n'y a pas de surapprentissage (overfitting). (Voir la figure 3.13)

```

predicted_lstm = model_lstm.predict(np.array(window_test_x))
y_pred_comp1_lstm= predicted_lstm[0].flatten()
y_pred_comp2_lstm = predicted_lstm[1].flatten()
y_pred_comp3_lstm= predicted_lstm[2].flatten()
y_pred_comp4_lstm= predicted_lstm[3].flatten()
y_pred_classes_comp1_lstm= np.array(list(map(lambda x: 0 if x<0.5 else 1, y_pred_comp1_lstm)))
y_pred_classes_comp2_lstm= np.array(list(map(lambda x: 0 if x<0.5 else 1, y_pred_comp2_lstm)))
y_pred_classes_comp3_lstm= np.array(list(map(lambda x: 0 if x<0.5 else 1, y_pred_comp3_lstm)))
y_pred_classes_comp4_lstm= np.array(list(map(lambda x: 0 if x<0.5 else 1, y_pred_comp4_lstm)))

```

FIGURE 3.13 – aperçu sur le code l’étape des tests

— les performances de model LSTM pour chaque composant :

Model	Composant	Accuracy	Precision	Recall	F1-Score	AUC
LSTM	Composant 1	0.9976	0.8208	0.6528	0.7272	0.826
LSTM	Composant 2	0.9972	0.8632	0.7471	0.8010	0.8731
LSTM	Composant 3	0.9989	0.9047	0.7476	0.8187	0.8737
LSTM	Composant 4	0.9989	0.9323	0.7885	0.8544	0.8941

TABLE 3.2 – Performances du modèle LSTM

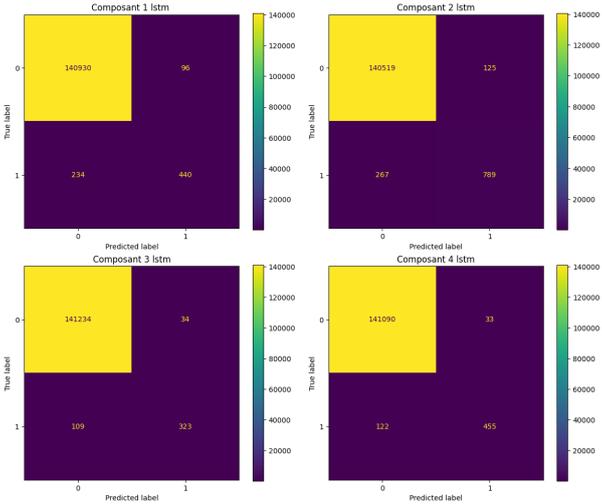


FIGURE 3.14 – Matrice de confusion de LSTM

— Analyse de la matrice de confusion :

Étant donné que nous traitons des données séquentielles, la matrice de confusion interprète nos résultats comme s’il s’agissait d’un jeu de données déséquilibré. Cela signifie que les classes de défaillances des composants sont beaucoup moins fréquentes que les classes de non-défaillances, ce qui peut fausser les évaluations de performance du modèle. Pour pallier à ce problème et obtenir une évaluation plus précise, nous avons utilisé d’autres métriques telles que la précision (Precision), le rappel (Recall), le score F1 (F1-Score) et l’aire sous la courbe ROC (AUC). Ces métriques nous permettent de mieux comprendre la capacité du modèle à prédire les défaillances des composants en tenant compte de l’équilibre entre les classes positives et négatives .(Voir la figure 3.14)

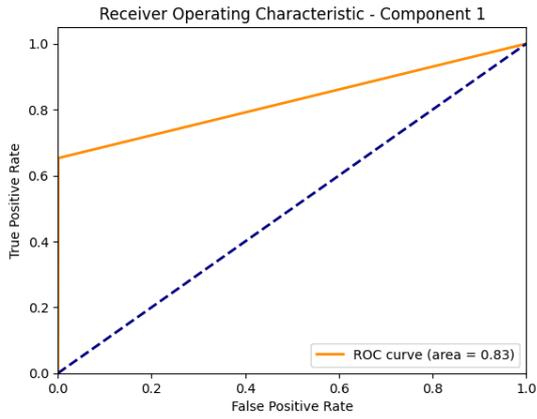


FIGURE 3.15 – la courbe ROC de composant 1

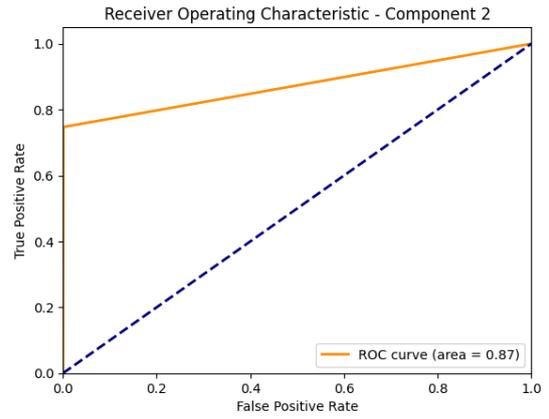


FIGURE 3.16 – la courbe ROC de composant 2

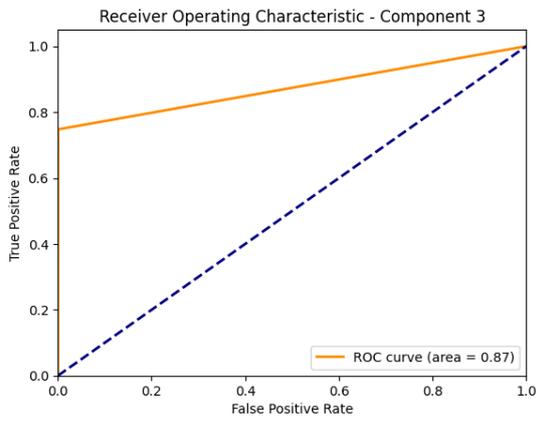


FIGURE 3.17 – la courbe ROC de composant 3

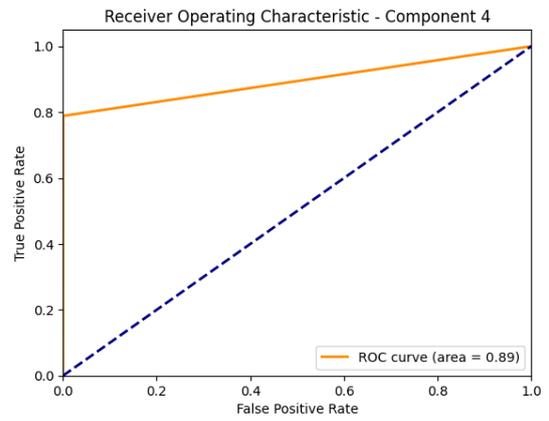


FIGURE 3.18 – la courbe ROC de composant 4

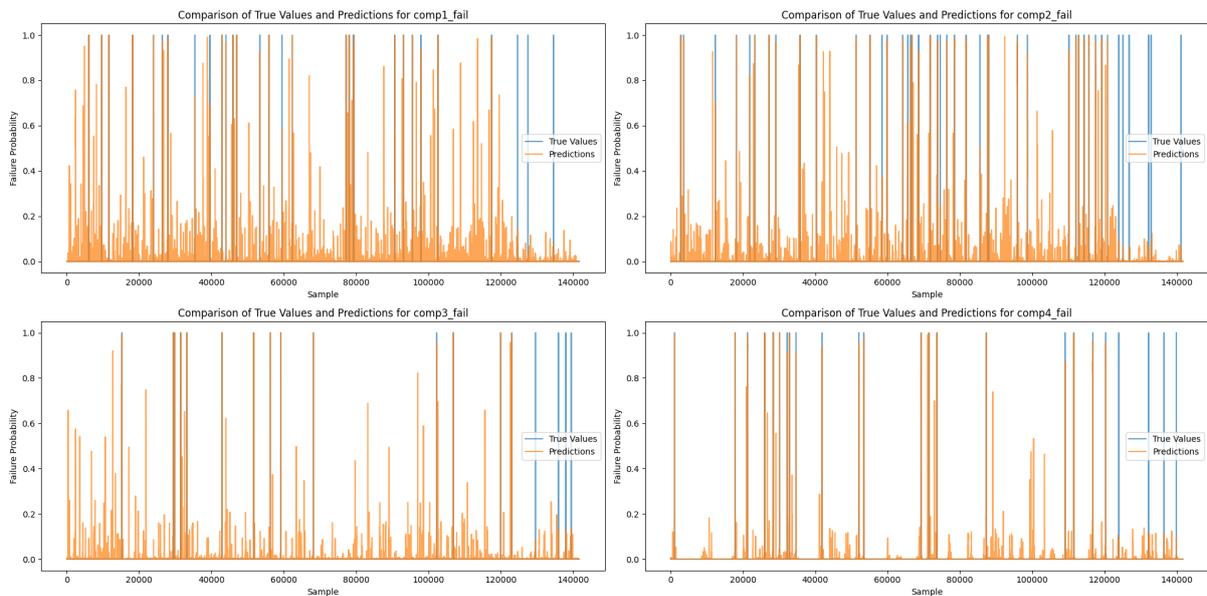


FIGURE 3.19 – comparaison entre les vraies valeurs et les valeurs prédites

— **Interprétation des résultats :**

- Le modèle LSTM avec ajustement des hyperparamètres montre une très haute précision pour tous les composants.
- La sensibilité (recall) varie légèrement, étant généralement bonne mais plus faible pour le composant 1.
- Les scores F1 et AUC montrent une performance robuste, avec le composant 4 obtenant les meilleurs résultats globaux.
- L'amélioration de la sensibilité pour le composant 1 pourrait être envisagée pour équilibrer davantage les performances du modèle.
- Les résultats montrent que les modèles de LSTM fonctionnent bien sur presque les 80 premières machines dans la plupart des composants (Voir la figure 3.19) . Cela est probablement dû au nombre d'époques qui été limité à 5, et que nous n'avons pas de matériel pour effectuer plus d'entraînements.
- Pour déterminer si le nombre d'époques influence les performances de mon modèle, j'ai effectué une exécution avec 12 époques afin de comparer les résultats avec ceux obtenus en 6 époques.

