



Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de l'auteur de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.

UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

**APPROCHES INNOVANTES POUR LA PRÉDICTION DES
DÉFAILLANCES MÉCANIQUES : MODÈLES DE MAINTENANCE 4.0
DANS L'INDUSTRIE MINIÈRE**

MÉMOIRE
PRÉSENTÉ
COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN INGÉNIERIE

PAR
NOUR ELKHENIN

MAI 2025

REMERCIEMENTS

Je souhaite exprimer ma sincère gratitude à toutes les personnes qui, d'une manière ou d'une autre, ont contribué à l'aboutissement de ce travail et m'ont soutenu tout au long de ce parcours. Ce projet a représenté un défi scientifique et technique, et son accomplissement n'aurait pas été possible sans l'aide précieuse de ceux qui ont su m'encadrer, me conseiller et m'accompagner avec bienveillance.

Tout d'abord, j'adresse mes plus vifs remerciements à mon directeur de recherche, le Professeur **Hatem MRAD**, pour son encadrement rigoureux, sa patience et la richesse de ses conseils. Son expertise scientifique et méthodologique a été déterminante dans la progression de cette recherche, me guidant avec clarté et précision à chaque étape du projet. Il a su m'accompagner avec bienveillance, en m'offrant les outils et les orientations nécessaires pour approfondir mes analyses et structurer mes réflexions. Je lui suis particulièrement reconnaissant pour le temps qu'il a consacré à m'épauler, ainsi que pour ses encouragements qui ont renforcé ma détermination à mener cette étude à bien.

Je tiens également à remercier les partenaires industriels Agnico Eagle – Complexe LaRonde, en particulier monsieur **Mederic Lafleur**, pour son appui et ses précieuses recommandations tout au long du projet, ainsi que Canadian Malartic pour sa collaboration et les ressources mises à disposition. Leur engagement et leur expertise ont largement enrichi la pertinence des analyses menées.

Je suis également reconnaissant aux membres du jury, dont l'expertise, les remarques pertinentes et les suggestions ont contribué à améliorer ce travail. Leur analyse rigoureuse a enrichi cette recherche tant sur le plan méthodologique que scientifique.

Enfin, j'adresse toute ma reconnaissance à ma famille et mes proches pour leur soutien constant, leur patience et leurs encouragements. Leur présence bienveillante m'a permis de faire face aux défis de cette recherche avec détermination.

DÉDICACE

Je dédie ce travail à ceux qui ont été ma source de force et de motivation tout au long de ce parcours.

À **mes parents**, pour leur amour inconditionnel et leur soutien sans faille. Maman, ta patience, ta bienveillance et tes encouragements m'ont toujours guidé dans les moments de doute. Papa, ta confiance en moi et tes conseils avisés ont été une source d'inspiration précieuse, me poussant à donner le meilleur de moi-même.

À **mon frère**, dont le soutien et la présence ont été une véritable source de réconfort et de motivation. Ta complicité et tes encouragements m'ont accompagné à chaque étape de ce projet, me donnant la force de persévérer.

Enfin, à **ma famille** et à mes proches, qui m'ont soutenu, encouragé et inspiré tout au long de cette aventure. Leur présence et leur bienveillance ont été essentielles pour mener ce travail à son terme.

TABLE DES MATIÈRES

REMERCIEMENTS	ii
DÉDICACE	iii
TABLE DES MATIÈRES	iv
LISTES DES FIGURES	vii
LISTES DES TABLEAUX.....	x
LISTE DES SIGLES ET ABRÉVIATIONS	xi
RÉSUMÉ	xiii
CHAPITRE 1 : INTRODUCTION GÉNÉRALE.....	1
1.1. Contexte de l'étude	1
1.2. Problématique	3
1.3. Objectifs	5
1.3.1. Objectif principal	5
1.3.2. Objectifs spécifiques	5
1.4. Hypothèses de la recherche	7
1.5. Retombées du projet.....	8
1.6. Originalité de la recherche	8
CHAPITRE 2 : CONTEXTE DE BASE ET REVUE DE LA LITTÉRATURE ...	10
2.1. Généralités.....	10
2.2. Contexte de base	11
2.2.1. Révolution industrielle et la maintenance 4.0	11
2.2.2. La maintenance industrielle	12
2.2.3. Structure d'une approche de maintenance prédictive basée sur les données	12
2.3. Revue de la littérature	17

2.3.1. Approches de maintenance prédictive des convoyeurs miniers.....	18
2.3.2. Approches de maintenance prédictive des camions miniers.....	22
2.4. Synthèse	25
CHAPITRE 3 : MÉTHODOLOGIE DE RECHERCHE	26
3.1. Introduction	26
3.2. Démarche de recherche	26
3.3. Méthodologie pour la prédiction de défaillance d'un réducteur de convoyeur	27
3.3.1. Collecte des données	28
3.3.2. Prétraitement des données.....	29
3.3.3. Approche basée sur le RNN pour la maintenance prévisionnelle.....	31
3.3.4. Détection des anomalies.....	39
3.4. Méthodologie pour la maintenance 4.0 des camions miniers	43
3.4.1. Collecte des données de télémétrie	44
3.4.2. Prétraitement et gestion des données de télémétrie.....	45
3.4.3. Digitalisation des données de maintenance	47
3.4.4. Détection d'anomalies avec le modèle SR-CNN	47
3.4.5. Modèle prévisionnel.....	50
3.4.6. Indicateurs de performance pour la gestion des camions miniers.....	54
3.5. Conclusion	59
CHAPITRE 4 : RÉSULTATS.....	60
4.1. Introduction	60
4.2. Développement d'un modèle de prédiction des défaillances dans un réducteur de convoyeur	60
4.2.1. Mise en contexte	60

4.2.2.	Collecte et préparation des données	62
4.2.3.	Analyse préliminaire	65
4.2.4.	Validation de l'interdépendance entre les paramètres d'états	67
4.2.5.	Développement du modèle du RNN	68
4.3.	Digitalisation et prévision de la maintenance des camions miniers.....	77
4.3.1.	Mise en contexte	77
4.3.2.	Collecte et préparation des données	78
4.3.3.	Analyse exploratoire des données de télémétrie	85
4.3.4.	Détection d'anomalies dans les données de télémétrie	91
4.3.5.	Prévision des séries temporelles avec le modèle Holt-Winters.....	95
4.3.6.	Conception des tableaux de bord interactifs	100
4.4.	Conclusion	104
CHAPITRE 5 : CONCLUSION GÉNÉRALE ET PERSPECTIVES		105
RÉFÉRENCES BIBLIOGRAPHIQUES		108

LISTES DES FIGURES

Figure 2.1 L'évolution industrielle [16]	12
Figure 2.2 Les étapes principales de création d'un modèle de prédiction	14
Figure 2.3 Caractéristiques des données collectées [22].....	14
Figure 2.4 Classification des techniques d'apprentissage automatique.....	16
Figure 2.5 Test du robot ROSI sur le port CPBS de VALE : (a) Déplacement sur terrain boueux, (b) Négociation d'obstacles [27]	19
Figure 2.6 Abrasion de la courroie due aux interactions avec la structure du convoyeur et ses composants [28]	20
Figure 2.7 Méthodologie d'extraction de signaux TSA [30]	21
Figure 2.8 Influence de l'usure des dents d'engrenage sur la dynamique des vibrations du réducteur [31]	21
Figure 2.9 Armoire HMI pour la surveillance et la maintenance en temps réel	25
Figure 3.1 Méthodologie appliquée sur le convoyeur des minerais.....	28
Figure 3.2 Architecture des types de RNN [56]	33
Figure 3.3 Fonctionnement des couches LSTM dans l'architecture RNN [56].....	34
Figure 3.4 Détection des anomalies par le facteur aberrant local [61].....	40
Figure 3.5 Détection des anomalies par la forêt d'isolement [63]	42
Figure 3.6 Méthodologie de flux de données et indicateurs clés de la maintenance prédictive des camions miniers	44
Figure 3.7 Processus de collecte des données de télémétrie	45
Figure 3.8 Flux de prétraitement et gestion des données de télémétrie	46
Figure 3.9 Digitalisation des données de maintenance en tableaux de bord interactifs.....	47
Figure 4.1 Schéma du processus de traitement des minerais [68]	61
Figure 4.2 Système d'entraînement : (a) Accouplement moteur/réducteur et (b) Emplacement des capteurs	62
Figure 4.3 Données historiques de maintenance du convoyeur.....	63
Figure 4.4 Extraction des données en temps réel à partir d'un requête SQL.....	64
Figure 4.5 Interface d'OpenRefine pour le nettoyage des données collectées	65

Figure 4.6 Tête de Pareto des pièces de rechange pour l'année 2023 en CA\$	66
Figure 4.7 Variation de la température avant et après le changement du réducteur	67
Figure 4.8 Matrice de corrélations des mesures des capteurs	68
Figure 4.9 Architecture de réseau neuronal pour la prédiction des données de vibration	69
Figure 4.10 L'évolution de la perte entre les données d'entraînement et de validation.....	70
Figure 4.11 Données de vibration réelles et prédites en fonction du temps et les maintenances effectuées.....	72
Figure 4.12 Détections des anomalies à partir de deux méthodes : (a) Local Outlier Factor, (b) la forêt d'isolement	75
Figure 4.13 (a) Usure des pneus ; (b) Dysfonctionnement du système hydraulique de propulsion.....	77
Figure 4.14 Vue éclatée des composants de la pompe hydraulique, incluant la boîte d'engrenage de transmission.....	79
Figure 4.15 Extrait du fichier CSV des opérations de maintenance et des outils requis	81
Figure 4.16 Résultats de la préparation des données télémétriques dans Power Query.....	85
Figure 4.17 Statistiques descriptives des données opérationnelles.....	86
Figure 4.18 Évolution temporelle des vibrations : (a) données brutes et (b) moyennes lissées	87
Figure 4.19 Variation moyenne de la rotation de la boîte d'engrenage en fonction du temps	88
Figure 4.20 Pression moyenne du système hydraulique (Pa) au cours du temps ..	88
Figure 4.21 Fluctuations du voltage moyen (V) au cours du temps	89
Figure 4.22 Matrice de dispersion et distributions des paramètres opérationnels ..	90
Figure 4.23 Analyse hiérarchique des anomalies dans les données de vibration...	92
Figure 4.24 Détection des anomalies de vibration avec seuil de 93 %.....	93

Figure 4.25 Détection des anomalies dans les paramètres opérationnels : (a) rotation, (b) pression et (c) voltage	94
Figure 4.26 Prévission des vibrations basée sur le modèle Holt-Winters	97
Figure 4.27 Prévisions des paramètres opérationnels à l'aide du modèle Holt-Winters – (a) Rotation, (b) Pression, (c) Voltage	98
Figure 4.28 Modélisation relationnelle des données.....	101
Figure 4.29 Tableau de bord interactif pour l'installation du système d'entraînement.....	102
Figure 4.30 Tableau de bord interactif des paramètres et défaillances	103

LISTES DES TABLEAUX

Tableau 4.1 Hyperparamètres optimisés du modèle RNN	73
Tableau 4.2 Hyperparamètres optimisés des modèles LOF et IF.....	76
Tableau 4.3 Étapes de maintenance et description des composants.....	80
Tableau 4.4 Paramètres opérationnels de la boîte d'engrenage	82
Tableau 4.5 Composants défaillants de la boîte d'engrenages par machine.....	83
Tableau 4.6 Liste des erreurs identifiées par machine	83
Tableau 4.7 Informations sur les modèles et l'ancienneté des camions miniers....	84
Tableau 4.8 Comparaison des paramètres de réglage Holt-Winters	99

LISTE DES SIGLES ET ABRÉVIATIONS

AA : Apprentissage automatique

CIL : Apprentissage par déséquilibre de classe

CNN : Réseau de neurones convolutifs

DAX : Expression d'analyse de données

ERP : Planification des ressources d'entreprise

GRU : Unité récurrente à portes

GMAO : Gestion de maintenance assistée par ordinateur

HMI : Interface homme-machine

IA : Intelligence artificielle

IF : Forêt d'isolement (Modèle de détection d'anomalies)

IIoT : Internet des objets industriels

IOT : Internet des objets

KNN : Algorithme des k plus proches voisins

KPI : Indicateur clé de performance

LOF : Facteur local d'anomalie

LSTM : Mémoire à long court terme (Type de réseau de neurones récurrents)

MAE : Erreur absolue moyenne

MAPE : Erreur de pourcentage absolue moyenne

ML : Apprentissage machine

MSE : Erreur quadratique moyenne

MTBF : Temps moyen entre pannes

MTTR : Temps moyen de réparation

OEE : Efficacité globale des équipements

PdM : Maintenance prédictive

PI SQL : Langage SQL pour l'information des procédés

PIB : Produit intérieur brut

RF : Forêt aléatoire (Algorithme d'apprentissage automatique)

R² : Coefficient de détermination

RMSE : Erreur quadratique moyenne racine

RNN : Réseau de neurones récurrents

ROI : Retour sur investissement

RUL : Durée de vie restante

SAG : Broyage semi-autogène

SCADA : Système de contrôle et d'acquisition de données

SNN : Réseau de neurones impulsionnels

SR-CNN : Réseau neuronal convolutif de super-résolution

TSA : Moyenne synchrone temporelle

VAE : Autoencodeur Variationnel

RÉSUMÉ

Les convoyeurs de transport de minerais et les camions miniers sont des équipements stratégiques dans l'industrie minière, assurant l'acheminement continu des matériaux extraits à travers les différentes étapes du processus de production. Toutefois, en raison des conditions d'exploitation extrêmes – températures élevées, humidité, terrains accidentés – ces équipements sont particulièrement exposés aux défaillances, pouvant entraîner des interruptions de production coûteuses, des pertes financières et des risques accrus pour la sécurité des travailleurs.

Cette étude propose une approche de maintenance prédictive alliant apprentissage automatique et digitalisation des données industrielles. Deux volets ont été développés : la prédiction des défaillances des convoyeurs et l'optimisation de la maintenance des camions miniers sur Power BI. Dans le premier volet, les défaillances potentielles des convoyeurs ont été analysées à partir de rapports d'inspection, d'actions correctives et de mesures de capteurs (vibrations, température et vitesse de rotation). Les réseaux de neurones récurrents (RNN) avec couches LSTM ont été utilisés pour la prévision des séries temporelles, tandis que les modèles LOF et IF ont permis d'identifier les anomalies. Les performances des prédictions ont été évaluées via l'erreur quadratique moyenne (RMSE), confirmant l'efficacité des RNN pour anticiper les dysfonctionnements. Le second volet repose sur la digitalisation des données de maintenance des camions miniers grâce à Power BI. Un tableau de bord interactif a été conçu pour structurer et analyser les données en temps réel, offrant une meilleure visibilité des tendances et optimisant les décisions de maintenance. L'intégration de modèles de prévision tels que Holt-Winters a permis d'anticiper les pannes critiques et d'améliorer la gestion des équipements. De plus, l'analyse des tendances a facilité l'optimisation des stocks et des interventions, réduisant ainsi les coûts et minimisant les interruptions des opérations.

Les résultats obtenus démontrent que l'association des modèles prédictifs avancés et des outils de visualisation interactive améliore la prise de décision en maintenance, réduit les interruptions imprévues et contribue à une gestion plus efficace des actifs miniers. Cette approche marque une avancée vers la maintenance intelligente et automatisée dans un environnement industriel exigeant.

Mots clés : Défaillances mécaniques, Maintenance prédictive, Réseaux de Neurones Récurrents, Détection d'anomalies, Digitalisation, Power BI

CHAPITRE 1 : INTRODUCTION GÉNÉRALE

1.1. Contexte de l'étude

L'industrie minière est un pilier fondamental de l'économie mondiale, jouant un rôle essentiel dans le développement économique de nombreux pays. Par exemple, en Australie, le secteur minier a généré un revenu d'exportation record de 455 milliards de dollars pour l'année financière 2022-2023, ce qui représente 66 % des revenus d'exportation du pays. Les principales exportations comprennent le charbon, le minerai de fer, l'or, l'aluminium et le cuivre, avec une croissance notable dans les métaux technologiques tels que le nickel, le zinc et le cuivre [1].

Au Canada, l'industrie minière a contribué 125 milliards de dollars au PIB en 2021, soit 5 % du PIB total. Le secteur est également un employeur majeur, fournissant 665 000 emplois à travers le pays et étant le plus grand employeur privé de peuples autochtones [2]. Le Canada, en tant que l'un des producteurs de minéraux et métaux les plus respectueux de l'environnement au monde, joue un rôle clé dans la transition énergétique mondiale en fournissant les matériaux nécessaires pour les technologies propres et durables.

L'exploitation minière implique l'utilisation de machines et d'équipements lourds dans des conditions extrêmes, ce qui entraîne une usure rapide et des défaillances fréquentes. Les réducteurs de convoyeurs de minerais et les camions miniers sont particulièrement sujets à ces défaillances, pouvant entraîner des arrêts de production coûteux et des pertes financières importantes [3, 4]. Les coûts de maintenance dans le secteur minier représentent généralement entre 30 % et 50 % des coûts opérationnels totaux d'une mine, et peuvent être encore plus élevés dans certains cas [5, 6]. Les machines lourdes, telles que les convoyeurs de transport et les camions miniers, doivent fonctionner dans des environnements difficiles, ce qui augmente les risques de défaillances mécaniques. Par exemple, les coûts de maintenance des équipements miniers peuvent représenter jusqu'à 75 % du coût initial de la machine sur toute sa durée de vie. Les équipements lourds tels que les

excavateurs hydrauliques peuvent coûter entre 950 000 et 1 650 000 USD, avec des coûts de maintenance élevés dus à la nécessité de réparations fréquentes et au besoin de techniciens hautement qualifiés pour effectuer ces réparations sur place [7, 8].

Les entreprises minières investissent de plus en plus dans la maintenance prédictive et la surveillance conditionnelle pour réduire ces coûts. Par exemple, la maintenance prédictive basée sur la surveillance des vibrations peut réduire les pannes d'équipement de 70 à 75 %, diminuant ainsi les coûts de maintenance de 5 à 10 % [6].

Avec l'avènement de l'industrie 4.0, de nouvelles technologies telles que l'intelligence artificielle (IA) et l'apprentissage automatique (AA) offrent des opportunités pour améliorer les pratiques de maintenance. Ces technologies permettent de développer des modèles prédictifs capables de détecter les signes avant-coureurs de défaillances mécaniques, permettant ainsi des interventions préventives et une réduction des temps d'arrêt non planifiés. La maintenance prédictive utilise des techniques telles que la surveillance par vibration pour détecter les défaillances potentielles avant qu'elles ne se produisent [9]. Par exemple, des capteurs de vibration peuvent identifier des anomalies dans les convoyeurs de transport de minerais et les systèmes de puissance d'un camion miniers, ce qui permet de planifier des interventions de maintenance avant que les pannes ne surviennent. Cette approche réduit non seulement les coûts de maintenance, mais améliore également la sécurité des opérations en prévenant les défaillances catastrophiques. Les modèles prédictifs basés sur l'IA et l'AA analysent de grandes quantités de données provenant de capteurs installés sur les équipements. Ces modèles peuvent apprendre des historiques de maintenance et des manuels des équipements pour identifier des schémas de défaillance et prévoir quand une pièce risque de tomber en panne. Par exemple, une analyse de la relation entre les paramètres géométriques et les défaillances des convoyeurs de transport de minerais a montré que la surveillance conditionnelle peut prévenir les pannes coûteuses et améliorer l'efficacité des opérations [10].

À ce jour, les avantages d'une approche proactive par rapport à une approche réactive n'ont pas été pleinement démontrés. Toutefois, cela pourrait être dû à l'insuffisance des modèles d'évaluation utilisés jusqu'à présent. Les technologies de maintenance prédictive offrent des solutions prometteuses pour améliorer la fiabilité et l'efficacité des équipements miniers, mais leur mise en œuvre nécessite des investissements en infrastructure et en formation du personnel. En intégrant ces technologies, l'industrie minière peut non seulement augmenter l'efficacité opérationnelle, mais aussi améliorer la durabilité et la sécurité des opérations. La maintenance 4.0, qui intègre des systèmes de surveillance conditionnelle et des modèles prédictifs basés sur l'IA, représente donc un levier stratégique pour optimiser la gestion des équipements et répondre aux défis environnementaux et économiques actuels. Les avantages incluent la réduction des coûts de maintenance, l'augmentation de la durée de vie des équipements, et une meilleure gestion des ressources humaines et matérielles.

1.2. Problématique

L'industrie minière, notamment dans le cadre des convoyeurs de transport de minerais et des camions miniers, fait face à des défis majeurs en matière de maintenance et de gestion des équipements. Ces défis sont exacerbés par les conditions d'exploitation extrêmes, telles que des températures élevées, une forte humidité et des environnements poussiéreux, qui entraînent une usure rapide et des défaillances fréquentes des équipements. Ces défaillances peuvent causer des arrêts de production coûteux, des pertes financières importantes, et des risques pour la sécurité des travailleurs.

Au sein de cette étude dédiée à l'optimisation de l'efficacité et à l'assurance de la fiabilité du processus de traitement des minerais, un élément central se dégage : le convoyeur, situé au cœur du circuit, joue un rôle essentiel dans le bon fonctionnement des équipements en amont et en aval. Ce système est composé d'un moteur asynchrone couplé à un réducteur à plusieurs étages, fournissant un couple spécifique pour entraîner la chaîne de transport. Des capteurs et des sondes

judicieusement positionnés surveillent en permanence l'état de ce dispositif. Ces instruments enregistrent divers paramètres, tels que les désalignements, le débit, la consommation électrique, ainsi que des indicateurs critiques comme les vibrations et la température. L'arrêt de ce convoyeur est fréquemment provoqué par la défaillance de différentes composantes et systèmes qui le composent. Cette défaillance est principalement attribuable à des vibrations excessives pendant le fonctionnement, entraînant l'usure de la bande transporteuse guidée par des galets corrodés, un tonnage de minerais dépassant les limites de résistance, ainsi que des problèmes d'alignement au niveau des accouplements dans le système de transmission moteur-réducteur [11]. En cas de défaillance grave non détectée rapidement, cela peut entraîner des dommages irréparables aux équipements, entraînant des réparations coûteuses et une interruption significative de la production. Pour les camions miniers, les défis de maintenance sont tout aussi importants. Ces véhicules subissent une usure rapide des pneus en raison des terrains accidentés et des charges lourdes qu'ils transportent [12]. De plus, la consommation de carburant est un facteur critique [13], car les moteurs doivent fonctionner à des niveaux élevés d'efficacité pour maintenir les opérations économiques. Une surveillance en temps réel de l'état des pneus et de la consommation de carburant est essentielle pour prévenir les pannes et optimiser les performances. Des capteurs installés sur les camions peuvent fournir des données continues sur ces paramètres, permettant des interventions de maintenance préventive et l'application de protocoles d'aide à la décision pour améliorer l'efficacité opérationnelle. De manière générale, une flotte d'exploitation à ciel ouvert comprend entre 50 et 70 camions de transport, 10 à 20 excavatrices et 10 à 15 unités de soutien. Les coûts annuels d'investissement et d'exploitation de ces vastes flottes peuvent atteindre plusieurs centaines de millions de dollars [14].

Pour relever les défis de la maintenance des convoyeurs de transport de minerais et des camions miniers, il est essentiel de passer d'une maintenance réactive à une maintenance prédictive. Cette transition repose sur la surveillance conditionnelle, où des capteurs surveillent en temps réel l'état des équipements et détectent les anomalies avant qu'elles ne provoquent des pannes, par exemple, des capteurs de

vibration pour les convoyeurs et les camions. Le développement de modèles prédictifs basés sur l'IA et l'apprentissage automatique est crucial pour analyser les données des capteurs, utilisant les historiques de maintenance pour prévoir les défaillances et planifier des interventions préventives. La mise en place de bases de données informatisées pour collecter et analyser ces données, ainsi que la formation des techniciens, est indispensable pour une transition réussie. Après le développement de ces outils de prédiction, ils peuvent être intégrés dans des plateformes numériques comme des systèmes de gestion d'entreprise (ERP). La numérisation des modèles de calcul fournit diverses solutions pour surmonter les contraintes de production. En adoptant ces solutions numériques, les entreprises industrielles peuvent optimiser la gestion de leur maintenance et de leurs données, tout en maintenant leur compétitivité sur le marché.

1.3. Objectifs

Les objectifs de ce projet sont subdivisés en deux catégories :

1.3.1. Objectif principal

L'objectif principal de ce projet est de développer une approche avancée de maintenance prédictive en combinant l'apprentissage automatique et la digitalisation des données. Il vise, d'une part, à concevoir un modèle de prédiction des défaillances mécaniques pour les convoyeurs de transport de minerais et, d'autre part, à optimiser la gestion de la maintenance des camions miniers à travers une digitalisation des données et l'exploitation d'un tableau de bord interactif sur Power BI.

1.3.2. Objectifs spécifiques

- i. Développement d'un modèle prédictif et de détection des anomalies pour les convoyeurs de transport de minerais
- Concevoir et implémenter un modèle de prédiction des défaillances mécaniques des réducteurs de convoyeurs, en exploitant les données de capteurs et les historiques de maintenance.

- Intégrer des modèles avancés de détection d'anomalies, notamment LOF et IF, pour identifier les signes précoces de défaillance.
- Valider la performance des modèles en s'appuyant sur des données réelles afin d'assurer leur précision et leur fiabilité dans un environnement opérationnel.

ii. Digitalisation et optimisation de la maintenance des camions miniers

- Développer des protocoles d'aide à la décision pour optimiser la maintenance préventive des camions miniers, en réduisant les temps d'arrêt et les coûts opérationnels.
- Intégrer des modèles de prévision, tels que Holt-Winters, pour anticiper les pannes critiques et améliorer la gestion des équipements.
- Exploiter les données de télémétrie pour affiner la prise de décision et optimiser les stratégies de maintenance conditionnelle et préventive.
- Concevoir un tableau de bord interactif sur Power BI pour structurer, analyser et visualiser en temps réel les données de maintenance des camions miniers.

iii. Optimisation de la maintenance préventive :

- Établir des programmes de maintenance préventive basés sur les prédictions du modèle pour les convoyeurs de transport de minerais et les camions miniers.
- Renforcer les compétences des équipes de maintenance en les formant à l'utilisation des outils analytiques et à l'interprétation des indicateurs de performance.

iv. Intégration et gestion des données :

- Mettre en place une infrastructure de gestion des données robuste pour collecter, stocker et analyser les informations provenant des capteurs et des systèmes de surveillance.
- Utiliser des bases de données avancées et des outils de mégadonnées pour traiter les informations et extraire des perspectives exploitables.
- Évaluer les performances des modèles développés à travers des métriques pertinentes (RMSE, MAPE, R^2) afin d'améliorer continuellement la précision des prévisions.

1.4. Hypothèses de la recherche

Pour le développement et la mise en œuvre de la stratégie de maintenance prédictive des convoyeurs de transport de minerais et des camions miniers, les hypothèses suivantes ont été formulées :

➤ **Hypothèses pour la prédiction des défaillances dans un réducteur de convoyeur de minerais :**

- Les variables mesurées via des capteurs sont appropriées et reflètent fidèlement les performances et l'état de santé des convoyeurs.
- Les données collectées via PI SQL ou autres systèmes de gestion de données sont représentatifs et fiables, couvrant l'ensemble des situations de fonctionnement.
- L'exclusion de certains composants, tels que la courroie du convoyeur, dans l'étude est justifiée en raison du manque de données disponibles sur ces équipements.
- L'adaptation des modèles prédictifs doit tenir compte des spécificités techniques et opérationnelles du réducteur afin d'optimiser la précision des prévisions et d'améliorer la maintenance prédictive.
- Le choix de la méthode d'apprentissage automatique dépend de la nature des données des bases disponibles.
- Les résultats de l'étude doivent faire l'objet d'une validation au moyen de données indépendantes pour assurer leur précision et leur fiabilité.
- La performance des algorithmes dépend de la qualité de la base de données.

➤ **Hypothèses pour la digitalisation et la prévision des données de maintenance des camions miniers sur Power BI :**

- Les données de maintenance et de télémétrie des camions miniers sont suffisamment complètes et précises pour permettre la modélisation efficace des tendances et des prévisions.
- L'intégration des modèles de prévision Holt-Winters sur Power BI permet d'anticiper les pannes critiques et d'améliorer l'efficacité des stratégies de maintenance.

- Un tableau de bord interactif structuré sous Power BI facilite l'exploitation des données en temps réel, améliorant ainsi la prise de décision et la gestion des interventions de maintenance.
- Il existe une corrélation mesurable entre les indicateurs de télémétrie (vibration, pression, rotation) et les pannes enregistrées, ce qui permet d'affiner les modèles de prévision et d'optimiser la planification des interventions.
- L'analyse des tendances des pannes permet d'améliorer la maintenance conditionnelle et prédictive, en réduisant les coûts opérationnels et en augmentant la disponibilité des équipements.

1.5. Retombées du projet

La mise en place d'une stratégie de maintenance prédictive pour les convoyeurs de transport de minerais et les camions miniers apportera plusieurs avantages. Elle réduira les temps d'arrêt imprévus et optimisera les interventions de maintenance, augmentant ainsi l'efficacité opérationnelle. En anticipant les pannes, les coûts de maintenance seront réduits, et la durée de vie des équipements prolongée, entraînant des économies substantielles. De plus, la sécurité des travailleurs sera améliorée grâce à la détection précoce des anomalies, réduisant les risques d'accident. Enfin, l'adoption de technologies avancées et la formation des techniciens renforceront les compétences des équipes, tout en permettant aux entreprises de rester compétitives et innovantes.

1.6. Originalité de la recherche

Cette recherche se distingue par son approche novatrice en matière de maintenance prédictive appliquée aux convoyeurs de transport de minerais et aux camions miniers, deux équipements essentiels dans l'industrie minière. Elle intègre des technologies de pointe, telles que des capteurs pour la surveillance en temps réel et des algorithmes prédictifs basés sur l'intelligence artificielle et l'apprentissage automatique. Adaptée aux conditions d'exploitation extrêmes du Canada, cette étude prend en compte les défis uniques rencontrés dans les mines canadiennes, notamment les températures très basses et les terrains difficiles. En mettant l'accent

sur la fiabilité des équipements, l'efficacité opérationnelle, et la réduction des coûts de maintenance, cette recherche vise à améliorer significativement la productivité et la rentabilité des mines. De plus, elle inclut la formation des techniciens de maintenance aux nouvelles technologies, contribuant ainsi à la montée en compétences du personnel et à l'adaptation de la main-d'œuvre aux exigences de l'industrie 4.0. Par ailleurs, l'approche prédictive renforce la gestion environnementale en anticipant et évitant les défaillances catastrophiques. En fin de compte, cette recherche positionne le Canada comme un leader en innovation technologique dans le secteur minier, en développant des solutions numériques avancées qui peuvent être adoptées à l'échelle mondiale.