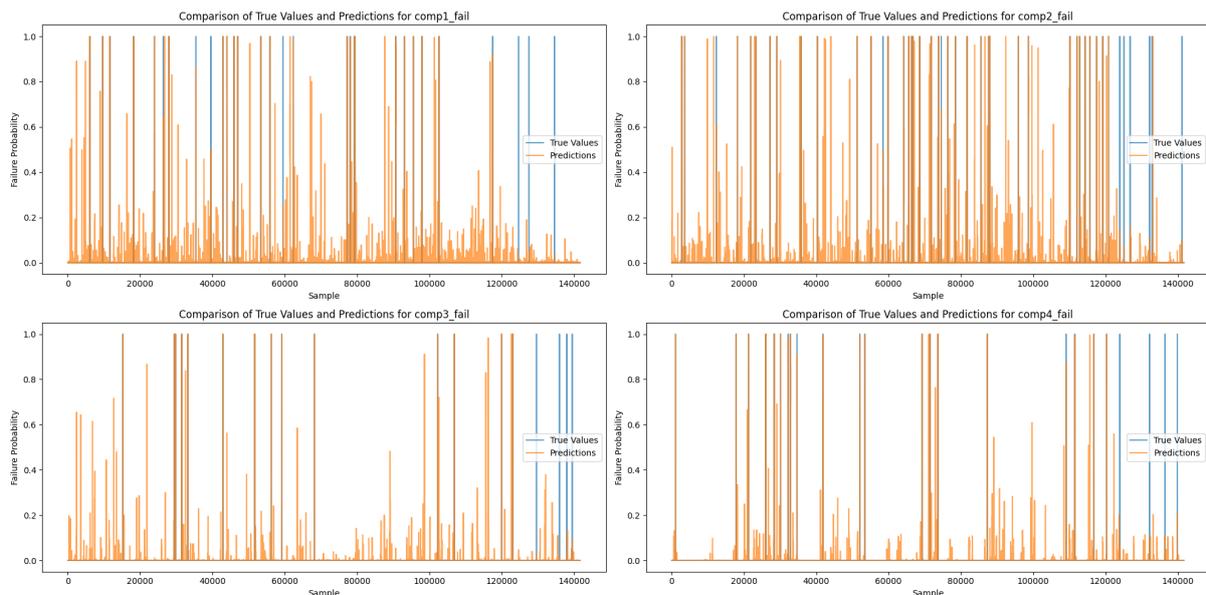


FIGURE 3.20 – les résultat de LSTM avec 12 époques

— **Résumé des Observations :**

Les graphiques montrent que les prédictions des modèles LSTM varient en fonction du nombre d'époques d'entraînement. Par exemple, dans la classification des anomalies du composant 1 avec le modèle LSTM entraîné pendant 12 époques, nous avons remarqué que ce modèle a réussi à détecter une des anomalies des dernières machines. Les observations détaillées pour chaque composant permettront de déterminer si un entraînement plus long (12 époques) est significativement meilleur qu'un entraînement plus court (6 époques) pour prédire les défaillances des composants de la machine. (Voir la figure 3.20)

— **Conclusion :**

En conclusion, les LSTM s'avèrent être une méthode fiable et performante pour la détection d'anomalies, et l'amélioration par le tuning des hyperparamètres renforce en-

core leur efficacité. Ces résultats prometteurs suggèrent une application potentielle à grande échelle pour la surveillance et la maintenance prédictive des systèmes complexes.

3.2.4.3 Modèle de maintenance prédictive GRU (Gated Recurrent Unit)

Les GRU sont conçus pour capturer les dépendances à long terme dans les données séquentielles, grâce à une architecture plus simple et plus rapide que les LSTM (Long Short-Term Memory), tout en maintenant une performance similaire.

— Architecture du modèle :

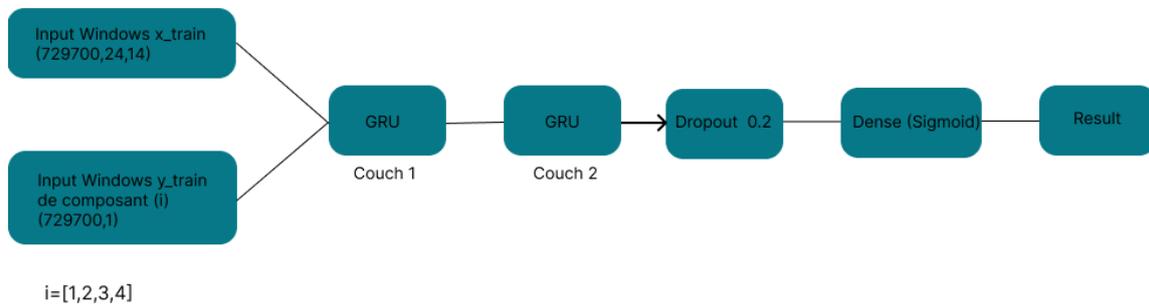


FIGURE 3.21 – l’architecture détaillée du model de GRU

— l’algorithme

Nous avons utilisé un modèle de maintenance prédictive basé sur les GRU (Gated Recurrent Unit), qui partage le même principe fondamental que les LSTM mais utilise des GRU pour optimiser le traitement des séquences de données. Dans cette implémentation spécifique, nous avons intégré deux couches de GRU pour renforcer la capacité du modèle à capturer les motifs temporels complexes des données. (Voir la figure 3.21)

— les performances de model GRU pour chaque composant :

Model	Composant	Accuracy	Precision	Recall	F1-Score	AUC
GRU	Composant 1	0.9976	0.8725	0.5994	0.7106	0.7994
GRU	Composant 2	0.9972	0.8676	0.7509	0.8050	0.8750
GRU	Composant 3	0.9990	0.8924	0.7685	0.8258	0.8841
GRU	Composant 4	0.9986	0.8726	0.7954	0.8322	0.8975