CHAPITRE 2 : CONTEXTE DE BASE ET REVUE DE LA LITTÉRATURE

2.1. Généralités

Les convoyeurs de transport de minerais et les camions miniers sont des composants essentiels de l'industrie minière, assurant le déplacement continu des matériaux extraits entre les différentes étapes du processus de production. Les convoyeurs, constitués de bandes transporteuses motorisées, de moteurs asynchrones couplés à des réducteurs, et de capteurs divers, transportent les minerais bruts des sites d'extraction vers les zones de traitement. Les camions miniers, quant à eux, sont des véhicules lourds conçus pour transporter de grandes quantités de matériaux sur des terrains difficiles. Ils sont équipés de moteurs puissants, de systèmes de suspension robustes, et de pneus résistants pour faire face aux conditions extrêmes. L'environnement de travail dans les mines est particulièrement exigeant, avec des températures extrêmes, une forte humidité, et des terrains accidentés et poussiéreux. Ces conditions sévères accélèrent l'usure des composants des convoyeurs et des camions, augmentant les risques de défaillances mécaniques. Par exemple, les vibrations excessives et les désalignements peuvent entraîner une usure prématurée des bandes transporteuses et des roulements des convoyeurs, tandis que les terrains accidentés provoquent une dégradation rapide des pneus et des systèmes de suspension des camions miniers. Pour répondre à ces défis, l'évolution industrielle a introduit la maintenance 4.0, qui intègre des techniques d'apprentissage automatique et des méthodes de gestion avancée de la maintenance. Cette approche permet de prédire et de détecter les anomalies de manière proactive, en utilisant des technologies de surveillance en temps réel et des modèles prédictifs basés sur l'intelligence artificielle (IA) et l'apprentissage automatique (AA). Grâce à ces outils, les entreprises peuvent mettre en place des protocoles d'aide à la décision qui optimisent les interventions de maintenance, réduisent les temps d'arrêt et améliorent la fiabilité et l'efficacité opérationnelle des équipements miniers.

2.2. Contexte de base

L'objectif de cette section est de fournir un aperçu concis des principaux concepts de base en lien avec la maintenance prédictive.

2.2.1. Révolution industrielle et la maintenance 4.0

L'idée de l'Industrie 4.0 a émergé pour la première fois en 2011, visant à améliorer l'efficacité de l'industrie manufacturière face à la complexité croissante des processus industriels, aux demandes personnalisées des clients et à la concurrence accrue sur le marché international. L'Industrie 4.0 intègre des technologies avancées telles que l'Internet des Objets (IoT), les mégadonnées et l'intelligence artificielle (IA), y compris l'apprentissage automatique, pour transformer les systèmes de fabrication et les rendre plus adaptatifs et efficaces [15]. Historiquement, trois grandes révolutions industrielles ont précédé la quatrième phase actuelle. La première révolution industrielle, survenue à la fin du XVIIIe siècle, a été caractérisée par la mécanisation. La deuxième révolution industrielle, à la fin du XIXe siècle, a été définie par l'électrification. Enfin, la troisième révolution industrielle, à partir des années 1970, a été marquée par l'automatisation et la mondialisation. Cette phase a vu l'introduction de l'électronique, des technologies de l'information et des systèmes automatisés, intégrant des innovations technologiques dans les processus de production et ouvrant la voie à la globalisation des marchés et des chaînes de valeur. La Figure 2.1 montre clairement ces révolutions.




Figure 2.1 L'évolution industrielle [16]

Dans l'industrie minière, l'évolution vers l'Industrie 4.0 se manifeste à plusieurs niveaux, notamment dans les opérations de maintenance des équipements.

2.2.2. La maintenance industrielle

D'après la norme AFNOR (NF X 60 010), la maintenance est définie comme un « ensemble des actions permettant de maintenir ou de rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé ». Les activités de maintenance nécessitent des interventions sur des équipements complexes et variés, impliquant des connaissances approfondies en sciences et techniques relatives aux systèmes, produits, processus, matériels et logiciels, ainsi qu'à leur fonctionnement et aux interactions entre eux. Dans tous les secteurs, il est crucial pour les industriels de prendre en compte les coûts et les impacts potentiels des défaillances soudaines, car la productivité dépend largement de l'efficacité des processus de maintenance.

2.2.3. Structure d'une approche de maintenance prédictive basée sur les données

La maintenance prédictive basée sur les données est une approche proactive qui utilise des technologies avancées pour anticiper les défaillances des équipements avant qu'elles ne surviennent. Pour mettre en œuvre une stratégie de maintenance prédictive, il est essentiel d'installer des capteurs connectés qui mesurent en continu les paramètres de fonctionnement des équipements concernés. Ces capteurs

permettent de collecter des données précises et en temps réel, facilitant ainsi l'analyse et la prédiction des pannes potentielles. Ces vastes ensembles de données soutiennent les technologies avancées d'analyse des données, l'apprentissage automatique (ML) et l'internet des objets industriel (IIoT) pour diagnostiquer les pannes et prédire les besoins de maintenance [17]. L'application de stratégies de maintenance prédictive (PdM) pour analyser la mégadonnées industrielle permet de prévenir les pannes imprévues et les interruptions de production. Ces méthodes permettent également de planifier la mise hors ligne des machines pour des opérations de maintenance spécifiques, optimisant ainsi la gestion des équipements [18]. Le modèle prédictif identifiera progressivement des corrélations entre certaines données reçues et les pannes. Il apprendra ainsi à reconnaître que des valeurs spécifiques mesurées précèdent certains types de défaillances. Dès que ces valeurs seront à nouveau détectées, le modèle pourra planifier une intervention de maintenance proactive, permettant ainsi de prévenir l'apparition de la panne.

Pour chaque phase de construction, il existe une variété d'outils disponibles, chacun étant spécialement adapté à des caractéristiques spécifiques, dépendant de l'équipement et du secteur d'activité de l'industrie. Hafsi et al. [19] ont proposé une feuille de route hybride qui met en lumière les défis liés à la gestion des projets de prédiction des pannes, couvrant à la fois les aspects de mise en œuvre et les cas d'utilisation. Après avoir sélectionné les différentes technologies à utiliser, il est impératif de passer à l'étape suivante : le développement du modèle de maintenance prédictive. Cette démarche se décompose en quatre étapes clés. Premièrement, il s'agit de collecter les données relatives aux équipements, puis de les analyser pour les classer en états normaux et anormaux. La deuxième étape consiste à modéliser l'algorithme d'identification des anomalies et les catégoriser en fonction d'un historique des pannes. Ensuite, le modèle prédictif doit être développé pour apprendre à reconnaître les nouveaux événements et défaillances lorsqu'ils se produisent. Enfin, il est essentiel d'adapter le système pour qu'il puisse mettre à jour sa base de données en fonction des nouvelles informations collectées sur le matériel. Le développement de modèle. La création de modèles prédictifs peut être structurée

en cinq étapes principales, comme illustrées dans le schéma tiré de MathWorks [20] de la Figure 2.2.




Figure 2.2 Les étapes principales de création d'un modèle de prédiction

2.2.3.1. Caractéristiques et qualité des données collectées

Pour évaluer l'efficacité de la méthode PdM, il est fondamental de considérer l'état des données collectées. Comme illustré par la Figure 2.3, la méthode PdM s'aligne souvent avec les 5 V des mégadonnées : vitesse, véracité, valeur, volume et variété [21].




Figure 2.3 Caractéristiques des données collectées [22]

Pour répondre efficacement aux exigences d'un environnement industriel, l'architecture des systèmes joue un rôle déterminant, notamment en ce qui concerne le volume, la vitesse et la variété des données. Les capteurs et les dispositifs industriels génèrent une quantité massive de données (volume) de différents types,

comme des images, des vidéos et des textes (variété), à un rythme élevé nécessitant une analyse en temps réel ou quasi réel (vélocité). Le volume est essentiel pour le développement des modèles prédictifs, car ceux-ci requièrent généralement de vastes ensembles de données pour être correctement entraînés. La vitesse est également primordiale pour collecter et traiter les données rapidement, permettant ainsi de prévoir les problèmes à temps pour planifier les actions appropriées. La véracité, qui désigne la précision et la fiabilité des données [23], est vitale à PdM, car les capteurs opèrent souvent dans des conditions difficiles et peuvent produire des données erronées. Dans ce contexte, la détection des anomalies joue un rôle important en identifiant ces erreurs et en améliorant les performances des méthodes de pronostic. Enfin, la valeur représente les informations précieuses extraites des données, ce qui dépend fortement des méthodes utilisées pour déterminer la durée de vie restante (RUL) et détecter les anomalies, car elles permettent d'extraire des connaissances et de la valeur des données.

2.2.3.2. Prétraitement des données et extractions des caractéristiques

Le prétraitement des données et l'extraction des caractéristiques sont des étapes essentielles dans le processus de maintenance prédictive. Ces étapes permettent de transformer les données brutes collectées par les capteurs en informations exploitables pour l'analyse et la modélisation prédictive. Le nettoyage des données est une phase importante dans le processus de traitement des données basée sur l'élimination des valeurs aberrantes et le remplissage des valeurs manquantes par des méthodes appropriées telles que l'interpolation ou l'imputation [24]. Ainsi une deuxième phase de normalisation permet de transformer les différentes variables sur des échelles communes, facilitant ainsi la comparaison et l'analyse. Shiqi et al. [25] ont introduit la technique de clustering des plus proches voisins (SNN) pour résoudre le problème de l'apprentissage par déséquilibre de classe (CIL). Ensuite, une phase d'analyse des données est nécessaire. Cette étape vise à identifier les tendances potentielles, à appliquer des tests statistiques appropriés et à présenter les données de manière graphique et numérique. L'objectif est de transformer les

données brutes en informations exploitables, permettant une meilleure compréhension et interprétation des résultats.

2.2.3.3. Modèle d'apprentissage automatique

En fonction du type de données disponibles lors de la phase de création du modèle, l'apprentissage automatique peut être classé de différentes manières. Après une analyse approfondie des données, l'étape suivante consiste à appliquer un modèle pour prédire les types de défauts. La plupart des modèles utilisés pour la maintenance prédictive reposent sur des méthodes statistiques ou des techniques d'intelligence artificielle. Il s'agit de deux types d'apprentissage automatique illustrés dans la Figure 2.4.




Figure 2.4 Classification des techniques d'apprentissage automatique

L'apprentissage supervisé est une branche de l'AA et de l'IA. Il se caractérise par l'utilisation d'ensembles de données étiquetés pour former des algorithmes capables de classer les données ou de prédire des résultats avec précision. En effet, les algorithmes sont formés en utilisant des ensembles de données d'entraînement où les entrées et les résultats souhaités sont connus à l'avance. Cette approche permet aux modèles de reconnaître des motifs et de faire des prédictions précises. La régression et la classification sont les techniques les plus couramment associées à

cette méthode d'apprentissage, comme souligné dans de nombreux articles scientifiques. En régression, le résultat attendu est une valeur numérique continue, tandis qu'en classification, le résultat est une catégorie discrète.

À l'opposé de l'apprentissage supervisé, qui vise à développer un modèle à partir de données étiquetées, l'apprentissage non supervisé cherche à identifier des structures et des relations sous-jacentes dans des ensembles de données non étiquetées. Cette approche utilise des algorithmes capables de découvrir des modèles cachés ou des groupements de données sans intervention humaine. Grâce à sa capacité à détecter les similitudes et les différences dans les informations, elle est idéale pour l'analyse exploratoire des données. Les principales méthodes employées dans ce cadre incluent la classification, l'agrégation et la réduction de la dimensionnalité.

2.2.3.4. Validation et déploiement du modèle

Une fois les résultats des modèles algorithmiques obtenus, ils sont intégrés à des techniques basées sur les connaissances pour améliorer la prise de décisions et l'élaboration de stratégies. Cette combinaison permet d'exploiter pleinement les informations dérivées des données et les expertises disponibles pour optimiser les résultats [26]. Des experts chevronnés de l'industrie examinent les modèles et les résultats, ce qui conduit à des améliorations des procédures d'exploitation, de maintenance, de surveillance, de test et d'audit afin d'assurer des actions plus sûres et plus efficaces. Par la suite, une phase de déploiement peut être mise en œuvre, constituant la dernière étape du flux de travail pour la conception d'un système de classification. Cette phase représente la mise en service opérationnelle du système.

2.3. Revue de la littérature

L'industrie minière repose fortement sur des équipements robustes et fiables, tels que les équipements tournants (pompes, moteurs, réducteurs, etc.) et les camions miniers, pour maintenir une production continue et efficace. Cette section examine les avancées et les recherches récentes sur la maintenance et l'optimisation de ces équipements critiques.

2.3.1. Approches de maintenance prédictive des convoyeurs miniers

La maintenance prédictive est de plus en plus valorisée au sein des groupes de recherche multidisciplinaires. Ces groupes se concentrent sur la création et l'intégration de systèmes complexes englobant l'acquisition de données, l'infrastructure, le stockage, la distribution, la sécurité et l'intelligence artificielle. D'importants efforts ont été déployés pour développer des méthodes fiables de détection des défauts. Cela inclut l'usage de technologies avancées pour analyser et interpréter les données en temps réel, permettant ainsi de prédire les pannes et d'optimiser les stratégies de maintenance. Dans ce contexte, on se concentre sur le convoyeur à bande pour le transport de minerais, un type d'équipement tournant. La fiabilité de ce système est d'une importance capitale pour les industries impliquées dans la manutention et le transport de matériaux en vrac. Cette fiabilité peut être perçue comme une fiabilité globale de ses divers composants, tels que la courroie, les poulies, l'unité d'entraînement et les rouleaux de renvoi. Garantir la fiabilité de chacun de ces éléments est essentiel pour assurer le bon fonctionnement du système dans son ensemble. Dans ce cadre, plusieurs approches sont proposées par des auteurs. Rocha et al. [27] ont démontré l'efficacité des systèmes robotiques autonomes pour les inspections, notamment à travers le développement d'un robot mobile conçu pour surveiller l'état des convoyeurs à bande, comme illustré dans la Figure 2.5.




Figure 2.5 Test du robot ROSI sur le port CPBS de VALE : (a) Déplacement sur terrain boueux, (b) Négociation d'obstacles [27]

Ce robot, muni de divers capteurs, collecte des données visuelles, thermiques et acoustiques durant les inspections. Grâce à l'utilisation d'algorithmes de réseaux de neurones convolutifs (CNN) et de forêts aléatoires (RF), le robot est capable d'identifier avec une grande précision des anomalies telles que les accumulations de saletés, les défaillances des rouleaux et les défauts de roulement. Dans une autre approche, Bortnowski et al. [28] ont souligné que les bruits et vibrations ne peuvent pas être directement considérés comme des signes de dommages physiques, mais plutôt comme des indicateurs précoces d'anomalies pouvant affecter le bon fonctionnement du convoyeur. L'apparition de bruits et de vibrations localisés est souvent associée à des perturbations du système, pouvant entraîner des dommages progressifs sur la bande transporteuse et ses composants. À titre d'illustration, plusieurs types de défauts fréquemment rencontrés sur les convoyeurs sont représentés dans la Figure 2.6.



Figure 2.6 Abrasion de la courroie due aux interactions avec la structure du convoyeur et ses composants [28]

Pour affiner la détection des anomalies, Yip et L. [29] ont proposé une approche basée sur le prétraitement des données de vibration synchrone dans le temps (TSA) afin d'extraire des indicateurs précis sur l'état du convoyeur. Cette méthodologie permet d'isoler les vibrations non synchrones avec l'impulsion du tachymètre, améliorant ainsi la fiabilité des diagnostics et la précision des interventions de maintenance. La Figure 2.7 illustre ce processus, où le signal de vibration est segmenté en fonction des impulsions du tachymètre, permettant une meilleure extraction des caractéristiques vibratoires liées aux défaillances.