TABLE 3.3 – Performances du modèle GRU

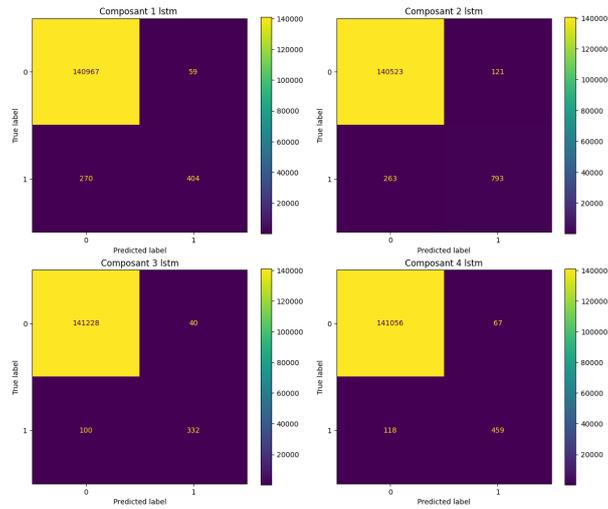


FIGURE 3.22 – matrice de confusion de GRU

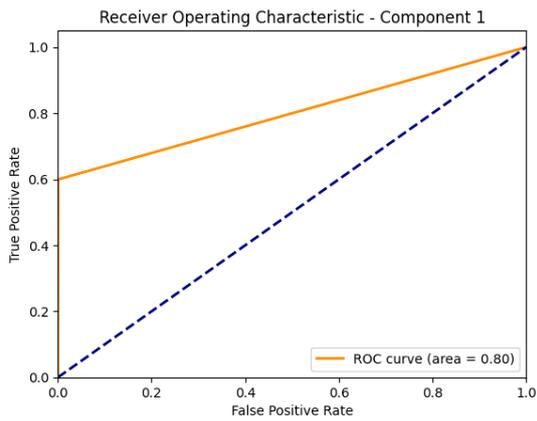


FIGURE 3.23 – la courbe ROC de composant 1

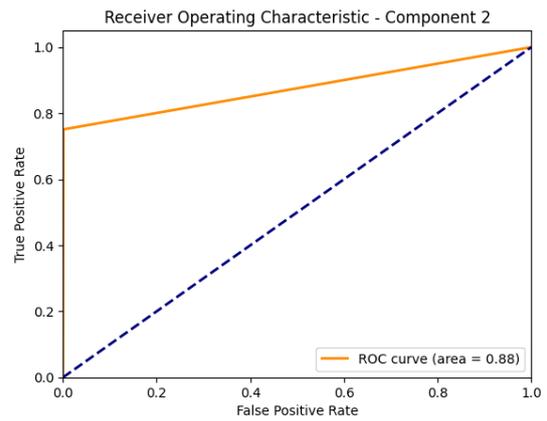


FIGURE 3.24 – la courbe ROC de composant 2

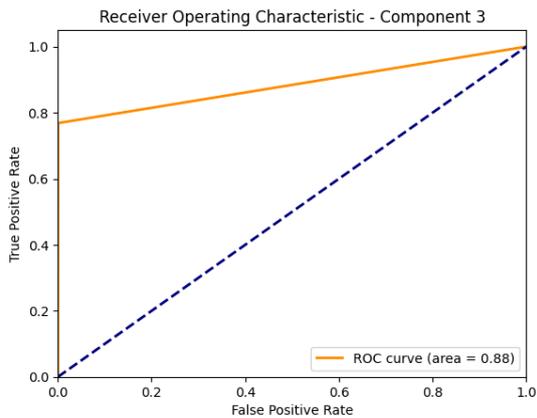


FIGURE 3.25 – la courbe ROC de composant 3

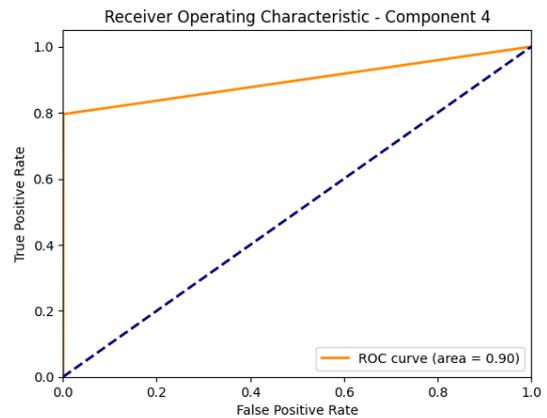


FIGURE 3.26 – la courbe ROC de composant 4

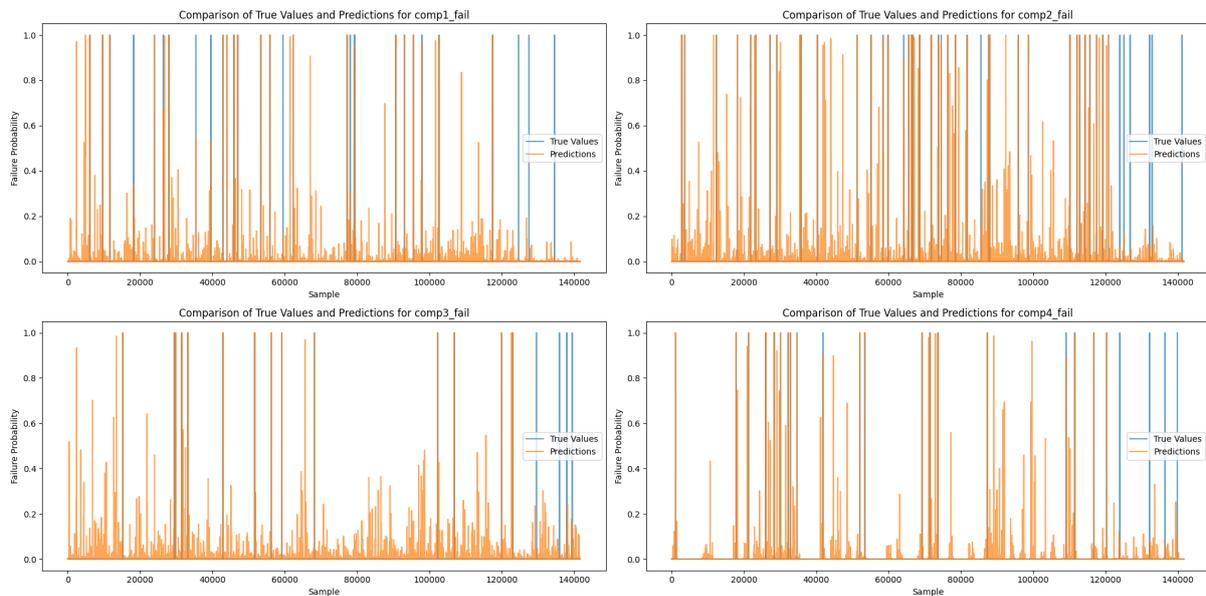


FIGURE 3.27 – comparaison entre les vraies valeurs et les valeurs prédites

— **Interprétation des résultats :**

les composants 2, 3 et 4 ont des performances globalement très bonnes avec un bon équilibre entre précision et rappel, et un AUC élevé, ce qui indique une forte capacité de distinction entre les classes. Donc il y a pas une grande différence entre les GRU et LSTM en terme de performances. Notre modèle de GRU a toujours une difficulté de détecter les anomalies des dernières machines (Voir la figure 3.27)

— **Conclusion :**

Les modèles GRU pour les quatre composants montrent une excellente performance globale avec des valeurs élevées de précision et de rappel. Les modèles pour les composants 2, 3 et 4 ont un bon équilibre entre précision et rappel, et des AUC élevés, ce qui indique une forte capacité à distinguer entre les classes. Le modèle pour le composant 1 a une haute précision mais un recall plus faible, ce qui suggère qu'il pourrait manquer certains vrais positifs. Des améliorations peuvent être apportées pour augmenter le recall du composant 1.

3.2.4.4 Modèle de maintenance prédictive transformers :

— **Architecture du modèle :**

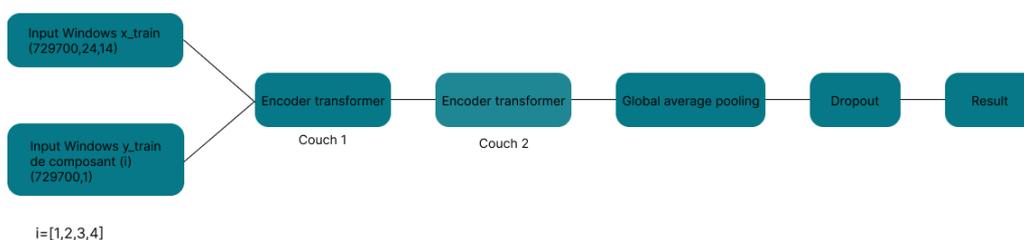


FIGURE 3.28 – l'architecture détaillée du model proposé

— **l’algorithme :**

1. **Préparation des données :**

Nous avons utilisé la même préparation des données des modèle précédents

2. **Définition du Bloc de Transformateur** Un bloc de transformateur est défini par une fonction appelée ‘transformer’_encoder’. Ce bloc comprend deux parties principales :

- Normalisation et Attention Multi-Têtes : Les données d’entrée sont d’abord normalisées, puis une couche d’attention multi-têtes est appliquée. Cette couche permet au modèle de se concentrer sur différentes parties des entrées pour chaque tête d’attention. Après l’attention, une couche de dropout est appliquée pour réduire le surapprentissage, suivie d’une connexion résiduelle qui ajoute les entrées initiales à la sortie de la couche d’attention.

- Partie Feed Forward : Les données passent ensuite par une autre couche de normalisation et deux couches entièrement connectées avec une fonction d’activation ReLU pour introduire la non-linéarité. Une autre couche de dropout est appliquée entre les deux couches denses, et une connexion résiduelle est ajoutée à la fin .(Voir la figure 3.28)

3. **Définition des Entrées**

Les données d’entrée du modèle sont définies comme des tenseurs de forme ‘(24, 14)’, où 24 représente le nombre de pas de temps et 14 le nombre de caractéristiques pour chaque pas de temps.(Voir la figure 3.28)

4. **Branches du Modèle**

Le modèle comporte quatre branches parallèles, chacune traitant les mêmes données d’entrée via deux blocs de transformateurs. Après avoir traversé les blocs de transformateurs, les données passent par une couche de pooling global pour réduire la dimensionnalité, suivie d’une couche de dropout pour réduire le surapprentissage.

5. **Couches de Sortie**

Chaque branche se termine par une couche de sortie dédiée à un composant spécifique. Ces couches de sortie utilisent une fonction d’activation sigmoïde pour produire des probabilités de classification binaire.

6. **Définition du Modèle**

Les entrées et les sorties des quatre branches sont combinées pour définir le modèle global. Ce modèle peut donc prédire simultanément l’état des quatre composants.

7. **Compilation du Modèle**

Le modèle est compilé avec la fonction de perte ‘binary_crossentropy’ pour chaque sortie, l’optimiseur Adam, et les métriques d’accuracy. Les poids de perte sont ajustés pour chaque sortie pour équilibrer leur importance durant l’entraînement.