Figure 2.7 Méthodologie d'extraction de signaux TSA [30]

Concernant les réducteurs utilisés dans les convoyeurs, Feng et al. [31] ont démontré que l'usure des engrenages peut entraîner une altération du profil des dents et une réduction de la surface de contact, modifiant ainsi les propriétés dynamiques du système (Figure 2.8). Ces changements provoquent une augmentation des forces de contact irrégulières, qui se traduisent par une hausse des vibrations et du bruit, deux indicateurs clés des défaillances en cours de formation.



Figure 2.8 Influence de l'usure des dents d'engrenage sur la dynamique des vibrations du réducteur [31]

Mark et al. [32] ont développé une approche fréquentielle visant à éliminer les perturbations induites par les transducteurs ainsi que les variations d'amplitude dues aux caractéristiques structurales des réducteurs. Cette technique permet d'améliorer l'interprétation des données vibratoires en réduisant les faux positifs et en optimisant l'analyse des défaillances.

Enfin, Mazurkiewicz [33] a développé un système expert à logique floue pour les joints de bande transporteuse basé sur des mesures et des données historiques. Alharbi et al. [34] ont effectué une revue récente portant sur la détection des défauts des rouleaux de convoyeurs à bande, en se basant sur les signaux acoustiques et vibratoires. Cette étude met en évidence l'utilisation de modèles d'apprentissage automatique (ML) pour améliorer la précision et l'efficacité de la détection des anomalies.

2.3.2. Approches de maintenance prédictive des camions miniers

Pour la maintenance prédictive des camions miniers, plusieurs approches ont été développées afin d'améliorer la détection des anomalies et l'optimisation des protocoles de maintenance. Ces méthodologies reposent sur l'intégration de technologies avancées telles que l'apprentissage automatique, les capteurs IoT et les systèmes de surveillance en temps réel, permettant ainsi d'identifier et d'anticiper les défaillances tout en renforçant l'efficacité et la fiabilité des opérations minières.

2.3.2.1. Suivi de l'état par l'apprentissage automatique

L'apprentissage supervisé, basé sur des techniques de classification et de régression, est couramment utilisé pour prédire des variables telles que l'occurrence de défaillances. Toutefois, ces modèles nécessitent des étapes préalables essentielles, notamment la normalisation des données, l'analyse des valeurs aberrantes et le traitement des données manquantes. À l'inverse, l'apprentissage non supervisé permet de regrouper les données en fonction de similitudes, sans dépendre d'une relation prédéfinie entre les entrées et les sorties [35-37].

Dans ce contexte, plusieurs études ont démontré l'efficacité des techniques d'intelligence artificielle pour la prédiction des pannes dans les camions miniers à partir des données de télémétrie. De plus, Aras et al. [38] ont comparé cinq algorithmes—Random Forest, Gradient Boosted Trees, K-Nearest Neighbors, Multilayer Perceptron et LightGBM—pour prédire la durée de vie restante et les pannes des équipements. Par ailleurs, Hébert et al. [39] ont appliqué des modèles basés sur les réseaux de neurones convolutifs (CNN) pour estimer les risques de défaillance à partir des données temporelles. De leur côté, Selvi et al. [40] ont utilisé des algorithmes de classification pour optimiser les stratégies de maintenance prédictive des systèmes de freinage des camions Scania, démontrant ainsi le potentiel des techniques de machine learning dans la gestion des véhicules miniers. Enfin, Sasanka et al. [41] ont réalisé une revue approfondie sur l'application de l'intelligence artificielle dans les camions lourds, en mettant en avant son rôle dans la prédiction de la consommation de carburant, l'estimation des émissions et l'amélioration des stratégies de maintenance prédictive.

2.3.2.2. Technologie de la télémétrie dans l'industrie minière

Dans l'industrie minière moderne, la télémétrie est essentielle pour optimiser la maintenance et la gestion des flottes de camions miniers. Traditionnellement, ces systèmes étaient développés pour répondre à des besoins spécifiques, mais ils manquaient souvent d'intégration avec des outils avancés d'analyse de données et de maintenance prédictive. Ces technologies étaient principalement utilisées pour collecter des données, sans exploiter pleinement leur potentiel pour améliorer la prise de décision en temps réel. Les solutions actuelles, en revanche, s'inscrivent dans une approche Maintenance 4.0, où la télémétrie est intégrée dans un cadre global de surveillance conditionnelle et d'optimisation des opérations minières. Les camions miniers modernes sont équipés de capteurs avancés mesurant des paramètres critiques tels que l'état du moteur, la capacité de charge, l'efficacité énergétique et les anomalies de fonctionnement. Ces flux de données en temps réel permettent de développer des stratégies de maintenance prédictive sophistiquées,

contribuant à réduire les temps d'arrêt, les coûts opérationnels et l'impact environnemental. Cependant, bien que certaines solutions IoT telles que My Sandvik [42] facilitent l'intégration des données, elles ne fournissent pas nécessairement des outils de maintenance prédictive avancés. Les systèmes de télématique traditionnels présentent encore des limitations en termes de compatibilité entre les marques, de protocoles réseau spécifiques et de capacités d'analyse des données. Le processus commence par l'installation de capteurs robustes Honeywell qui mesurent des paramètres comme la température, la pression et les vibrations sur des composants critiques. Ces données sont ensuite transmises à une passerelle télématique comme Caterpillar's MineStar [43], qui centralise et traite l'information. L'ensemble est ensuite relayé via Wi-Fi vers un dispositif Android qui communique avec le serveur FDM-Dispatcher de la mine. Enfin, les données sont intégrées au système de contrôle, permettant un suivi en temps réel et un archivage pour des analyses prédictives avancées. Si des études telles que celles de Mohammadali et al. [44] ont démontré l'efficacité des systèmes IoT pour la gestion des flottes, elles se concentrent principalement sur la communication et le suivi en temps réel, sans exploiter pleinement les capacités analytiques prédictives. Notre approche va au-delà en intégrant des algorithmes d'apprentissage automatique, capables de prédire les pannes et d'optimiser les interventions de maintenance.

Dans ce cadre, les technologies de communication sans fil dans les environnements miniers reposent sur des solutions spécifiques telles que le Wi-Fi industriel, contrairement aux réseaux urbains polyvalents [45, 46]. La télémétrie combinée aux systèmes de Big Data et d'intelligence artificielle transforme ainsi les pratiques industrielles traditionnelles et améliore l'efficacité des opérations minières [47]. L'intégration avancée de la télémétrie dans la Maintenance 4.0 permet également une optimisation de la consommation énergétique des équipements miniers. Par exemple, Noah et al. [48] ont développé des algorithmes optimisant l'usage énergétique des pelles hydrauliques à partir des données de télémétrie. Notre approche étend cette méthodologie à l'ensemble des équipements miniers, en intégrant des stratégies visant l'amélioration de la fiabilité, de la sécurité et la

réduction des coûts [49]. La Figure 2.9 illustre une interface HMI (Human-Machine Interface) utilisée dans les ateliers de maintenance et entrepôts miniers, représentant une application concrète de la télémétrie dans la gestion des opérations mécaniques.




Figure 2.9 Armoire HMI pour la surveillance et la maintenance en temps réel

Cet HMI fournit aux équipes de maintenance des données en temps réel sur des paramètres critiques, tels que les niveaux d'huile, de liquide de refroidissement et de graisse, réduisant ainsi les risques de panne et améliorant la fiabilité des équipements [50]. De plus, ces systèmes permettent une planification proactive des interventions grâce à des alertes automatiques, renforçant ainsi la sécurité et l'efficacité des opérations minières.

2.4. Synthèse

Ce chapitre a exploré les avancées en maintenance prédictive dans l'industrie minière, avec un accent sur les convoyeurs de transport de minerais et les camions miniers. L'intégration des technologies d'Industrie 4.0, comme l'apprentissage automatique, l'IoT et les mégadonnées, permet d'anticiper les défaillances et d'optimiser les opérations de maintenance. Les études citées démontrent l'efficacité des systèmes robotiques autonomes et des algorithmes d'apprentissage pour la détection des anomalies, améliorant ainsi la fiabilité des équipements. La collecte, le prétraitement et l'analyse des données sont cruciaux pour développer des modèles prédictifs robustes, essentiels pour la sécurité et la rentabilité des opérations minières.

CHAPITRE 3 : MÉTHODOLOGIE DE RECHERCHE

3.1. Introduction

Ce chapitre décrit la démarche suivie pour mettre en œuvre la solution proposée. Comme mentionné dans le Chapitre 1, l'objectif principal de cette étude est de développer un modèle de prédiction et d'anticipation des défaillances mécaniques pour les convoyeurs de transport de minerais, ainsi que d'élaborer une approche innovante pour la gestion de la maintenance des camions miniers.

3.2. Démarche de recherche

Pour atteindre les objectifs de ce projet de maîtrise, cette recherche s'articule autour d'études de cas en collaboration avec des partenaires du secteur minier. La réalisation de ces études comprend quatre phases essentielles :

- **Contextualisation** : cette phase est fondamentale pour comprendre et se familiariser avec le thème de recherche. Elle permet de situer le projet dans son contexte industriel et scientifique, en tenant compte des spécificités du secteur minier.
- **Identification** : cette étape est dédiée à la compréhension des besoins du partenaire industriel et à l'identification de la problématique de recherche. L'objectif est d'établir un système de maintenance prédictive capable de détecter à temps les défaillances des convoyeurs de minerais et des camions miniers, afin de prévenir les arrêts imprévus et coûteux des équipements.
- **Conception de la solution** : cette phase concerne la création du modèle de prédiction et la définition de la méthodologie à suivre pour résoudre la problématique identifiée.
- **Évaluation** : la dernière étape consiste à tester les modèles de prédiction à travers une étude de cas utilisant des données réelles. Cette phase vise à valider la méthodologie et à vérifier si les objectifs fixés en collaboration avec les partenaires industriels sont atteints.

3.3. Méthodologie pour la prédiction de défaillance d'un réducteur de convoyeur

La méthodologie pour développer un modèle de prédiction et de détection des anomalies pour les convoyeurs de minerais est structurée en plusieurs étapes clés comme illustre la Figure 3.1. Elle commence par une phase de mise en contexte et d'analyse préliminaire pour comprendre les exigences et les besoins spécifiques liés aux équipements miniers. Ensuite, les données pertinentes, telles que les données de vibration, sont collectées à partir de systèmes d'acquisition comme PI SQL. Les données collectées sont ensuite prétraitées pour éliminer les valeurs redondantes et les nettoyer, en utilisant des outils comme OpenRefine. La phase suivante implique le développement d'un modèle d'apprentissage automatique basé sur des réseaux de neurones récurrents (RNN), avec la définition des ensembles de données d'entraînement, de test et de validation. Le modèle est ensuite configuré en définissant sa structure et ses paramètres, notamment le nombre et le type de couches de neurones. Après cette configuration, le modèle est entraîné et testé, et sa performance est comparée aux données réelles pour évaluer sa précision. Si les résultats sont validés, les hyperparamètres optimaux sont sélectionnés, sinon des ajustements sont faits. Une fois validé, le modèle final est développé pour prédire les données de vibration et intégrer les dates d'intervention antérieures, améliorant ainsi la maintenance prédictive. Enfin, le modèle est utilisé pour détecter les dates de maintenance nécessaires en analysant les données prédites par le RNN et en utilisant des modèles de détection d'anomalies comme Local Outlier Factor (LOF) et Isolation Forest (IF). Cette méthodologie assure une approche rigoureuse et structurée, garantissant la fiabilité et l'efficacité des opérations minières.




Figure 3.1 Méthodologie appliquée sur le convoyeur des minerais

3.3.1. Collecte des données

Dans le cadre de l'acquisition des données, l'avancée de la technologie IoT permet de capturer divers types de données, souvent appelées mégadonnées industrielles, directement à partir des équipements surveillés et de les stocker pour une analyse approfondie. Deux types de données ont été fournis par le partenaire minier Agnico Eagle Complexe LaRonde. Le premier type provient des rapports sur les actions correctives effectuées sur le convoyeur. Le second type comprend des données numériques collectées en temps réel par des capteurs installés sur le système d'entraînement moteur-réducteur. L'intégration de ces deux bases de données permet d'exploiter des approches d'apprentissage automatique supervisées et non supervisées pour améliorer la maintenance prédictive.

3.3.2. Prétraitement des données

Les données brutes collectées pour les séries chronologiques contiennent souvent des anomalies, des valeurs manquantes ou des échelles incohérentes. Ces imperfections, si elles ne sont pas corrigées, peuvent nuire à la performance des modèles d'apprentissage automatique. Pour garantir la qualité et la pertinence des données utilisées dans le modèle, deux étapes clés de prétraitement ont été effectuées : le nettoyage des données et la normalisation des données.

3.3.2.1. Nettoyage des données

Le nettoyage des données est une étape essentielle du prétraitement, visant à corriger les valeurs manquantes, redondantes et aberrantes [51] afin d'assurer la qualité des séries chronologiques. Cette phase se décompose en trois sous-étapes principales.

Premièrement, la gestion des valeurs manquantes est indispensable pour traiter les lacunes causées par des capteurs défectueux ou des interruptions. Des méthodes comme l'interpolation linéaire, qui estime les valeurs en fonction des points adjacents, ou la moyenne mobile, basée sur les points précédents, ont été utilisées pour combler ces absences.

Deuxièmement, la détection et la suppression des anomalies permettent d'identifier et d'éliminer des perturbations telles que des pics extrêmes ou des valeurs incohérentes. Ces anomalies ont été repérées grâce à des techniques statistiques, notamment l'écart-type, en identifiant les points dépassant un seuil prédéfini.

Enfin, pour atténuer le bruit dans les séries chronologiques, un filtre passe-bas a été appliqué. Ce processus lisse les données en réduisant les fluctuations mineures tout en conservant les informations pertinentes, garantissant ainsi des données prêtes pour les analyses ultérieures.

3.3.2.2. Normalisation des données

La normalisation des données joue un rôle important dans la préparation des séries chronologiques pour l'apprentissage automatique. Elle vise à harmoniser les plages de valeurs des différentes caractéristiques afin de garantir une contribution équilibrée de chaque variable au processus de modélisation. Sans cette étape, les caractéristiques ayant des amplitudes élevées pourraient dominer l'analyse, entraînant des résultats biaisés.

Plusieurs méthodes de normalisation sont couramment utilisées pour répondre à ces besoins :

- **Min-Max Scaler** [52] : cette méthode met à l'échelle les données dans un intervalle fixe, généralement entre 0 et 1. Les valeurs normalisées sont calculées à l'aide de l'équation suivante :

$$X' = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (1)$$

Où X' correspond à la valeur normalisée, et $\min(X)$, $\max(X)$ sont respectivement les minimum et maximum de la variable.

- **Standard Scaler** [53] : cette approche transforme les données de manière qu'elles soient centrées autour de zéro et qu'elles aient une variance égale à un. La normalisation est obtenue à l'aide de l'équation suivante :

$$X' = \frac{X - \text{moyenne}(X)}{\sigma(X)} \quad (2)$$

Où $\text{moyenne}(X)$ représente la moyenne de la variable, et $\sigma(X)$ son écart type.

- **Robust Scaler** [54] : Spécialement conçu pour être résilient face aux valeurs aberrantes, il utilise la plage interquartile pour normaliser les données :

$$X' = \frac{X - Q_1(X)}{Q_3(X) - Q_1(X)} \quad (3)$$

Où $Q_1(X)$ et $Q_3(X)$ désignent respectivement les premier et troisième quartile.

Pour les réseaux de neurones récurrents (RNN) avec des couches LSTM, le choix de la méthode de normalisation joue un rôle déterminant dans l'entraînement du modèle. Dans cette étude, le Standard Scaler a été choisi pour normaliser les données. Cette méthode ajuste les variables pour qu'elles aient une moyenne nulle et une variance unitaire, ce qui améliore la stabilité des calculs et optimise les performances des LSTM dans la capture des dépendances temporelles.

3.3.3. Approche basée sur le RNN pour la maintenance prévisionnelle

La mise en œuvre d'un modèle prévisionnel basé sur un réseau de neurones récurrents (RNN) repose sur une base de données soigneusement préparée et sur une méthodologie rigoureuse. Dans cette étude, la division de la base de données en trois ensembles distincts a été réalisée afin de garantir une évaluation fiable et une validation efficace du modèle :

- **Ensemble d'entraînement** : cet ensemble, représentant 60% des données totales, est utilisé pour entraîner le modèle. Il permet au modèle d'apprendre les caractéristiques et les relations présentes dans les données.
- **Ensemble de tests** : constituant 20% des données, cet ensemble sert à évaluer le modèle final. Il permet de tester le modèle et de mesurer sa performance en le comparant aux ensembles de données précédents.
- **Ensemble de validation** : Représentant également 20 % des données, cet ensemble sert à ajuster les hyperparamètres du RNN et à prévenir le surapprentissage.

Les sections suivantes présentent en détail les différentes techniques adoptées dans cette étude.

L'apprentissage supervisé se réfère à une méthode dans laquelle on utilise des données d'entraînement étiquetées, c'est-à-dire des données dont les résultats souhaités sont connus. Chaque entrée x_i est associée à une sortie cible y_i , formant ainsi un ensemble de données $D = \{(x_i, y_i)\}_{i \in [1, N]}$. L'objectif de cette méthode est

d'entraîner un modèle à partir de données étiquetées, afin qu'il puisse prédire avec précision les résultats pour de nouvelles données non observées.

Dans le cadre de ce travail, l'apprentissage supervisé est appliqué à un problème de régression, où la variable cible à prédire est une valeur continue représentant une quantité réelle. Par exemple, des algorithmes de régression peuvent être utilisés pour estimer la consommation énergétique d'une installation ou prévoir les fluctuations du cours des actions en bourse [55].

Pour cette étude, RNN a été choisi pour la prédiction des données. Ce type de modèle est particulièrement adapté à la modélisation des séries temporelles et des données séquentielles, ce qui le rend parfaitement approprié à cette application. Grâce à son architecture spécifique, il peut conserver des informations contextuelles sur de longues séquences, permettant ainsi de capturer les dépendances temporelles complexes observées dans les données de vibration des équipements miniers.

3.3.3.1.Types de réseaux de neurones récurrents et leurs applications

Les RNN sont spécialement conçus pour traiter des séquences temporelles, telles que les données linguistiques, les vidéos ou les séries chronologiques numériques. Leur capacité à maintenir une mémoire des informations passées leur permet de prédire avec précision les séquences de données futures, rendant ces modèles particulièrement adaptés aux processus industriels à grande échelle. Ces derniers, comme la fonderie et la forge, génèrent un volume important de données (par exemple, température des outils, pression, vitesse ou état des machines) souvent cycliques. La stabilité de ces paramètres, enregistrés en temps réel grâce à des capteurs, influence directement la qualité des pièces produites. La prédiction des dérives ou des anomalies dans ces données est donc un enjeu majeur pour lequel les techniques de machine learning, et plus particulièrement les RNN, offrent des solutions performantes.

le RNN simple (ou « Vanilla RNN »), le LSTM (Long Short-Term Memory) et le GRU (Gated Recurrent Unit). Le RNN simple est une architecture de base qui ne

dispose pas de mécanismes de contrôle des flux d'informations, ce qui peut entraîner la perte de données importantes sur de longues séquences. En revanche, les variantes avancées telles que les LSTM et les GRU intègrent des portes de contrôle qui permettent de mémoriser ou d'oublier sélectivement certaines informations, les rendant plus efficaces pour modéliser des séries temporelles complexes. Dans le cadre de cette étude, le RNN a été utilisé avec des couches LSTM pour atteindre une meilleure précision dans les prédictions des données prévisionnelles. La Figure 3.2 présente un aperçu des architectures de ces différents types de RNN.




Figure 3.2 Architecture des types de RNN [56]

3.3.3.2. Structure et fonctionnement d'une cellule LSTM

Une cellule LSTM (Long Short-Term Memory) dans les réseaux de neurones récurrents est nettement plus sophistiquée qu'une cellule RNN traditionnelle ou qu'un neurone classique. Une unité LSTM typique se compose d'une cellule et de trois portes principales, comme illustré dans la Figure 3.3 : la porte d'oubli, la porte d'entrée et la porte de sortie. Ces portes gèrent une mémoire dynamique, notée C , qui évolue en fonction de la séquence temporelle des données.

La porte d'oubli filtre les informations passées qui ne sont plus pertinentes, décidant ainsi quelles informations doivent être oubliées ou conservées. La porte d'entrée contrôle les nouvelles informations à ajouter à la cellule à l'instant t , intégrant des données pertinentes qui étaient inexistantes ou moins importantes à l'instant $t - 1$. Enfin, La porte de sortie régule les informations à transmettre à l'instant $t + 1$, en fonction de la mémoire C et de la fonction d'activation. Grâce à ces mécanismes, la

cellule LSTM peut mémoriser des valeurs sur des intervalles de temps arbitraires, avec les trois portes régulant le flux des informations entrantes et sortantes. Cela permet aux LSTM de traiter efficacement les dépendances à long terme dans les données séquentielles, ce qui est crucial pour les tâches de prédiction de séries temporelles complexes.




Figure 3.3 Fonctionnement des couches LSTM dans l'architecture RNN [56]

Les fonctions mathématiques suivantes sont présentées pour détailler le fonctionnement de chaque composante de la cellule LSTM [57]. Elles expliquent comment les portes d'oubli, d'entrée, et de sortie, ainsi que la mise à jour de la mémoire de la cellule, interagissent pour traiter et mémoriser les informations au fil des séquences temporelles.

La porte d'oubli permet de déterminer quelles informations issues des étapes temporelles précédentes doivent être conservées ou oubliées. Cette opération est représentée mathématiquement par l'activation de la porte d'oubli f_t , calculée comme suit :

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

Où W_f et b_f représentent respectivement les poids et biais associés, h_{t-1} est l'état caché précédent, x_t est l'entrée actuelle, et σ désigne la fonction sigmoïde.

Ainsi, la porte d'entrée, essentielle pour intégrer de nouvelles informations à la cellule, s'active selon l'équation suivante :

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

En parallèle, un état temporaire $\tilde{c}_t$ des nouvelles informations à intégrer est calculé selon la relation suivante :

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (6)$$

Où la fonction $\tanh$ (tangente hyperbolique) agit comme une fonction d'activation, limitant les valeurs $\tilde{c}_t$ dans un intervalle -1 et 1, afin de mieux contrôler l'amplitude des nouvelles informations.

La mémoire de la cellule est ensuite actualisée en combinant les contributions des portes d'oubli et d'entrée. La mise à jour est réalisée comme suit :

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (7)$$

Où $\circ$ représente une multiplication élément par élément. Cette étape garantit que seules les informations pertinentes sont conservées dans la mémoire.

Enfin, la porte de sortie régule les informations à transmettre à l'étape temporelle suivante. Son activation est donnée par :

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

L'état caché actuel, transmis comme sortie de la cellule, est calculé à l'aide de la mémoire mise à jour et de la porte de sortie :

$$h_t = o_t \circ \tanh(c_t) \quad (9)$$

Ces caractéristiques en font un choix particulièrement adapté pour les applications de maintenance prévisionnelle basées sur l'analyse des données temporelles.

3.3.3.3. Optimisation des LSTM avec l'algorithme Adam

Pour résoudre les limitations des méthodes traditionnelles de descente de gradient stochastique, l'algorithme Adam (Adaptive Moment Estimation) a été adopté. Cette méthode combine les forces des approches à gradient adaptatif et de la propagation quadratique moyenne (RMSProp), permettant une optimisation plus efficace pour les réseaux complexes tels que les LSTM. Contrairement aux techniques classiques, Adam ajuste dynamiquement les taux d'apprentissage pour chaque paramètre, améliorant ainsi la vitesse de convergence tout en réduisant la sensibilité aux paramètres initiaux.

Grâce à sa capacité à explorer efficacement l'espace des paramètres et à corriger les biais liés aux moments, Adam s'impose comme une solution particulièrement adaptée aux tâches de prédiction de séries temporelles avec des modèles complexes comme les LSTM. Dans cet algorithme [58], les estimations du premier moment (moyenne) et du deuxième moment (variance) des gradients sont calculées comme suit :

$$\begin{aligned} m_t &= \beta_1 \times m_{t-1} + (1 - \beta_1) \times g_t \\ v_t &= \beta_2 \times v_{t-1} + (1 - \beta_2) \times g_t^2 \end{aligned} \quad (10)$$

Où β_1 et β_2 sont des coefficients de pondération et g_t représente le gradient à l'itération t .

Ces moments sont ensuite corrigés pour réduire les biais initiaux à l'aide des équations suivantes :

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (11)$$

Enfin, les paramètres du modèle sont mis à jour selon la règle suivante :

$$\theta_{t+1} = \theta_t - \eta \times \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (12)$$

Où η est le taux d'apprentissage initial, et ε est une constante numérique de stabilité pour éviter la division par zéro.

L'intégration de l'algorithme Adam pour optimiser les LSTM dans cette étude a permis d'améliorer la vitesse de convergence et la capacité de généralisation du modèle. En outre, Adam s'est montré résilient face aux ensembles de données bruités ou incomplets, garantissant une optimisation efficace des hyperparamètres et renforçant les performances du modèle de maintenance prévisionnelle.

3.3.3.4. Réglage des hyperparamètres

Les hyperparamètres définissent la configuration des modèles d'apprentissage automatique, notamment pour les réseaux de neurones récurrents (RNN) et les algorithmes de détection des anomalies. Contrairement aux paramètres internes ajustés automatiquement durant l'entraînement, les hyperparamètres doivent être définis au préalable et influencent directement la performance du modèle. Leur choix impacte la capacité d'un modèle à capturer des tendances complexes et à détecter efficacement des comportements anormaux.

- Recherche par grille (Grid Search CV)

L'optimisation des hyperparamètres améliore la précision et la robustesse des modèles prédictifs. Une méthode couramment utilisée est la recherche par grille [59] (Grid Search CV), qui permet d'explorer différentes configurations de paramètres sur une grille prédéfinie. Implémentée dans Scikit-Learn, cette approche évalue chaque combinaison à l'aide d'une validation croisée, identifiant ainsi l'ensemble optimal d'hyperparamètres.

Dans le cadre des RNN, les hyperparamètres clés incluent :

- Le nombre de couches récurrentes et le nombre de neurones par couche, qui influencent la capacité du modèle à mémoriser les séquences temporelles.
- Le taux d'apprentissage, qui impacte la vitesse et la stabilité de l'optimisation.

- Le taux de dropout, utilisé pour éviter le surajustement.

Pour les modèles de détection des anomalies, comme LOF (Local Outlier Factor) et Isolation Forest (IF), l'optimisation porte notamment sur :

- Le nombre de voisins (pour LOF), influençant la sensibilité à la densité locale des données.
- Le seuil d'anomalie, qui détermine le degré de déviation nécessaire pour qu'un point soit considéré comme anormal.
- Le nombre d'arbres dans Isolation Forest, impactant la capacité du modèle à isoler efficacement les points aberrants.

3.3.3.5.Évaluation des Performances du Modèle LSTM

Pour évaluer la précision des prédictions générées par un modèle LSTM après la phase d'entraînement, une phase de test est réalisée. Cette phase consiste à mesurer les écarts entre les observations réelles et les prédictions à l'aide de métriques quantitatives. Parmi les mesures les plus couramment utilisées, la RMSE (Root Mean Square Error) et le coefficient de détermination (R^2) sont particulièrement adaptées pour analyser les performances des modèles appliqués aux séries temporelles. La racine de l'erreur quadratique moyenne, permet de quantifier les différences entre les prédictions et les valeurs réelles. Elle est calculée selon la relation suivante :

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (13)$$

Où $\hat{y}_i$ représente la valeur prédite, y_i la valeur réelle, et n le nombre total d'observations. Sensible aux grandes erreurs, la RMSE est idéale pour détecter des écarts significatifs, particulièrement dans des contextes où l'objectif est de prévoir des valeurs futures à différents moments ($t + 1$, $t + 2$, $t + 3$). Elle offre ainsi une évaluation claire de la précision globale du modèle.

En complément, le coefficient de détermination (R^2) est utilisé pour mesurer la qualité de la relation entre les prédictions et les données réelles. Il est défini par l'équation suivante :

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

Dans cette formule, $\bar{y}$ représente la moyenne des valeurs réelles. Un R^2 proche de 1 indique que le modèle explique efficacement la variance des données réelles, tandis qu'une valeur proche de 0 suggère une faible corrélation entre les prédictions et les observations. Cette métrique est particulièrement utile pour évaluer la robustesse et la fiabilité du modèle.

3.3.4. Détection des anomalies

Dans le cadre de l'Industrie 4.0, la détection des anomalies est essentielle pour la maintenance prédictive et l'optimisation des processus industriels. Pour répondre à cette exigence, nous avons utilisé des algorithmes d'apprentissage automatique non supervisés capables d'analyser les données et de détecter les valeurs anormales. Parmi les méthodes employées, on trouve le clustering basé sur la densité et la forêt d'isolement, qui sont particulièrement efficaces pour identifier les anomalies dans de grands ensembles de données.

3.3.4.1. Méthode basée sur la densité LOF

Proposé par Breunig et al. [60] en 2000, le Facteur Aberrant Local (LOF) représente une méthode efficace pour détecter les anomalies au sein d'ensembles de données multidimensionnelles. Cette technique repose sur la comparaison de la densité locale d'un point avec celle de ses voisins, permettant une identification précise des anomalies, même dans des bases de données présentant des variations de densité importantes, où les approches basées exclusivement sur la distance montrent leurs limites. Comme illustré dans la Figure 3.4, chaque point se voit attribuer un score, désigné sous le terme de Local Outlier Factor, qui reflète son degré d'anomalie. Un point est considéré comme aberrant lorsque sa densité locale est nettement

inférieure à celle de ses K-plus proches voisins (K-NN), la distance entre les points constituant un critère essentiel dans cette évaluation.




Figure 3.4 Détection des anomalies par le facteur aberrant local [61]

Pour appréhender le fonctionnement du Facteur Aberrant Local (LOF), il convient de présenter les différentes étapes de l'algorithme. Celles-ci détaillent le processus d'évaluation de la densité locale des points de données et le calcul de leur score d'aberration, permettant ainsi d'identifier les anomalies avec précision.

- Étape 1 : Calcul de k – distance :

La distance k – distance ($d_k(R)$) est déterminée pour chaque point R , où k représente le nombre de voisins considérés. Cette distance correspond à la mesure entre le point R et son k – ième voisin le plus proche. La distance euclidienne est généralement utilisée, définie comme suit :

$$d_{Eucl}(X_i, X_j) = \sqrt{\sum_{k=1}^m (X_{ik} - X_{jk})^2} \quad (15)$$

Où m est le nombre de dimensions des données, X_{ik} et X_{jk} sont les coordonnées des points i et j dans la dimension k .