8. **Entraînement du Modèle**

L’organigramme ou algorithme suivant résume les différentes étapes suivies pour la résolution de notre problème

— **les performances de model Transformers pour chaque composant :**

Model	Composant	Accuracy	Precision	Recall	F1-Score	AUC
transformers	Composant 1	0.9958	0.60253	0.3531	0.4452	0.6760
transformers	Composant 2	0.9924	0.4957	0.5530	0.5228	0.7744
transformers	Composant 3	0.9970	0.5188	0.6064	0.5592	0.8023
transformers	Composant 4	0.9971	0.6827	0.5407	0.6034	0.7698

TABLE 3.4 – Performances du modèle de transformers

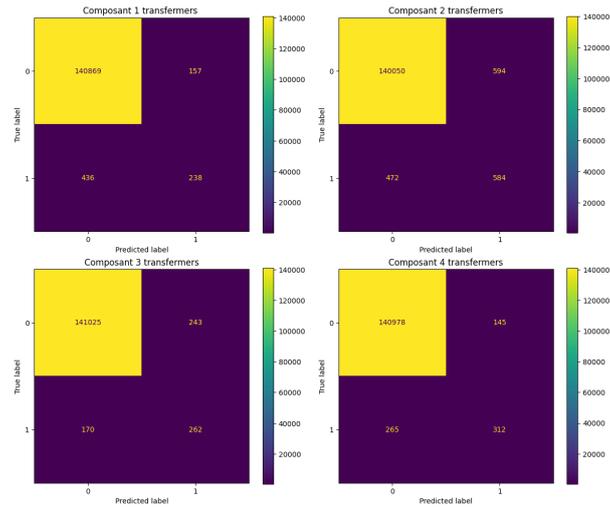


FIGURE 3.29 – Matrice de confusion modèle de transformers

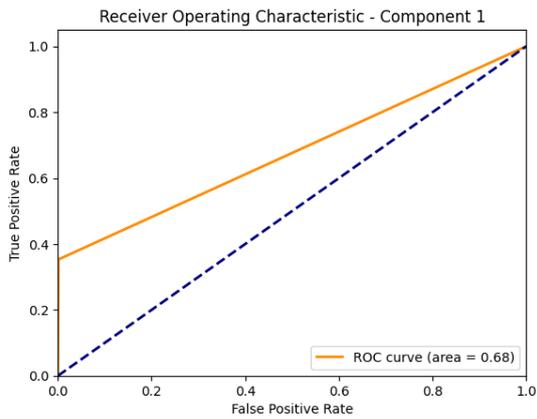


FIGURE 3.30 – la courbe ROC de composant 1

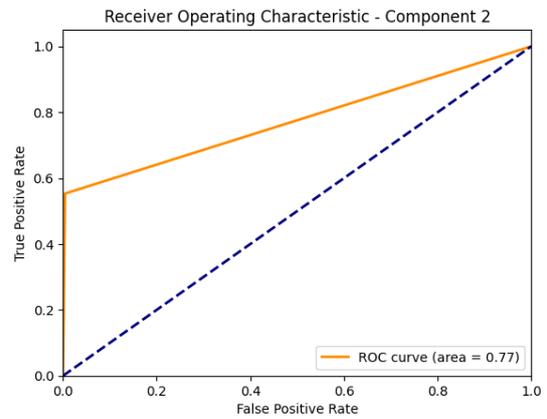


FIGURE 3.31 – la courbe ROC de composant 2

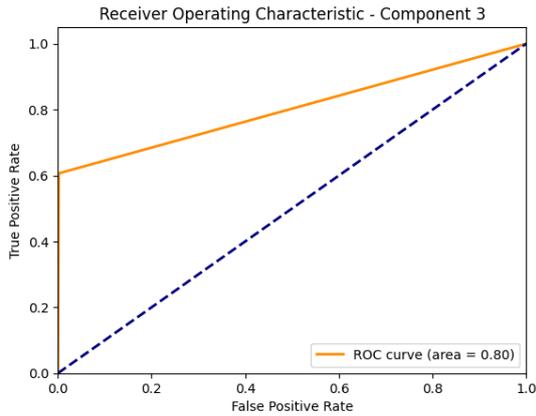


FIGURE 3.32 – la courbe ROC de composant 3

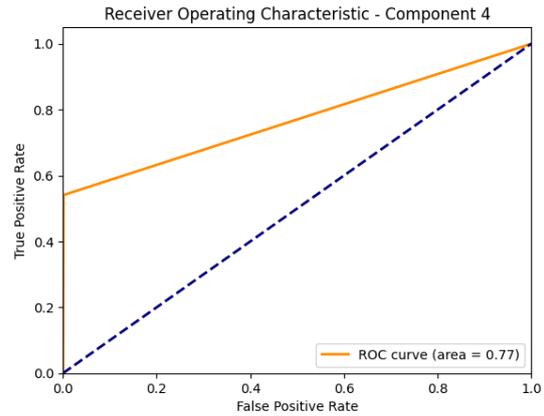


FIGURE 3.33 – la courbe ROC de composant 4

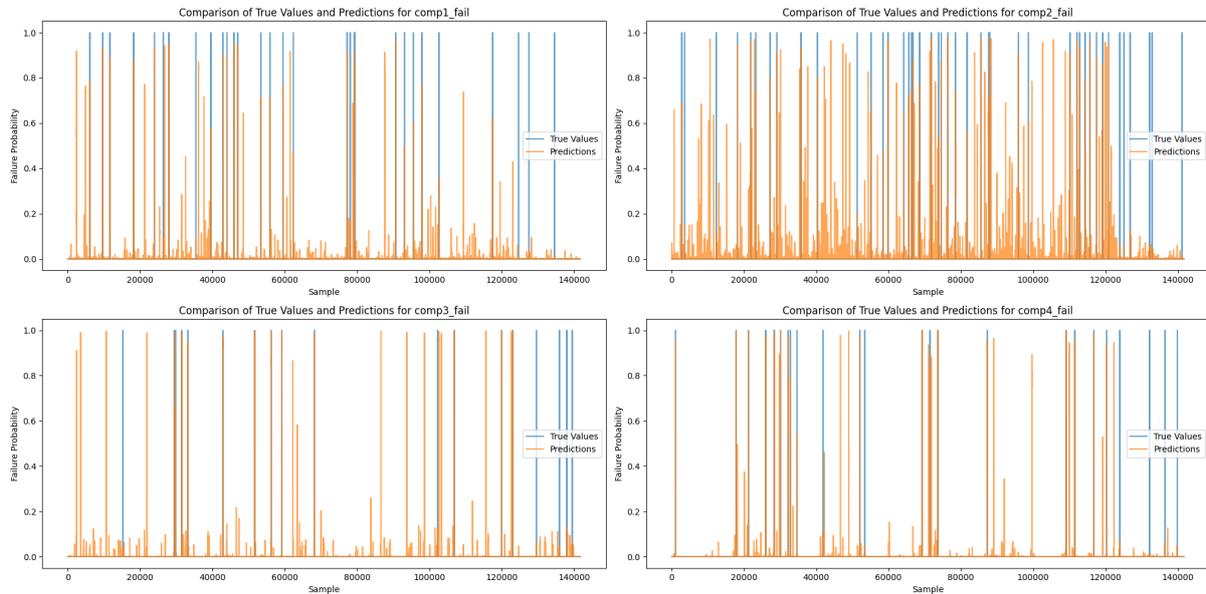


FIGURE 3.34 – comparaison entre les vraies valeurs et les valeurs prédites

— Interprétation des résultats

Les transformers n'ayant pas donné de bons résultats, globalement tous les composants ont montré une accuracy élevée. Cependant, les précisions et recalls sont globalement faibles à modérés, montrant des difficultés à détecter toutes les anomalies et un nombre significatif de faux positifs. Les F1-scores montrent une amélioration progressive d'un composant à l'autre, mais restent modestes, indiquant des compromis médiocres entre la précision et le rappel. Les AUCs varient, avec des performances allant de modérées à bonnes en termes de séparation des classes. Le composant 4 se distingue par la meilleure précision et le meilleur F1-score, bien que son rappel soit encore perfectible. (voir la table 3.4)

— Conclusion :

En conclusion, bien que les transformers n'aient pas donné les résultats escomptés, les composants évalués ont montré une accuracy élevée mais des précisions et recalls faibles à modérés, indiquant des défis dans la détection des anomalies et la gestion des

faux positifs. Les F1-scores et AUCs suggèrent des performances variables. Le composant 4 se distingue par la meilleure précision et le meilleur F1-score, mais il reste encore des marges d'amélioration, notamment en termes de rappel.

3.2.4.5 Modèle de maintenance prédictive Hybride (GRU+LSTM) :

Un modèle hybride GRU (Gated Recurrent Unit) et LSTM (Long Short-Term Memory) combine les forces des deux types de réseaux de neurones récurrents. Ce modèle améliore la précision des prédictions en capturant efficacement les dépendances à long et court terme dans les séries temporelles (voir la figure 3.35)

— Architecture du modèle :

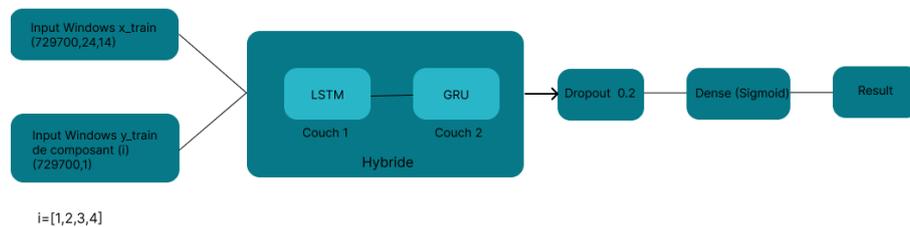


FIGURE 3.35 – l'architecture détaillée du modèle de hybride

— Algorithme du modèle :

L'algorithme définit et entraîne un modèle hybride (LSTM et GRU) pour la détection d'anomalies dans quatre composants distincts. Le modèle utilise des combinaisons de couches LSTM et GRU et est construit à l'aide de TensorFlow et Keras. Voici une explication détaillée :

1. Importation des Bibliothèques

Les bibliothèques nécessaires de Keras sont importées pour créer et gérer les couches LSTM, GRU, Dropout, Dense et Input, ainsi que pour définir et compiler le modèle.

2. Définition de l'Entrée

Les données d'entrée du modèle sont définies comme ayant une séquence de 24 pas de temps et 14 caractéristiques à chaque pas de temps.

3. Définition des Branches du Modèle

Le modèle est divisé en quatre branches distinctes, chacune utilisant une combinaison différente de couches LSTM et GRU pour traiter les données d'entrée. Chaque branche suit une structure similaire :

- Branche 1 (LSTM + GRU) : Applique une couche LSTM suivie d'une couche Dropout, puis une couche GRU suivie d'une autre couche Dropout.
- Branche 2 (LSTM+ LSTM) : Applique une couche LSTM suivie d'une couche Dropout, puis une couche GRU suivie d'une autre couche Dropout.
- Branche 3 (LSTM + GRU) : Applique une couche LSTM suivie d'une couche Dropout, puis une couche GRU suivie d'une autre couche Dropout.

- Branche 4 (LSTM + LSTM) : Applique une couche LSTM suivie d'une couche Dropout, puis une couche GRU suivie d'une autre couche Dropout.
- Définition des Couches de Sortie Chaque branche se termine par une couche dense avec une activation sigmoïde pour produire une probabilité de défaillance pour chaque composant.

4. Compilation du Modèle

Le modèle est compilé avec la fonction de perte `binary_crossentropy` pour chaque sortie, l'optimiseur Adam, et les métriques d'évaluation sont définies comme la précision pour chaque composant.

5. Entraînement du Modèle

Le modèle est entraîné sur les données d'entraînement définies (`window_train_x`) avec les étiquettes correspondantes pour chaque composant pendant 5 époques avec une taille de batch de 25.

— les performances de model Hybride pour chaque composant :

Model	Composant	Accuracy	Precision	Recall	F1-Score	AUC
hybride	Composant 1	0.9978	0.8464	0.6706	0.7483	0.8350
hybride	Composant 2	0.9968	0.7958	0.7679	0.7816	0.8832
hybride	Composant 3	0.9987	0.8172	0.7662	0.7909	0.8828
hybride	Composant 4	0.9986	0.9315	0.7313	0.8194	0.8655

TABLE 3.5 – Performances du modèle d'hybride(LSTM et GRU)

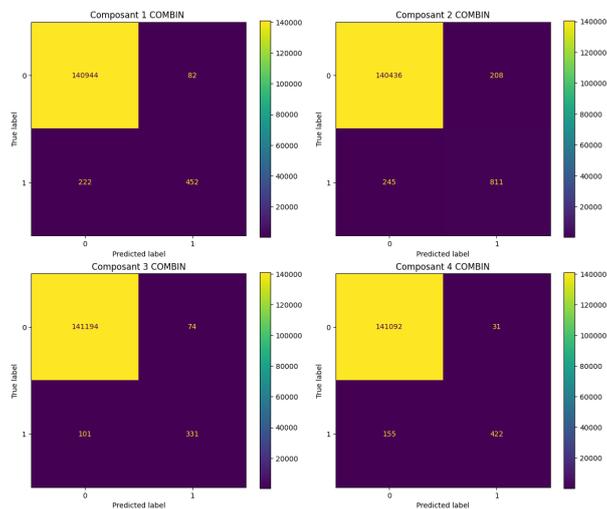


FIGURE 3.36 – matrice de confusion de model hybride

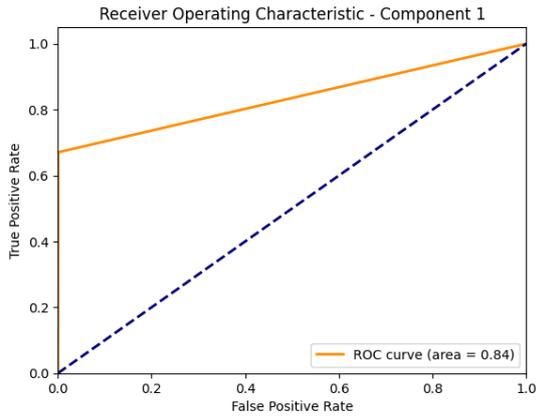


FIGURE 3.37 – la courbe ROC de composant 1

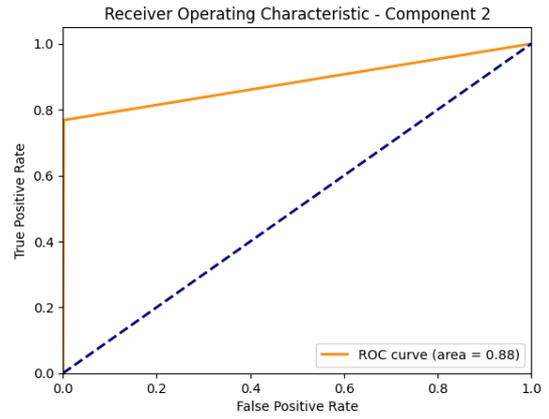


FIGURE 3.38 – la courbe ROC de composant 2

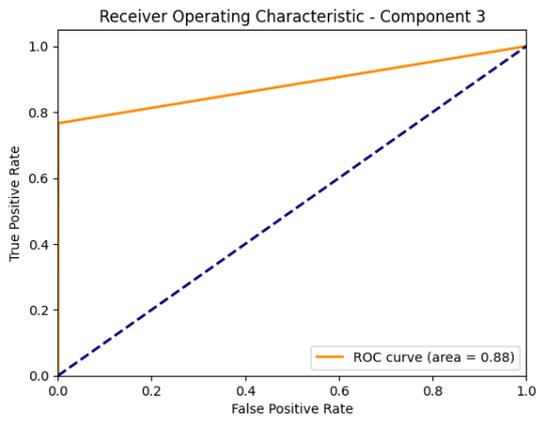


FIGURE 3.39 – la courbe ROC de composant 3

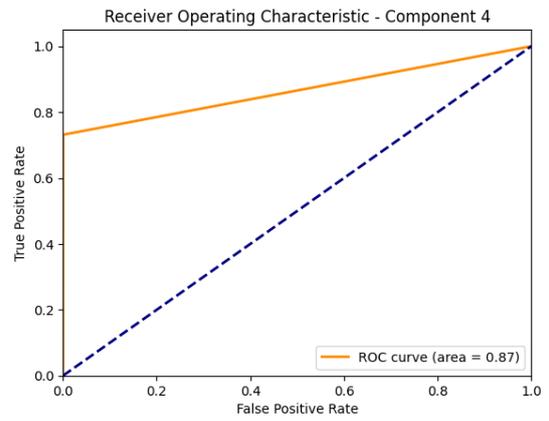


FIGURE 3.40 – la courbe ROC de composant 4

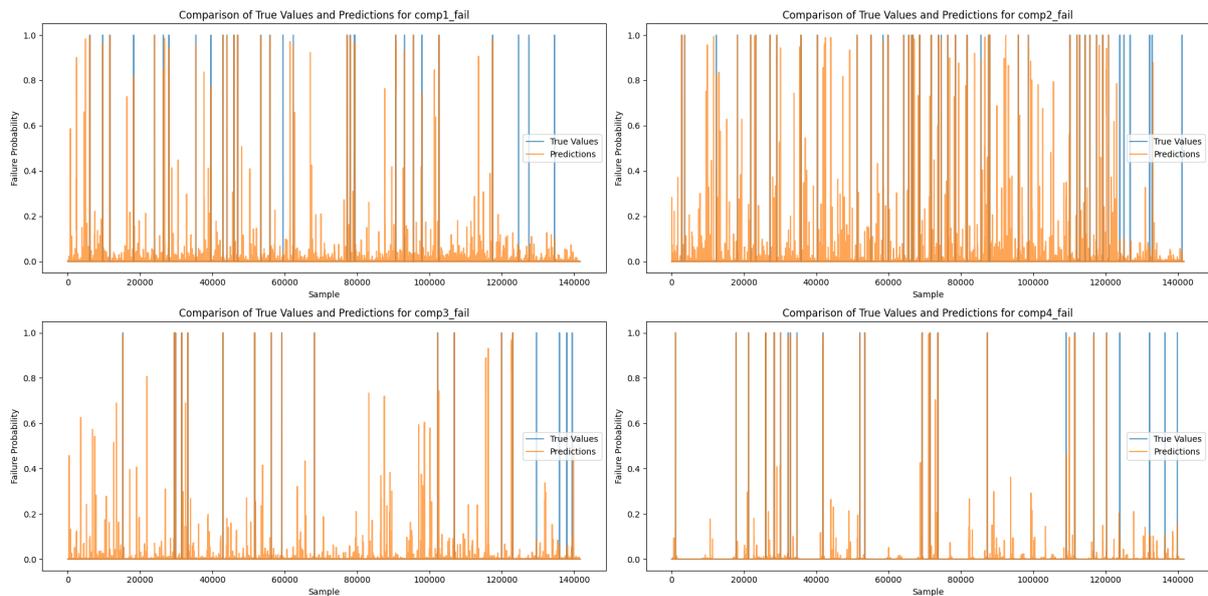


FIGURE 3.41 – comparaison entre les vraies valeurs et les valeurs prédites

— **Interprétation des résultats :**

-Composant 4 semble le meilleur en termes de précision et F1-Score, ce qui signifie qu'il est bien équilibré entre la précision et le rappel, tout en ayant une très bonne capacité de discrimination des classes.

-Composant 2 a le meilleur AUC et un rappel élevé, ce qui peut être crucial pour des applications où l'identification des vrais positifs est primordiale.

-composant 3 montre une précision et un F1-Score élevés, légèrement derrière le composant 4 mais avec un très bon équilibre global.

-Composant 1 a la précision la plus basse et un rappel plus faible, ce qui pourrait le rendre moins favorable comparé aux autres.

— **conclusion :**

Le modèle hybride LSTM+GRU est très efficace pour la détection d'anomalies dans tous les composants, montrant des taux de précision élevés et une bonne capacité à distinguer les anomalies des instances normales. Cependant, l'amélioration du rappel pour certains composants pourrait renforcer encore davantage sa performance globale.