- Étape 2 : Définition du voisinage k – distance :

Le voisinage k – distance ($N_k(R)$) inclut tous les points B dont la distance avec R est inférieure ou égale à la k – distance de R . Cette étape permet d’identifier les k – plus proches voisins autour de chaque point, définis par :

$$N_k(R) = \{B \in D \setminus \{R\} | d(R, B) \leq d_k(R)\} \quad (16)$$

- Étape 3 : Calcul de la distance atteignable ($reach - dist_k$) :

La distance atteignable ($reach - dist_k(R, S)$) est calculée pour chaque point S du voisinage $N_k(R)$. Elle définit comme :

$$reach - dist_k(R, S) = \max\{d_k(S), d(R, S)\} \quad (17)$$

- Étape 4 : Évaluation de la densité locale atteignable (lrd_K) :

La densité locale atteignable d’un point R est le réciproque de la moyenne des distances atteignables entre R et ses voisins :

$$lrd_K(R) = \frac{|N_k(R)|}{\sum_{S \in N_k(R)} reach - dist_k(R, S)} \quad (18)$$

- Étape 5 : Calcul du facteur aberrant (LOF_k) :

Le LOF est défini comme la ration entre la densité locale moyenne des voisins de R et la densité locale de R :

$$LOF_k(R) = \frac{\frac{1}{|N_k(R)|} \sum_{S \in N_k(R)} lrd_K(S)}{lrd_K(R)} \quad (19)$$

3.3.4.2. Forêt d’isolement

La forêt d’isolement, développé par Liu et al. [62] en 2008, est un algorithme de détection d’anomalies basé sur des arbres binaires. Cet algorithme fonctionne en réalisant des splits aléatoires sur le jeu de données et en comptant le nombre de divisions nécessaires pour isoler chaque point. Plus un point est rapidement isolé, plus il est susceptible d’être une anomalie. Pour éviter les fausses anomalies, l’algorithme itère ce processus plusieurs fois, construisant ainsi une forêt d’arbres

de décision illustré dans la Figure 3.5 où seuls les points statistiquement isolés sont considérés comme des anomalies.




Figure 3.5 Détection des anomalies par la forêt d'isolement [63]

L'algorithme repose sur le concept de longueur de chemin d'accès pour chaque échantillon. Lorsqu'un échantillon est analysé, l'algorithme calcule la profondeur moyenne des nœuds dans lesquels cet échantillon est isolé à travers l'ensemble des arbres de la forêt. Plus cette profondeur est courte, plus le score d'anomalie associé est élevé. La longueur moyenne du chemin d'accès pour un sous-échantillon φ est donnée par l'équation (20) :

$$c(\varphi) = \begin{cases} 2H(\varphi - 1) - \frac{2(\varphi-1)}{1}, & \text{si } \varphi > 2 \\ 1, & \text{si } \varphi = 2 \\ 0, & \text{si } \varphi < 2 \end{cases} \quad (20)$$

Où :

- φ : représente la taille du sous-échantillon.
- $H(k)$ est le nombre harmonique calculé par :

$$H(k) = \ln(k) + 0.577216649 \text{ (Constante d'Euler)} \quad (21)$$

La profondeur $h(\delta)$ d'un point δ dans un arbre de la forêt est normalisée à l'aide de $c(\varphi)$, et le score d'anomalie $s(\delta)$ est défini par l'équation (22) :

$$s(\delta) = 2^{-\frac{E(h(\delta))}{c(\varphi)}} \quad (22)$$

Où :

- $E(h(\delta))$: représente la moyenne des profondeurs $h(\delta)$ à travers les arbres de la forêt.
- $c(\varphi)$: la longueur moyenne attendue de chemin d'accès.

Un score $s(\delta)$ proche de 1 indique une forte probabilité que le point δ soit une anomalie, tandis qu'un score proche de 0 suggère que le point est normal.

Cette approche présente plusieurs avantages, notamment sa capacité à gérer de grands ensembles de données avec une complexité de calcul réduite, tout en maintenant une efficacité élevée dans la détection des anomalies.

3.4. Méthodologie pour la maintenance 4.0 des camions miniers

Cette section présente un cadre architectural avancé, illustré dans la Figure 3.6, conçu pour prédire les défaillances des camions miniers, en alignement avec les initiatives de maintenance 4.0. Ce cadre explore l'intégration de systèmes sophistiqués de collecte de données et de protocoles avancés de distribution, permettant une amélioration significative des capacités de gestion des défaillances dans les opérations minières. En exploitant les fonctionnalités de visualisation et d'analyse intégrées dans Power BI, cette méthodologie propose une approche optimisée pour les stratégies de maintenance, renforçant la fiabilité, réduisant les temps d'arrêt et améliorant l'efficacité opérationnelle et les normes de sécurité.

L'approche repose sur l'installation de capteurs sur des composants critiques tels que la boîte de vitesses, le système de refroidissement et la pompe hydraulique, qui surveillent en continu des données de télémétrie telles que les niveaux de vibration, la température, et la pression d'huile. Ces données, combinées à des historiques de maintenance, sont intégrées pour accroître leur utilité analytique. Les données collectées sont analysées à l'aide des outils prédictifs de Power BI, notamment les fonctionnalités de tendances et prévisions intégrées, qui permettent d'identifier des indicateurs précoces de défaillance. Ces outils utilisent des techniques de séries temporelles pour détecter des anomalies et prédire des comportements futurs des

équipements. Ces prédictions sont combinées avec les indicateurs de performance clés (KPI) comme l'efficacité globale des camions (OEE) et le temps moyen entre les défaillances (MTBF), pour évaluer et améliorer la performance des stratégies de maintenance.




Figure 3.6 Méthodologie de flux de données et indicateurs clés de la maintenance prédictive des camions miniers

3.4.1. Collecte des données de télémétrie

La Figure 3.7 présente le processus de collecte des données de télémétrie dans le cadre de la maintenance 4.0 des camions miniers. Ce processus commence par le matériel embarqué, où des capteurs robustes (température, pression, vibrations) sont installés sur des composants critiques pour collecter des données en temps réel.

Ces données sont ensuite transmises à une passerelle télématique, qui les agrège et les traite. Les informations sont ensuite transférées via une connexion sans fil (Wi-Fi) vers un appareil mobile, qui joue un rôle intermédiaire en relayant les données au serveur de gestion des données du réseau minier pour une première analyse. Enfin, les données sont transmises au système de contrôle pour une surveillance en temps réel, l'application de modèles de maintenance prédictive et leur stockage à des fins d'analyses à long terme.




Figure 3.7 Processus de collecte des données de télémétrie

3.4.2. Prétraitement et gestion des données de télémétrie

Le prétraitement et la gestion des données de télémétrie constituent une étape clé dans la méthodologie de maintenance 4.0, car ils garantissent la qualité et la fiabilité des informations utilisées pour les analyses prédictives. La Figure 3.8 illustre ce processus, qui s'appuie sur les outils intégrés de Power BI et Microsoft Azure pour assurer une gestion optimale des flux de données.





Figure 3.8 Flux de prétraitement et gestion des données de télémétrie

Ce processus débute par l'importation des données brutes provenant de diverses sources, telles que des fichiers CSV, des bases de données SQL et d'autres systèmes d'acquisition. Ces données sont chargées dans Power BI Desktop via Power Query, un outil puissant permettant de nettoyer et de transformer les données. Les principales étapes incluent la suppression des doublons, le traitement des valeurs manquantes, l'uniformisation des formats et la création de colonnes calculées pour enrichir les jeux de données. Une fois les données nettoyées, elles sont centralisées dans Azure Data Lake, où elles sont organisées sous forme de conteneurs et de flux. Azure garantit une gestion sécurisée des données grâce à la configuration des autorisations et au suivi des métadonnées, assurant ainsi leur traçabilité. Les données transformées sont ensuite intégrées dans Power BI en ligne, où elles sont organisées sous forme de flux de données automatisés. Ces flux permettent des mises à jour régulières et partagées dans des espaces de travail collaboratifs. Enfin, les données prétraitées sont exploitées pour créer des modèles sémantiques, des rapports interactifs et des tableaux de bord dans Power BI, fournissant aux responsables de maintenance des analyses précises et une visualisation en temps réel pour une prise de décision optimisée.

3.4.3. Digitalisation des données de maintenance

La digitalisation des données de maintenance consiste à transformer des informations issues de supports papier en un format numérique exploitable pour la création de tableaux de bord interactifs. La Figure 3.9 illustre ce processus, qui commence par la standardisation des tâches de maintenance, basées sur des normes d'exécution claires et documentées, telles que les instructions spécifiques à chaque composant ou opération. Ces normes sont ensuite converties en données structurées, généralement sous forme de fichiers CSV, où chaque tâche est associée à un identifiant unique (ID) de lieu ou d'opération.



À l'aide du concepteur de synoptiques pour Power BI, les données structurées sont reliées à des schémas visuels représentatifs, permettant de cartographier les opérations sur un modèle numérique intuitif. Ce lien entre les fichiers CSV et les représentations synoptiques garantit une correspondance précise entre les informations de maintenance et leur localisation ou contexte d'application. Une fois cette étape réalisée, les tâches de maintenance numérisées sont intégrées dans un tableau de bord interactif dans Power BI, permettant une visualisation dynamique et en temps réel des opérations.

3.4.4. Détection d'anomalies avec le modèle SR-CNN

La détection des anomalies dans les séries temporelles de télémétrie, essentielle pour la maintenance 4.0, repose sur un modèle avancé, le SR-CNN (Spectral Residual - Convolutional Neural Network), intégré dans Power BI [64]. Ce modèle exploite des techniques issues de l'intelligence artificielle pour identifier les points

d'anomalie avec précision dans des ensembles de données complexes et volumineux.

Le modèle SR-CNN utilise une combinaison de méthodes spectrales et de réseaux de neurones convolutifs pour détecter les anomalies dans les données temporelles. Le processus se déroule en plusieurs étapes principales :

- **Transformée de Fourier logarithmique**

Cette première étape extrait le spectre d'amplitude logarithmique à partir de la séquence d'entrée $x = \{x_1, x_2, \dots, x_n\}$, où chaque valeur représente un point dans la série chronologique. Les équations suivantes permettent de décrire cette transformation :

$$A(f) = \text{Amplitude}(f(x)) : \text{amplitude spectrale} \quad (23)$$

$$P(f) = \text{Phase}(f(x)) : \text{Spectre de phase} \quad (24)$$

$$L(f) = \log(A(f)) : \text{amplitude spectrale logarithmique} \quad (25)$$

Ces transformations permettent de représenter la série dans le domaine fréquentiel, mettant en évidence les composantes dominantes.

- **Calcul du résidu spectral**

Après avoir obtenu l'amplitude spectrale logarithmique $L(f)$, le résidu spectral est calculé pour isoler les informations pertinentes tout en réduisant le bruit. Ce résidu est défini par la différence entre $L(f)$ et $AL(f)$, le spectre moyen logarithmique :

$$R(f) = L(f) - AL(f) \quad (26)$$

Le spectre moyen logarithmique $AL(f)$ est obtenu en appliquant une convolution au spectre $L(f)$ à l'aide d'une matrice moyenne $h_q(f)$, définie comme suit :

$$AL(f) = h_q(f) \times L(f) \quad (27)$$

Où $h_q(f)$ est une matrice $q \times q$ uniforme donnée par :

$$h_q(f) = \frac{1}{q^2} \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix} \quad (28)$$

Ce résidu met en évidence les anomalies en supprimant les tendances régulières du signal.

- **Transformée de Fourier inverse**

Une fois le résidu spectral $R(f)$ calculé, la transformée de Fourier est appliquée pour revenir au domaine spatial. Cette étape permet de produire une carte de saillance $S(x)$, qui met en évidence les anomalies dans les séries temporelles.

La transformée de Fourier inverse est définie comme suit :

$$S(x) = \|f^{-1}(\exp(R(f) + iP(f)))\| \quad (29)$$

Cette carte sert d'entrée au réseau de neurones convolutif (CNN), permettant d'identifier et de classifier les anomalies.

- **Classification des anomalies avec CNN**

obtenue après la transformée de Fourier inverse, est analysée par un réseau de neurones convolutif (CNN), qui classe les points en anomalies ou non. L'utilisation de cette carte, plutôt que des données brutes, améliore l'efficacité de la détection en se concentrant uniquement sur les variations significatives.

Les performances de cette classification dépendent fortement des hyperparamètres du modèle SR-CNN, qui contrôlent la sensibilité et la précision de l'analyse :

- **Taille de la fenêtre glissante** : Ce paramètre définit la granularité des observations temporelles, permettant de capter des variations locales tout en conservant une vision globale. Une fenêtre optimale équilibre la précision et la réduction des faux positifs.
- **Seuil de détection** : Ajusté ici à 93 %, ce seuil garantit que les anomalies identifiées sont pertinentes tout en minimisant les détections erronées. Il

offre ainsi une robustesse accrue dans des contextes opérationnels complexes.

- **Résolution spectrale** : Ce paramètre contrôle la finesse des fréquences analysées, permettant de détecter des variations critiques tout en filtrant les bruits inutiles.

- **Calcul des points d'anomalies**

La dernière étape du modèle SR-CNN consiste à calculer les valeurs des points d'anomalies à partir de la carte de saillance $S(x)$. Ces points sont définis par l'équation suivante :

$$x = (\bar{x} + mean)(1 + var) \times r + x \quad (30)$$

Où :

- $\bar{x}$: représente la moyenne locale des points précédents.
- $mean$ et var : sont respectivement la moyenne et la variance de tous les points de la fenêtre glissante actuelle.
- $r \sim N(0,1)$: est une variable aléatoire échantillonnée selon une distribution normale standard.

3.4.5. Modèle prévisionnel

Les modèles prévisionnels sont essentiels dans la maintenance 4.0 pour anticiper les défaillances et optimiser les interventions. En s'appuyant sur une approche des séries chronologiques, les données de télémétrie permettent d'identifier des tendances, anomalies et schémas répétitifs, contribuant ainsi à une gestion proactive des équipements. Power BI, avec ses capacités de prévision intégrées, exploite des méthodes avancées comme le modèle Holt-Winters, offrant des projections fiables pour améliorer la prise de décision en temps réel.

3.4.5.1.Approche des séries chronologiques

Power BI adopte une approche reposant sur la décomposition des séries chronologiques pour analyser et prévoir les comportements des données

temporelles [65]. Cette méthode consiste à diviser les séries en trois composantes fondamentales :

- **Tendance $T(t)$** : représente la direction générale ou l'évolution à long terme des données au fil du temps.
- **Saisonnalité $S(t)$** : représente la direction générale ou l'évolution à long terme des données au fil du temps.
- **Résidu $R(t)$** : correspond aux variations aléatoires ou imprévues, souvent liées à des événements non récurrents.

L'équation générale (31) permettant de modéliser une série chronologique s'exprime comme suit :

$$Y(t) = T(t) + S(t) + R(t) \quad (31)$$

Où $Y(t)$ est la valeur observée à l'instant t .

Cette décomposition est fondamentale pour l'analyse des séries chronologiques, car elle offre une meilleure compréhension des comportements sous-jacents des données.

3.4.5.2.Méthode de lissage exponentiel : le modèle Holt-Winters

Le modèle Holt-Winters, également connu sous le nom de lissage exponentiel triple, est couramment utilisé pour prévoir les séries chronologiques présentant une tendance et un modèle saisonnier [66]. Le lissage exponentiel regroupe plusieurs méthodes adaptées à différents types de séries temporelles :

- **Le lissage exponentiel simple** : est pertinent pour les séries sans tendance ni saisonnalité prononcée, où seules les valeurs récentes influencent les prévisions.
- **La méthode de Holt** : est adaptée aux séries qui présentent une tendance mais sans composante saisonnière.
- **La méthode de Winters** : est utilisée pour les séries avec une saisonnalité, éventuellement combinée à une tendance.

Il est important de noter que cette méthode repose sur l'hypothèse que le niveau, la tendance et la saisonnalité des données sont constants ou évoluent de manière linéaire. Par conséquent, elle peut être moins fiable pour les séries comportant des schémas complexes ou non linéaires. Ces deux dernières approches sont souvent regroupées sous l'appellation commune de modèle Holt-Winters.