3.3 Évaluation des Modèles Prédictifs pour la Détection des Défaillances Composantes : Une Étude Comparative

Les résultats des évaluations montrent les performances des modèles pour chaque composant selon les différentes métriques. En comparant les valeurs d'Accuracy, de Précision, de Recall, de F1-Score et d'AUC, nous pouvons identifier les points forts et les limitations de chaque modèle pour chaque composant. Cette comparaison permet de mieux comprendre l'efficacité de chaque branche du modèle dans la prédiction des défaillances, facilitant ainsi l'identification des meilleures configurations et des domaines nécessitant des améliorations. Les graphiques ci-dessous présentent une comparaison visuelle des performances des quatre modèles pour chaque métrique d'évaluation. Chaque barre du graphique représente un modèle, permettant une comparaison directe et claire des performances des différentes branches du réseau.

3.3.1 Étude Comparative pour la Détection des Défaillances de Composant 1

La figure 3.42 compare les performances de quatre modèles (LSTM, GRU, Transformer, Hybride) sur quatre métriques : Accuracy, Précision, Recall, F1-Score, et AUC.

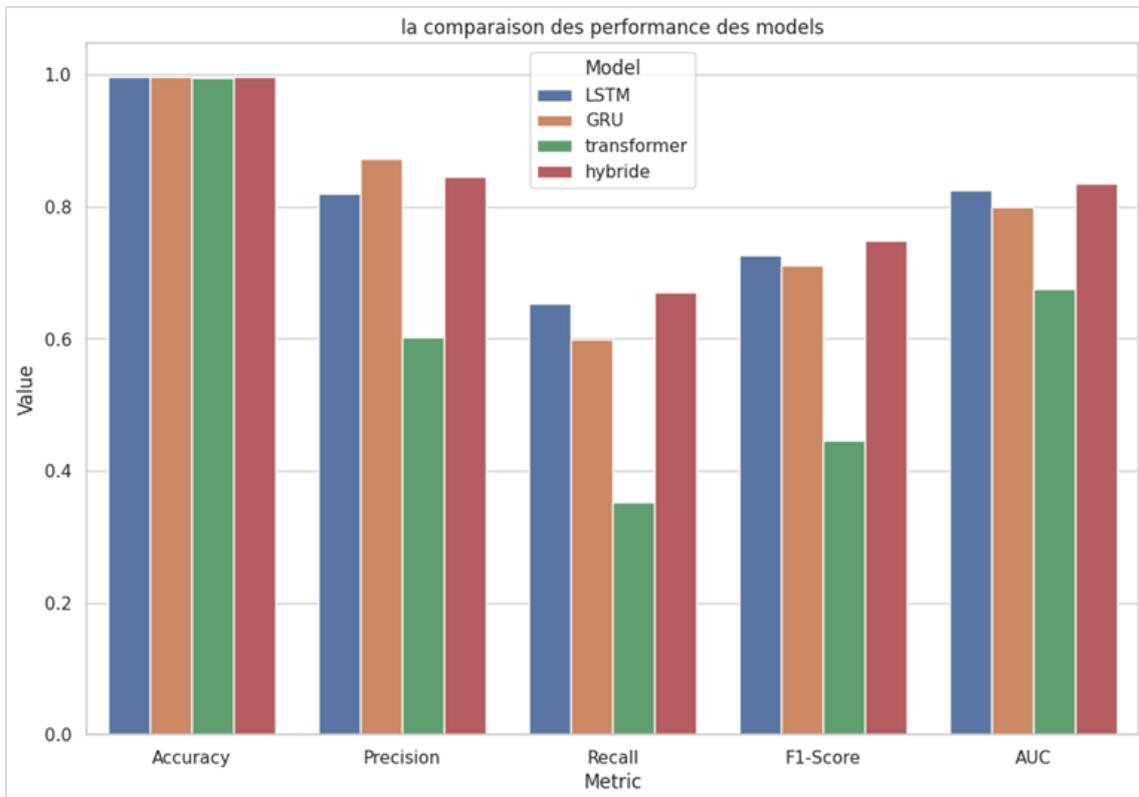


FIGURE 3.42 – la comparaison des performances des modèles du composant 1

3.3.1.1 Interprétation des Résultats

Voici les observations principales pour chaque métrique :

1. Accuracy (Exactitude) :

- Tous les modèles ont une accuracy très élevée, proche de 1.0.
- Le modèle LSTM, GRU, et Hybride montrent une légère supériorité par rapport au Transformer.

2. Precision (Précision) :

- Le modèle Hybride (LSTM+GRU) et le modèle GRU ont les meilleures précisions.
- Le Transformer a la précision la plus basse, indiquant qu'il génère plus de faux positifs par rapport aux autres modèles.

3. Recall (Rappel) :

- Le modèle Transformer et le modèle Hybride ont des valeurs de rappel similaires et relativement élevées.
- Le modèle LSTM a un rappel plus bas que les autres, indiquant qu'il manque plus d'anomalies (faux négatifs) par rapport aux autres modèles.

4. F1-Score :

- Le modèle Hybride a le F1-Score le plus élevé, montrant un bon équilibre entre précision et rappel.

- Les modèles LSTM et GRU ont également de bons F1-Scores, mais légèrement inférieurs au modèle Hybride.
- Le Transformer a un F1-Score plus bas, ce qui est cohérent avec sa précision plus faible.

5. AUC (Area Under the Curve) :

- Le modèle Hybride a la meilleure AUC, suivi de près par les modèles LSTM et GRU.
- Le Transformer a l'AUC la plus basse, indiquant qu'il est globalement moins performant pour distinguer entre classes.

3.3.1.2 Choix du Meilleur Modèle

En analysant les différentes métriques, le modèle Hybride (LSTM+GRU) se démarque comme étant le meilleur :

- **Précision et Recall Équilibrés** : Il offre un bon compromis entre la précision et le rappel, comme le montre son F1-Score élevé.
- **AUC Supérieur** : Sa valeur AUC est la plus élevée, ce qui signifie qu'il est globalement meilleur pour distinguer entre les anomalies et les non-anomalies.

Ainsi, le modèle Hybride (LSTM+GRU) est recommandé comme le meilleur choix pour la détection des anomalies dans cette étude.

3.3.2 Étude Comparative pour la Détection des Défaillances de Composant 2

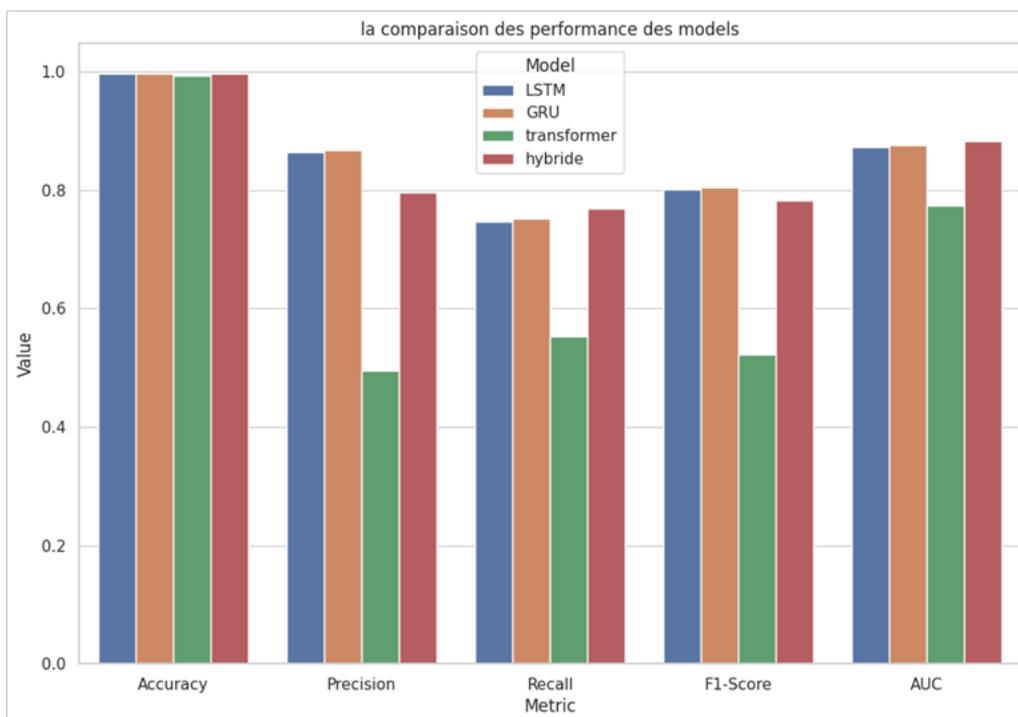


FIGURE 3.43 – la comparaison des performances des modèles du composant 2

3.3.2.1 Interprétation des Résultats

Pour interpréter les résultats présentés dans l'histogramme (voir la figure 3.43), nous pouvons comparer les performances des quatre modèles (LSTM, GRU, Transformer, et Hybride) en utilisant les métriques suivantes : Précision (Accuracy), Précision (Precision), Rappel (Recall), Score F1 (F1-Score), et AUC (Area Under the Curve). Voici une analyse détaillée de chaque métrique :

1. **Accuracy** : Tous les modèles (LSTM, GRU, Transformer, et Hybride) montrent des performances similaires et très élevées en termes de précision, avec des valeurs proches de 1. Cela indique que tous les modèles sont capables de prédire correctement la majorité des instances.
2. **Précision (Precision)** :
 - LSTM et GRU ont des valeurs de précision légèrement supérieures comparées aux autres modèles.
 - Transformer montre une performance significativement plus faible en termes de précision.
 - Le modèle Hybride a une précision relativement élevée, se rapprochant des meilleures performances.
3. **Rappel (Recall)** :
 - LSTM, GRU, et modèle Hybride montrent des valeurs de rappel élevées, indiquant une bonne capacité à identifier les vraies instances positives.
 - Transformer a une performance plus faible en termes de rappel, ce qui signifie qu'il peut manquer plusieurs instances positives.
4. **Score F1 (F1-Score)** :
 - LSTM, GRU, et modèle Hybride ont des scores F1 élevés et similaires, montrant un bon équilibre entre la précision et le rappel.
 - Transformer a un score F1 plus faible, ce qui reflète ses performances plus faibles en précision et rappel.
5. **AUC (Area Under the Curve)** : Tous les modèles montrent des valeurs AUC très élevées et similaires, ce qui indique une bonne performance globale en termes de séparation des classes.

3.3.2.2 Choix du Meilleur Modèle

Les modèles LSTM, GRU, et Hybride ont des performances globales similaires et élevées, avec une légère supériorité du modèle Hybride en termes de Rappel. Le modèle Transformer, cependant, présente des performances inférieures en précision, rappel et score F1. En résumé, bien que tous les modèles aient une bonne précision et AUC, le modèle Hybride semble offrir le meilleur équilibre entre les différentes métriques de performance.

3.3.3 Étude Comparative pour la Détection des Défaillances du Composant 3

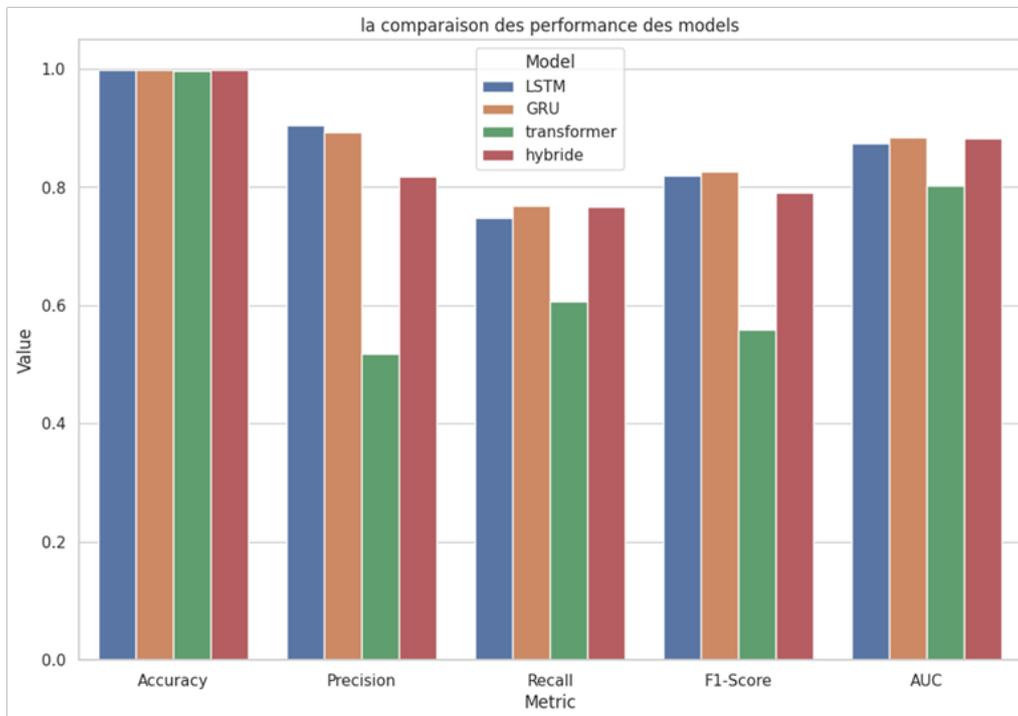


FIGURE 3.44 – la comparaison des performances des modèles du composant 3

3.3.3.1 Interprétation des Résultats

L'histogramme présente une comparaison des performances de quatre modèles différents (voir la figure 3.44) : LSTM, GRU, Transformer, et un modèle hybride. La comparaison est faite selon cinq métriques de performance : Précision, Rappel, F1-Score, et AUC (Surface sous la courbe).

1. Exactitude (Accuracy) :

- Les quatre modèles (LSTM, GRU, Transformer, Hybride) ont une exactitude très similaire, proche de 1.0. Cela suggère que tous les modèles classent correctement les données de manière efficace.

2. Précision :

- Le modèle Transformer a la précision la plus faible parmi les quatre modèles.
- Les modèles LSTM, GRU, et Hybride ont une précision similaire, nettement supérieure à celle du Transformer.

3. Rappel (Recall) :

- Le modèle Transformer a un rappel nettement inférieur par rapport aux autres modèles.
- Les modèles LSTM, GRU, et Hybride ont un rappel similaire.

4. F1-Score :

- Le F1-Score du modèle Transformer est inférieur par rapport aux modèles LSTM, GRU, et Hybride.
- Les modèles LSTM, GRU, et Hybride ont des F1-Scores similaires, indiquant une performance équilibrée entre la précision et le rappel.

5. AUC (Surface sous la courbe) :

- Tous les modèles ont des valeurs AUC très similaires, proches de 1.0, indiquant une excellente performance pour distinguer entre les classes.

3.3.3.2 Choix du Meilleur Modèle

Le modèle LSTM semble être le meilleur choix global, car il combine les points forts des autres modèles et montre des performances équilibrées et robustes sur toutes les métriques. Il est presque à égalité avec les modèles Hybride et GRU en termes de précision et de rappel, tout en ayant des valeurs élevées de F1-Score.

3.4 Conclusion

Après avoir essayé quatre modèles différents pour la détection des anomalies pour chaque composant de la machine, nous avons constaté que les modèles LSTM, GRU et hybrides (LSTM et GRU) ont donné des résultats intéressants et prometteurs.

Les modèles de réseaux de neurones récurrents (RNN), en particulier les architectures LSTM et GRU, se sont révélés efficaces pour capturer les dépendances temporelles et les schémas séquentiels dans les données de télémétrie des machines. Ces modèles ont montré une capacité supérieure à détecter les anomalies par rapport aux méthodes plus simples, grâce à leur aptitude à mémoriser et à utiliser des informations passées sur de longues séquences de données.

Le modèle hybride, combinant à la fois LSTM et GRU, a montré des performances notables en tirant parti des avantages des deux architectures. Ce modèle a démontré une robustesse et une précision accrues dans la détection des défaillances, surpassant parfois les modèles individuels de LSTM et GRU.

Conclusion Générale et Perspectives

Conclusion Générale

A la fin de cette étude, nous concluons que la prédiction joue un rôle essentiel dans la maintenance industrielle en permettant d'identifier les anomalies avant qu'elles ne deviennent des défaillances critiques. Cette capacité à anticiper les problèmes est cruciale pour optimiser la performance opérationnelle et réduire les coûts associés aux arrêts non planifiés. En effet, les méthodes traditionnelles, telles que les approches réactives et préventives basées sur des calendriers fixes, se révèlent inefficaces pour détecter précocement les anomalies et prévenir les défaillances critiques, entraînant des pertes économiques significatives et une réduction de la compétitivité industrielle. Face à ces limitations, l'intégration des technologies de pointe comme l'Internet des Objets (IoT), le Big Data et l'intelligence artificielle a ouvert de nouvelles perspectives. En particulier, les réseaux de neurones récurrents, notamment les LSTM (Long Short-Term Memory) et les GRU (Gated Recurrent Unit), ont montré une capacité remarquable à modéliser des séquences temporelles complexes et à détecter des anomalies avec une précision accrue. Notre étude a proposé et validé une approche hybride combinant les LSTM et les GRU, permettant de tirer parti des forces de chaque modèle pour améliorer la robustesse et la précision des prédictions de maintenance.

Les résultats obtenus montrent que cette approche hybride surpasse les autres méthodes et offre une solution prometteuse

- pour la maintenance prédictive, permettant d'anticiper les défaillances,
- réduire les temps d'arrêt non planifiés
- et optimiser l'utilisation des ressources,

contribuant ainsi à une meilleure performance opérationnelle et à des économies significatives.

Perspectives

En regardant vers l'avenir, bien que ce mémoire se concentre principalement sur l'Industrie 4.0, il est important de noter

- l'émergence de l'Industrie 5.0, qui mettra davantage l'accent sur :
- l'interaction entre l'humain et la machine, la durabilité et la résilience des systèmes industriels.
- Cette nouvelle ère promet de nouvelles avancées technologiques et méthodologiques qui pourraient encore améliorer les stratégies de maintenance prédictive.

- Les futures recherches pourraient se concentrer sur l'intégration de l'intelligence artificielle augmentée et de l'apprentissage automatique avancé pour développer des modèles encore plus précis et réactifs.
- De plus, l'intégration de sources de données diversifiées et l'amélioration de la fusion de données permettront une meilleure compréhension et anticipation des défaillances.
- Enfin, l'accent mis sur la durabilité et l'efficacité énergétique deviendra de plus en plus crucial, alignant les stratégies de maintenance avec les objectifs globaux de développement durable.