Dans Power BI, la version additive du modèle Holt-Winters, utilisée pour les prévisions des séries chronologiques, est formulée comme suit dans l'équation (32) :

$$\hat{Y}_{t+h} = a_t + h \times b_t + s \times [t - p + 1 + (h - 1) \times \text{mod}(p)] \quad (32)$$

Où :

- $\hat{Y}_{t+h}$: prévision pour h périodes futures.
- a_t : composante de niveau.
- b_t : composante de tendance.
- s : composante saisonnière.
- p : période de la saisonnalité.
- h : nombre de périodes futures à prévoir.

Les composantes du modèle Holt-Winters sont calculées comme suit :

- **Composante de niveau (a_t)** : l'équation (33) calcule le niveau de la série, en intégrant les données observées et les effets saisonniers passés.

$$a_t = \alpha \times (Y_t - s_{t-p}) + (1 - \alpha) \times (a_{t-1} + b_{t-1}) \quad (33)$$

- **Composante de niveau (b_t)** : l'équation (34) met à jour la tendance en prenant en compte l'évolution du niveau :

$$b_t = \beta \times (a_t - a_{t-1}) + (1 - \beta) \times b_{t-1} \quad (34)$$

- **Composante saisonnière (s_t)** : l'équation (35) ajuste la saisonnalité en tenant compte des nouvelles observations :

$$s_t = \gamma \times (Y_t - a_t) + (1 - \gamma) \times s_{t-1} \quad (35)$$

Les trois composantes du modèle Holt-Winters (niveau, tendance et saisonnalité) sont modélisées à l'aide de trois types de lissage exponentiel. Ces lissages nécessitent les paramètres α , β et γ , chacun ayant une fonction spécifique pour affiner le modèle :

- **α (alpha) :** Ce paramètre contrôle le niveau ou la « valeur de base » des données. Une valeur α élevée privilégie les observations récentes, rendant les prévisions plus sensibles aux changements immédiats.
- **β (bêta) :** Il ajuste la composante de tendance, en attribuant davantage de poids aux variations récentes lorsque β est élevé, permettant ainsi de mieux suivre l'évolution des données dans le temps.
- **γ (gamma) :** Ce paramètre agit sur la composante saisonnière. Une valeur γ importante met en avant les cycles saisonniers les plus récents, offrant une meilleure adaptation aux schémas périodiques changeants.

Dans Power BI, les équations du modèle Holt-Winters sont implémentées automatiquement, simplifiant ainsi le processus de prévision. Le logiciel ajuste de manière autonome les paramètres (α , β , γ) pour réduire les erreurs et fournit des résultats fiables sous forme de courbes prévisionnelles accompagnées de bandes de confiance. Cette méthode est particulièrement adaptée à l'analyse de séries chronologiques complexes, telles que les données de télémétrie, permettant d'identifier efficacement les tendances à long terme et les schémas saisonniers.

3.4.5.3.Évaluation des performances du modèle de prévision

L'évaluation des performances des modèles de prévision est une étape indispensable pour garantir leur fiabilité et leur pertinence dans un contexte opérationnel. Elle permet de mesurer la qualité des prévisions, d'identifier les écarts significatifs et d'assurer une précision optimale dans l'analyse des séries chronologiques. L'analyse des performances d'un modèle de prévision repose sur des métriques quantitatives standard permettant de mesurer les écarts entre les valeurs prévues et les valeurs observées. Ces métriques, largement utilisées dans le cadre de Power BI, incluent les suivantes :

- **Erreur absolue moyenne (MAE) :** l'équation (36) calcule la MAE, qui mesure l'erreur moyenne en termes absolus entre les valeurs réelles (Y_t) et les prévisions ($\hat{Y}_t$) :

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (36)$$

Cette métrique estime simplement l'écart moyen sans tenir compte de la direction des erreurs.

- **Erreur quadratique moyenne (MSE) :** l'équation (37) exprime le MSE, qui pénalise davantage les grandes erreurs en élevant les écarts au carré. Il est particulièrement utile pour détecter les prévisions très éloignées des valeurs réelles :

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (37)$$

- **Erreur absolue moyenne en pourcentage (MAPE) :** l'équation (38) définit la MAPE, qui exprime l'erreur en pourcentage, facilitant ainsi la comparaison de la précision entre différentes séries chronologiques :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (38)$$

Les paramètres d'évaluation sont calculés sous Power BI à l'aide du langage DAX (Data Analysis Expressions), qui permet de créer des colonnes et mesures comparant les valeurs réelles et prévues. Les résultats sont ensuite visualisables dans des graphiques ou tableaux de bord interactifs pour analyser les performances du modèle.

3.4.6. Indicateurs de performance pour la gestion des camions miniers

Les indicateurs de performance clés (KPI) constituent des outils essentiels pour évaluer l'efficacité des stratégies de maintenance et la performance des équipements dans le cadre de la maintenance 4.0. Ces KPI, implémentés dans Power BI, permettent une analyse en temps réel et une visualisation intuitive, facilitant ainsi la prise de décision pour divers acteurs de l'exploitation minière. Chaque KPI est calculé à l'aide de formules spécifiques, permettant de mesurer différents aspects des performances des camions miniers.

3.4.6.1. Efficacité globale des équipements (OEE)

L'Efficacité Globale des Équipements est un indicateur clé utilisé pour mesurer la performance opérationnelle des équipements. Dans le contexte de la maintenance 4.0 des camions miniers, cet indicateur permet d'évaluer l'efficacité des opérations en prenant en compte trois composantes fondamentales [67] : la disponibilité, la performance et la qualité. Il est calculé selon la formule suivante :

$$OEE = Disponibilité \times Performance \times Qualité \quad (39)$$

Dans le secteur minier, le calcul de l'OEE se distingue par la complexité des cycles d'exploitation interdépendants (forage, chargement, transport, déchargement), où une interruption peut affecter l'ensemble de la chaîne. Les pertes sont regroupées en trois catégories : les pertes de disponibilité (temps non planifié, maintenance, temps d'attente), les pertes de performance (temps de chargement, ralentissements dus aux conditions environnementales), et les pertes de qualité (chargements incomplets). Cette classification permet d'identifier les leviers d'amélioration pour optimiser l'efficacité des camions miniers, essentiels dans les opérations à ciel ouvert ou souterraines.

Les composantes de l'OEE permettent de mesurer et d'analyser les performances des équipements en tenant compte de différents aspects critiques. Chaque composante est définie par une formule spécifique, assurant une évaluation détaillée et fiable.

- **La disponibilité** : première composante de l'OEE, mesure l'impact des pertes de temps liées aux maintenances planifiées, aux arrêts non planifiés ou aux interruptions imprévues. Elle est calculée selon l'équation (40) :

$$Disponibilité = \frac{\text{Temps réellement disponible}}{\text{Temps total}} \quad (40)$$

Cette métrique reflète la proportion du temps total durant laquelle l'équipement est opérationnel et disponible pour des tâches productives.

- **La performance** : évalue l'efficacité des opérations en tenant compte des ralentissements, des pertes de vitesse et des interruptions pendant les cycles de production. Elle est exprimée par l'équation (41) :

$$Performance = \frac{\text{Temps de production net}}{\text{Temps réellement disponible}} \quad (41)$$

Elle permet de quantifier l'impact des inefficacités dans les opérations quotidiennes, en mesurant la vitesse et la constance des équipements par rapport à leur potentiel.

- **La qualité** : dernière composante de l'OEE, analyse la proportion de la capacité théorique effectivement exploitée lors des cycles de production. Elle est définie par l'Équation (42) :

$$Qualité = \frac{\text{Volume moyen chargé}}{\text{Capacité nominale de chargement}} \quad (42)$$

Ce paramètre met en évidence les pertes dues aux chargements incomplets ou aux cycles de production non optimaux. Une qualité élevée reflète une utilisation efficace des capacités de l'équipement, réduisant les pertes matérielles et augmentant la productivité.

3.4.6.2.Retour sur l'investissement (ROI)

Le retour sur l'investissement est un indicateur financier clé dans le cadre de la maintenance 4.0, permettant d'évaluer l'efficacité économique des stratégies mises en œuvre. Il mesure la rentabilité des investissements réalisés en maintenance en comparant les bénéfices générés par ces interventions aux coûts engagés. Cet indicateur joue un rôle central dans la prise de décision stratégique, en aidant à prioriser les actions et à allouer efficacement les ressources.

Le ROI est calculé selon l'équation (43) :

$$ROI = \frac{\text{Bénéfice net}}{\text{Investissement total}} \times 100 \quad (43)$$

où :

- Bénéfice net : représente les gains économiques obtenus grâce à l'optimisation des équipements (réduction des temps d'arrêt, augmentation de la productivité, etc.).
- Investissement total inclut l'ensemble des coûts liés à la maintenance, comme les interventions correctives, préventives ou prédictives.

Un ROI élevé indique que les stratégies de maintenance déployées génèrent des retours financiers significatifs par rapport aux coûts investis, justifiant ainsi leur adoption.

3.4.6.3. Temps moyen entre les défaillances (MTBF)

Le temps moyen entre les défaillances est un indicateur utilisé pour mesurer la fiabilité des équipements dans un contexte opérationnel. Il permet de quantifier la durée moyenne pendant laquelle un équipement peut fonctionner sans subir de panne. Le MTBF est calculé selon l'équation (44) :

$$MTBF = \frac{\text{Temps opérationnel total}}{\text{Nombre de défaillances}} \quad (44)$$

où :

- Temps opérationnel total : représente la durée pendant laquelle l'équipement est opérationnel entre deux défaillances.
- Nombre de défaillances : correspond au total des pannes survenues au cours de la période d'analyse.

Un MTBF faible signale une fréquence élevée de pannes, nécessitant l'intervention des ingénieurs de maintenance pour mettre en place des mesures correctives ou planifier des stratégies de maintenance préventive adaptées.

3.4.6.4. Coût de maintenance par unité

Le coût de maintenance par unité représente une métrique essentielle pour analyser l'efficacité économique des interventions de maintenance. Il exprime le rapport

entre les dépenses de maintenance engagées et le volume de production réalisé, permettant ainsi de mieux évaluer la rentabilité des actions entreprises. Dans le secteur minier, où les équipements tels que les camions sont au cœur des opérations, ce calcul revêt une importance particulière pour optimiser les ressources. Cette métrique est déterminée selon l'équation (45) :

$$\text{Coût par unité} = \frac{\text{Coût total de maintenance}}{\text{Unité de production}} \quad (45)$$

où :

- Coût total de maintenance : inclut les dépenses liées aux interventions correctives, préventives et prédictives.
- Unités de production : correspond à la quantité totale de matériaux extraits ou transportés pendant la période analysée.

Suivre le coût par unité permet aux ingénieurs de maintenance d'identifier les écarts de performance par rapport aux objectifs et d'ajuster les stratégies si nécessaire.

3.4.6.5. Temps de réponse de la maintenance

Le temps de réponse de la maintenance évalue la rapidité avec laquelle les techniciens interviennent pour résoudre les incidents. Cet indicateur reflète l'efficacité opérationnelle de l'équipe de maintenance face aux défaillances ou problèmes signalés. Il est calculé à l'aide de l'équation (46) :

$$\text{Temps de réponse} = \frac{\text{Temps total de réponse}}{\text{Nombre d'incidents}} \quad (46)$$

où :

- Temps total de réponse : correspond à la somme des durées prises pour intervenir sur chaque incident durant une période donnée.
- Nombre d'incidents : désigne le total des défaillances ou problèmes enregistrés pendant la même période.

Une valeur faible pour cet indicateur traduit une organisation optimisée et une forte réactivité des techniciens, ce qui permet de minimiser les interruptions et d'améliorer la disponibilité des équipements.

3.5. Conclusion

Ce chapitre a présenté les méthodologies adoptées, qui seront appliquées dans l'analyse des résultats. Après avoir défini le contexte et la problématique, nous avons abordé la collecte et le prétraitement des données pour garantir leur qualité. Une revue de la littérature a permis d'identifier les modèles les plus adaptés : les réseaux de neurones récurrents (RNN) avec couches LSTM pour l'analyse des vibrations, et les algorithmes non supervisés LOF et IF pour la détection des anomalies et l'amélioration de la maintenance prédictive. En parallèle, une seconde approche méthodologique a été développée pour la digitalisation des données de maintenance sur Power BI. L'intégration des données de télémétrie dans un tableau de bord interactif facilite la surveillance en temps réel, la détection des anomalies et l'optimisation des interventions. Le modèle SR-CNN a été utilisé pour affiner la détection des anomalies grâce aux données spatio-temporelles, tandis que le modèle Holt-Winters permet d'anticiper les tendances des indicateurs critiques de maintenance.

CHAPITRE 4 : RÉSULTATS

4.1. Introduction

Les résultats de cette étude reposent sur deux approches complémentaires. La première concerne la prédiction des défaillances d'un réducteur de convoyeur de minerais, basée sur la méthodologie détaillée dans le chapitre précédent et sur les données collectées auprès de notre partenaire industriel, Agnico Eagle – Complexe LaRonde. Ces données, issues des fiches d'inspection, des rapports d'actions correctives et des capteurs du convoyeur, sont traitées afin d'éliminer les anomalies et d'optimiser l'analyse des enjeux de maintenance. La seconde approche porte sur la digitalisation et la modélisation prévisionnelle des données de maintenance des camions miniers, à partir des informations fournies par Canadian Malartic. Grâce à Power BI, les données de télémétrie sont intégrées dans un tableau de bord interactif, facilitant l'analyse des tendances et la détection des anomalies pour une meilleure anticipation des pannes critiques. Cette approche vise à optimiser la gestion des équipements et renforcer la prise de décision, en améliorant la fiabilité et la disponibilité des actifs miniers.

4.2. Développement d'un modèle de prédiction des défaillances dans un réducteur de convoyeur

4.2.1. Mise en contexte

Le transport des minerais dans une mine repose sur un ensemble d'équipements interconnectés permettant l'acheminement et le traitement efficace du matériau extrait. Parmi ces équipements, le convoyeur joue un rôle central en assurant le transfert continu du minerai vers les différentes étapes du processus. Comme illustré dans la Figure 4.1, le système de traitement comprend plusieurs composants clés, notamment les convoyeurs, le broyeur SAG et les pompes, chacun étant équipé de capteurs permettant un suivi en temps réel des conditions opérationnelles.

Le processus commence par l'alimentation, où le minerai brut est déversé dans le circuit de traitement. À cette étape, il est dirigé vers un premier convoyeur

(Convoyeur 1), qui assure son transport vers les étapes suivantes du traitement. Ensuite, le minerai passe par un second convoyeur (Convoyeur 2) qui l'achemine vers le broyeur SAG (Semi-Autogenous-Grinding). Ce broyeur est une pièce essentielle du processus, car il permet de réduire la taille des particules de minerai en les broyant sous l'effet de l'impact de grosses billes métalliques et du frottement entre les morceaux de minerai eux-mêmes. La densité du matériau est contrôlée en continu grâce à des capteurs intégrés, garantissant une granulométrie optimale pour le traitement ultérieur. Une fois broyé, le minerai mélangé à de l'eau est dirigé vers une pompe, qui joue un rôle crucial en assurant l'acheminement du mélange vers l'étape de classification. La pompe envoie ce mélange vers un hydrocyclone (ou cyclone), un dispositif utilisé pour séparer les particules fines des particules plus grossières en fonction de leur densité et de leur taille.