Bibliographie

- [1] *4th Industrial Revolution (4IR) and Entrepreneurship Beyond*. <https://www.linkedin.com/pulse/4th-industrial-revolution-4ir-entrepreneurship-beyond-sureshbabu-s>. Accessed : July 8, 2024.
- [2] AFNOR. *La maintenance industrielle*. Association Française de Normalisation, 1994.
- [3] Cao et AL. “KSPMI : a knowledge-based system for predictive maintenance in industry 4.0”. In : *Robotics and Computer-Integrated Manufacturing* 74 (2022), p. 102281.
- [4] Jimenez et AL. “Towards multi-model approaches to predictive maintenance : A systematic literature survey on diagnostics and prognostics”. In : *Journal of Manufacturing Systems* 56 (2020), p. 539-557.
- [5] Es-sakali et AL. “Review of predictive maintenance algorithms applied to HVAC systems”. In : *Energy Reports* 8 (2022), p. 1003-1012.
- [6] Sayyad et AL. “Estimating remaining useful life in machines using artificial intelligence : A scoping review”. In : *Libr. Philos. Pract* (2021), p. 1-26.
- [7] Shreyas Gawde et AL. “A scoping review on multi-fault diagnosis of industrial rotating machines using multi-sensor data fusion”. In : *Artificial Intelligence Review* (2022), p. 1-54.
- [8] Ikram AMROUCHE et Malak Sakina LAHOUASSA. “Application du Machine Learning à la Maintenance Prédictive : Un Processus basé sur la Sélection d’Algorithmes et l’Alignement Stratégique”. Mém. de mast. Ecole Nationale Supérieure de Technologie, République Algérienne Démocratique et Populaire, 2023.
- [9] N. AMRUTHNATH et T. GUPTA. “A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance”. In : *2018 5th International Conference on Industrial Engineering and Applications (ICIEA)*. 2018, p. 355-361.
- [10] G. AUDEMARD et al. “Sur le pouvoir explicatif des arbres de décision”. In : *Extraction et Gestion des Connaissances, EGC, Jan 2022, Blois, France*. 2022, p. 147-158. URL : <http://www.cril.univ-artois.fr/>.
- [11] X. BAMPOULA et al. “A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders”. In : *Sensors* 21 (2021), p. 972.
- [12] Arnab BISWAS. *Microsoft Azure Predictive Maintenance Dataset*. Accessed : 2024-06-28. 2021. URL : <https://www.kaggle.com/datasets/arnabbiswas1/microsoft-azure-predictive-maintenance>.
- [13] R. BUYYA et A. V. DASTJERDI. *Internet of Things : Principles and Paradigms*. Morgan Kaufmann, Elsevier, 2016.
- [14] F. DE VITA et D. BRUNEO. “On the use of LSTM networks for Predictive Maintenance in Smart Industries”. In : *2019 IEEE International Conference on Smart Computing (SMARTCOMP)*. 2019. DOI : 10.1109/SMARTCOMP.2019.00059.
- [15] *Different Types of Maintenance*. https://www.researchgate.net/figure/Les-differents-types-de-maintenance_fig15_351735755. Accessed : July 8, 2024.
- [16] M. ELKATEB, J. SMITH et N. GARCIA. “Predictive Maintenance for Circular Knitting Machines Using IoT and Machine Learning”. In : *Journal of Industrial Technology* 10.2 (2024), p. 45-56.

- [17] H. ERBIYIK. "Definition of Maintenance and Maintenance Types with Due Care on Preventive Maintenance". In : *Maintenance Management - Current Challenges, New Developments, and Future Directions*. Sous la dir. de G. LAMBERT-TORRES, E. L. BONALDI et L. E. de L. DE OLIVEIRA. IntechOpen, 2022. DOI : 10.5772/intechopen.106346.
- [18] *Etapes du cycle de vie d'un produit*. https://www.researchgate.net/figure/Etapes-du-cycle-de-vie-dun-produit_fig1_256437263. Accessed : July 8, 2024.
- [19] S. ISLAM et al. "A Comprehensive Survey on Applications of Transformers for Deep Learning Tasks". In : *Expert Systems With Applications* (2023). arXiv : arXiv : 2306.07303v1 [cs.LG].
- [20] A. K. S. JARDINE, D. LIN et D. BANJEVIC. "A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance". In : *Mechanical Systems and Signal Processing* (2006).
- [21] P. JOHNSON. "One-Hot Encoding". In : *Data Science Journal* 14 (2015), p. 35-45.
- [22] S. KHAN et T. YAIRI. "A Review on the Application of Deep Learning in System Health Management". In : *Mechanical Systems and Signal Processing* 107 (2018), p. 241-265.
- [23] N.G. KUFTINOVA et al. "Predictive diagnostics and maintenance of industrial equipment". In : *Russian Engineering Research* 42.2 (2022), p. 158-161.
- [24] Dwi KUSUMANINGRUM, Nani KURNIATI et Budi SANTOSA. "Machine learning for predictive maintenance". In : *Proceedings of the International Conference on Industrial Engineering and Operations Management*. 2021, p. 2348-2356.
- [25] E. MERCIER-LAURENT. "Intelligence artificielle 4.0 pour l'Industrie 4.0". In : *1024 : Bulletin de la Société Informatique de France* 15 (2020), p. 127-137. DOI : 10.48556/SIF.1024.15.127.
- [26] R. Keith MOBLEY. *Maintenance Fundamentals*. Butterworth-Heinemann, 2011.
- [27] NF EN 13306. *Maintenance - Terminologie*. AFNOR, 2018.
- [28] R. NOUREDDINE. "Implémentation de la maintenance prédictive dans les systèmes de production". Thèse de doct. Université des Sciences et de la Technologie d'Oran - Mohamed Boudiaf, 2008.
- [29] F. PEDREGOSA et al. "scikit-learn : Machine Learning in Python". In : *Journal of Machine Learning Research* 12 (2011), p. 2825-2830. URL : <http://jmlr.csail.mit.edu/papers/v12/pedregosa11a.html>.
- [30] Q. QI et F. TAO. "Digital twin and big data towards smart manufacturing and industry 4.0 : 360 degree comparison". In : *IEEE Access* 6 (2018), p. 3585-3593.
- [31] PNV Srinivasa RAO et PVY JAYASREE. "International Journal of Mechanical Engineering". In : 7.5 (2022). ISSN : 0974-5823.
- [32] *RapidMiner*. <https://www.rapidminer.com/>. Consulté le 28 juin 2024.
- [33] D. RAVI et al. "Deep Learning for Health Informatics". In : *IEEE Journal of Biomedical and Health Informatics* 21.1 (2017), p. 4-21. DOI : 10.1109/JBHI.2016.2636665.
- [34] Oscar SERRADILLA et al. "Deep learning models for predictive maintenance : A survey, comparison, challenges and prospects". In : *Applied Intelligence* 52.10 (2022), p. 10934-10964.
- [35] H.D. SHOORKAND, M. NOURELFATH et A. HAJJI. "A hybrid CNN-LSTM model for joint optimization of production and imperfect predictive maintenance planning". In : *Reliability Engineering & System Safety* 241 (2024), p. 109707.
- [36] Willamos SILVA. "CNN-PDM : A Convolutional Neural Network Framework For Assets Predictive Maintenance". Thèse de doct. Western University, 2019.
- [37] K. SMAGULOVA et A. P. JAMES. "A Survey on LSTM Memristive Neural Network Architectures and Applications". In : *The European Physical Journal Special Topics* 228.10 (2019), p. 2313-2324.
- [38] A. H. C. TSANG. "Condition-based Maintenance : Tools and Decision Making". In : *Journal of Quality in Maintenance Engineering* (1995).
- [39] R. TUFANO, L. PASCARELLA et G. BAVOTA. "Automating Code-Related Tasks Through Transformers : The Impact of Pre-training". In : (2023). arXiv : arXiv : 2302.04048v1 [cs.SE].
- [40] E. WESCOAT, M. KRUGH et L. MEARS. "Procedia Manufacturing". In : 53 (2021), p. 644-655.

- [41] X FD. 60-000, *Norme Française*. AFNOR, 2002.
- [42] C.-H. YEH et al. "Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine". In : *Sensors* 19.7 (2019), p. 1671.
- [43] Woo-Seung YUN, Won-Hwa HONG et Hyuncheol SEO. "A data-driven fault detection and diagnosis scheme for air handling units in building HVAC systems considering undefined states". In : *Journal of Building Engineering* 35 (2021), p. 102111.

Résumé

Ce mémoire propose une approche intelligente de maintenance prédictive pour l'Industrie 4.0, visant à détecter les anomalies dans les équipements industriels grâce à l'intégration des réseaux de neurones LSTM et GRU. L'objectif principal est d'améliorer la fiabilité opérationnelle et la gestion des ressources en optimisant la prédiction des défaillances. En exploitant les réseaux de neurones récurrents, nous avons proposé d'utiliser l'approche hybride combinant LSTM et GRU pour résoudre le défi de la maintenance prédictive. Les résultats expérimentaux démontrent une amélioration significative de la précision prédictive par rapport aux approches traditionnelles, mettant en évidence l'efficacité du modèle hybride proposé pour anticiper et prévenir les défaillances industrielles.

Mots clés : maintenance prédictive, Industrie 4.0, LSTM, GRU, deep learning, gestion des ressources, anomalies industrielles.

Abstract

This thesis proposes an intelligent predictive maintenance approach for Industry 4.0, aiming to detect anomalies in industrial equipment through the integration of LSTM and GRU neural networks. The main objective is to improve operational reliability and resource management by optimizing the prediction of failures. By exploiting recurrent neural networks, we proposed using the hybrid approach combining LSTM and GRU to solve the challenge of predictive maintenance. Experimental results demonstrate a significant improvement in predictive accuracy compared to traditional approaches, highlighting the effectiveness of the proposed hybrid model for anticipating and preventing industrial failures.

Keywords : predictive maintenance, Industry 4.0, LSTM, GRU, deep learning, resource management, industrial anomalies.