Figure 4.1 Schéma du processus de traitement des minerais [68]

Au cœur de ce dispositif, le système d'entraînement du convoyeur 2, présenté en Figure 4.2, est constitué d'un moteur asynchrone, d'un accouplement rigide et d'un réducteur étagé. Ce dernier a pour fonction de fournir un couple suffisant pour entraîner la bande transporteuse et assurer un flux optimal du minerai. Considéré comme un équipement critique par les fiabilistes du partenaire minier, ce convoyeur

représente un point névralgique du processus, dont une défaillance pourrait entraîner un goulot d'étranglement impactant la continuité des opérations. Afin de prévenir ces interruptions, un réseau de capteurs et de sondes est stratégiquement positionné pour surveiller les vibrations du système.




Figure 4.2 Système d'entraînement : (a) Accouplement moteur/réducteur et (b) Emplacement des capteurs

Deux capteurs principaux sont particulièrement étudiés : la sonde de vibrations A, située sur le moteur, et la sonde de vibrations B, installée sur le réducteur. Ces capteurs sont intégrés à un système de surveillance intelligent permettant une collecte et une analyse des données en temps réel, afin d'optimiser la maintenance du convoyeur et d'éviter toute interruption imprévue du processus. Cette approche s'inscrit dans une logique de maintenance prédictive, visant à améliorer la fiabilité et la performance globale du convoyeur en anticipant les défaillances potentielles.

4.2.2. Collecte et préparation des données

La collecte des données constitue une étape essentielle dans le développement d'un modèle de prédiction des défaillances, car elle permet d'identifier les tendances de pannes et d'optimiser la maintenance préventive. Dans ce projet, deux sources principales ont été exploitées : les historiques de maintenance et les données en temps réel issues des capteurs. Tout d'abord, des fichiers CSV fournis par le partenaire minier ont permis d'analyser les interventions de maintenance effectuées sur le convoyeur 2. La Figure 4.3 illustre un extrait de ces fichiers, mettant en évidence les références et descriptions des pièces remplacées, les dates d'intervention et les coûts associés. Cette analyse permet d'identifier les composants les plus sollicités et sujets à défaillance.

ID	Date	Code	Prix	Description	Détail	Code2	NB	REF
14818	31/01/2023 0:00	214102	47432	COURROIE 42" X 3/8" X 1/8" NYL	GRADE 500 , 400PIEDS	214102	1.000000	BRCON02
15614	03/02/2023 0:00	113765	28166	REDUCTEUR DE VITESSE	A ARBRE PARALLELE FALK	113765	1.000000	BRCON02RED01
14818	08/01/2023 0:00	113655	6411	DRUM, CROWN QUARRY DUTY	16X46 X50 BUSH C/W 1/2 DIAMOND	113655	1.000000	BRCON02
14818	08/01/2023 0:00	113655	6411	DRUM, CROWN QUARRY DUTY	16X46 X50 BUSH C/W 1/2 DIAMOND	113655	1.000000	BRCON02
14818	31/01/2023 0:00	14852	1218	ROULEAU GRATTOIR REMACLEAN	8" X 1" X 16.5'	14852	1.000000	BRCON02
14818	19/04/2023 0:00	115016	810	RETVEMENT	16-1/2" X 60-3/4" HARDOX 500	115016	1.000000	BRCON02
14818	08/01/2023 0:00	20149	761	PALIER FSAFD22522.109+ECS22D2	3-15/16" + COUVERT+FIXING RING	20149	2.000000	BRCON02
14818	08/01/2023 0:00	20149	761	PALIER FSAFD22522.109+ECS22D2	3-15/16" + COUVERT+FIXING RING	20149	2.000000	BRCON02
14818	02/02/2023 0:00	19997	676	PALIER A SEMELLE	3-7/16" + COUVERT + ECS20D2	19997	1.000000	BRCON02
14818	02/02/2023 0:00	19997	651	PALIER A SEMELLE	3-7/16" + COUVERT + ECS20D2	19997	1.000000	BRCON02
14818	19/04/2023 0:00	14493	491	ROULEAU SEUL TRANSPORTEUR	IMPACT 7" DIA X 15" LONG	14493	1.000000	BRCON02
14818	18/04/2023 0:00	14493	491	ROULEAU SEUL TRANSPORTEUR	IMPACT 7" DIA X 15" LONG	14493	1.000000	BRCON02
14818	08/01/2023 0:00	13124	365	ROULEMENT A ROULEAU SPHERIQUE	110MM ID 200MM OD 53MM L	13124	2.000000	BRCON02
14818	08/01/2023 0:00	13124	365	ROULEMENT A ROULEAU SPHERIQUE	110MM ID 200MM OD 53MM L	13124	2.000000	BRCON02
14818	08/01/2023 0:00	13124	365	ROULEMENT A ROULEAU SPHERIQUE	110MM ID 200MM OD 53MM L	13124	-2.000000	BRCON02
14818	31/01/2023 0:00	200948	325	BRAS D'INTERUP.	THERMO RAMSAY ROS	200948	2.000000	BRCON02
14818	02/02/2023 0:00	269827	273	BOITIER DE CONNEXION BNC	VIBRATION, ACCELEROMETRE, 2140	269827	1.000000	BRCON02
14818	02/02/2023 0:00	269804	250	ACCELEROMETRE HS170	SERIES PREMIUM SERIES 100M/VG	269804	4.000000	BRCON02
14818	18/04/2023 0:00	220384	188	ROULEAU 7" SCALE QUALITY	PORTEUR ACIER SERIE 50000	220384	1.000000	BRCON02
14818	14/02/2023 0:00	220384	188	ROULEAU 7" SCALE QUALITY	PORTEUR ACIER SERIE 50000	220384	1.000000	BRCON02
14818	01/02/2023 0:00	220384	188	ROULEAU 7" SCALE QUALITY	PORTEUR ACIER SERIE 50000	220384	4.000000	BRCON02
14818	31/01/2023 0:00	220384	188	ROULEAU 7" SCALE QUALITY	PORTEUR ACIER SERIE 50000	220384	1.000000	BRCON02
14818	08/01/2023 0:00	196892	142	ENS.JOINT 3-15/16	LOR109+B10724+109+40100CR	196892	2.000000	BRCON02
14818	08/01/2023 0:00	196892	142	ENS.JOINT 3-15/16	LOR109+B10724+109+40100CR	196892	2.000000	BRCON02
14818	02/02/2023 0:00	196891	133	ENS.JOINT 3-7/16	LOR102+B10724+102+40085CR	196891	1.000000	BRCON02
14818	19/01/2023 0:00	11499	107	ATTACHE COURROIE 2"	2E 25/BTE	11499	4.000000	BRCON02

Figure 4.3 Données historiques de maintenance du convoyeur

En complément, des données en temps réel ont été extraites via PI SQL à partir des capteurs stratégiquement installés sur le réducteur du convoyeur, permettant de mesurer des paramètres critiques influençant son fonctionnement. Ces capteurs enregistrent en continu les vibrations du moteur et du réducteur, la température de l'huile de lubrification, ainsi que la vitesse de rotation du tambour, fournissant ainsi des indicateurs essentiels pour anticiper d'éventuelles défaillances mécaniques. La Figure 4.4 illustre l'interface de PI SQL Commander Lite, où une requête SQL a été exécutée pour extraire 43 319 enregistrements sur une période de neuf mois. Chaque enregistrement contient des informations détaillées sur l'élément surveillé, l'horodatage et la valeur enregistrée.

Query: 127.3.250.122:external

```

SELECT eh.Name Element, a.Name Attribute, ar.TimeStamp, ar.Value, a.Description
FROM Master.ElementHierarchy eh
INNER JOIN Master.ElementAttribute a ON a.ElementID = eh.ElementID
INNER JOIN Master.ElementArchive ar ON ar.AttributeID = a.ID
WHERE ar.TimeStamp BETWEEN '1-304' AND '1-305'
and eh.Name = 'BRCONVIREDO1' and a.Name = 'TIC4033.PV'

```

Element	Attribute	TimeStamp	Value	Description
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:33:30.263	19.26958	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:34:30.264	19.26547	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:35:30.265	19.26462	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:36:30.266	19.24697	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:37:30.266	19.22219	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:38:30.266	19.21431	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:39:30.263	19.22015	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:40:30.263	19.20224	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:41:30.264	19.19533	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:42:30.265	19.20239	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:43:30.267	19.18627	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:44:30.267	19.17976	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:45:30.268	19.18732	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:46:30.269	19.16063	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:47:30.269	19.1503	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:48:30.269	19.13454	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:49:30.280	19.13664	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:50:30.292	19.12585	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:51:30.292	19.12267	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:52:30.293	19.11601	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:53:30.293	19.10363	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:54:30.293	19.09041	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:55:30.294	19.06426	Valeur de procede - Temp. de Huile 1340-REDO1
BRCONVIREDO1	TIC4033.PV	2023-05-02 14:56:30.295	19.06719	Valeur de procede - Temp. de Huile 1340-REDO1

Query executed successfully

Figure 4.4 Extraction des données en temps réel à partir d'une requête SQL

Afin d'exploiter ces données efficacement, une phase de préparation a été réalisée à l'aide de OpenRefine et de Power Query dans Excel pour organiser et nettoyer les données brutes. Cette étape a permis d'éliminer les valeurs redondantes et d'uniformiser les formats afin d'assurer une analyse cohérente. La Figure 4.5 illustre l'interface d'OpenRefine, où les enregistrements de données sont affichés et filtrés pour garantir une qualité optimale des informations avant leur intégration dans le modèle de maintenance prédictive. L'association de ces différentes sources de données, combinant l'historique des pannes et les mesures en temps réel, constitue ainsi une base robuste pour l'élaboration du modèle de prédiction et l'optimisation des stratégies de gestion du convoyeur.

OpenRefine TIC4033pv csv [Permalien](#) Ouvrir... Exportation Aide

Facette / Filtre Annuler / Rétablir **43193 lignes** Extensions Wikibase

Afficher en tant que : **enregistrements de lignes** Afficher : 5 10 25 50 100 500 1000 lignes
« premier » « précédent » 1 « suivant » « dernier »

Utilisation des facettes et des filtres

Utilisez des facettes et des filtres pour sélectionner des sous-ensembles de vos données sur lesquels agir. Choisissez les méthodes de facettes et de filtres dans les menus situés en haut de chaque colonne de données.

Vous ne savez pas par où commencer?
[Regardez ces screencasts](#)

	Tout	composant	étiquette	date	valeur	description
1.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:52:30.013Z	23.35863	Valeur de procédé - Temp. de l'huile 1340-RED01
2.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:53:30.012Z	23.36907	Valeur de procédé - Temp. de l'huile 1340-RED01
3.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:54:30.015Z	23.34928	Valeur de procédé - Temp. de l'huile 1340-RED01
4.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:55:30.015Z	23.34162	Valeur de procédé - Temp. de l'huile 1340-RED01
5.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:56:30.019Z	23.34637	Valeur de procédé - Temp. de l'huile 1340-RED01
6.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:57:30.016Z	23.35697	Valeur de procédé - Temp. de l'huile 1340-RED01
7.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:58:30.018Z	23.33629	Valeur de procédé - Temp. de l'huile 1340-RED01
8.	★	BRCON01RED01	TIC4033. PV	2023-05-01T14:59:30.019Z	23.33803	Valeur de procédé - Temp. de l'huile 1340-RED01
9.	★	BRCON01RED01	TIC4033. PV	2023-05-01T15:00:30.020Z	23.33605	Valeur de procédé - Temp. de l'huile 1340-RED01
10.	★	BRCON01RED01	TIC4033. PV	2023-05-01T15:01:30.020Z	23.34281	Valeur de procédé - Temp. de l'huile 1340-RED01

Figure 4.5 Interface d'OpenRefine pour le nettoyage des données collectées

4.2.3. Analyse préliminaire

L'analyse détaillée des défaillances du système de transmission de mouvement pour l'année 2023 en lien avec l'historique des interventions a été réalisée pour établir un bilan complet des tâches de maintenances. Il a été constaté que certaines tâches se répètent plus fréquemment que d'autres. L'analyse à base de Pareto a permis de classer les pièces de rechange. La Figure 4.6 décrit le pourcentage cumulé des coûts des pièces défaillantes.




Figure 4.6 Tête de Pareto des pièces de rechange pour l'année 2023 en CA\$

L'étude démontre qu'environ 80 % des coûts totaux de maintenance correspondent à l'ensemble des pièces de rechange Ω , également courroie-réducteur représentent 20% des causes.

Afin de compléter cette analyse des coûts et de mieux comprendre l'impact des interventions de maintenance sur le fonctionnement du convoyeur, une étude de corrélation entre les tâches de maintenance et les données en temps réel a été réalisée. L'objectif est de valider l'exactitude des données collectées en examinant si les variations des paramètres mesurés par les capteurs coïncident avec les événements de maintenance. La Figure 4.7 illustre cette approche en représentant l'évolution de la température du procédé au niveau du réducteur du convoyeur, mesurée toutes les 20 minutes. Les valeurs, exprimées en pourcentage, correspondent à une température normalisée selon la configuration de l'instrumentation.




Figure 4.7 Variation de la température avant et après le changement du réducteur

Ces données ont été extraites via PI SQL, puis visualisées sous Matlab afin de faciliter l'interprétation des tendances. L'analyse met en évidence une baisse marquée de température autour du 3 février 2023, correspondant précisément à une opération de remplacement du réducteur de vitesse. Dans la suite de cette étude, l'accent est porté sur le réducteur étant donné la disponibilité de capteurs mesurant les vibrations instantanées de ce composant. La décision de ne pas inclure la courroie dans l'analyse repose sur le manque de données consistantes à son sujet, ce qui rendrait difficile une approche aussi précise que celle adoptée pour le réducteur. Cette hypothèse se traduit par la prise en considération de données fiables tout en reconnaissant les contraintes de disponibilité de données.

4.2.4. Validation de l'interdépendance entre les paramètres d'états

Pour mener cette étude, on a examiné les corrélations au sein de nos données à l'aide de la matrice de Pearson, révélant des relations potentielles entre différentes variables telles que les mesures de vibration A et B, la température du procédé à l'intérieur du réducteur et la vitesse de rotation du tambour. Cela permis à mieux comprendre les liens sous-jacents et à sélectionner les caractéristiques les plus

pertinentes pour le modèle d'apprentissage automatique sur l'état de la bande transporteuse et du réducteur. La matrice de Pearson, dans la Figure 4.8, représente l'interdépendance des sorties des différents capteurs.




Figure 4.8 Matrice de corrélations des mesures des capteurs

Bien qu'il n'y ait pas de corrélations significatives entre les différents capteurs, on note que la vitesse de rotation exerce une influence sur les vibrations du moteur et du réducteur. Cette interaction complexe suggère que la réduction de la vitesse de rotation pourrait servir d'indicateur pour anticiper une possible diminution d'autres paramètres, telle que la température. Cette observation met en évidence qu'il n'y a pas d'interdépendance entre ces variables en se basant sur leur faible corrélation. Par conséquent, l'objectif principal de cette étude est d'exploiter l'intelligence artificielle, particulièrement les réseaux de neurones récurrents pour prédire les valeurs de vibration future.

4.2.5. Développement du modèle du RNN

Pour relever ces défis, l'architecture proposée, présentée dans la Figure 4.9, constitue un RNN optimisé pour l'analyse prédictive de séries temporelles issues de

données vibratoires recueillies sur une période de huit mois via des capteurs de surveillance sur le réducteur.




Figure 4.9 Architecture de réseau neuronal pour la prédiction des données de vibration

La première couche LSTM, dotée de 64 unités, est déployée pour encoder les dépendances séquentielles intrinsèques des données, grâce à sa capacité à retenir des informations sur des intervalles prolongés et à transmettre cet état interne d'un pas de temps à l'autre. Pour pallier le risque de sur-ajustement à ce type de modélisation, une stratégie de régularisation est mise en œuvre sous la forme de couches de Dropout, lesquelles désactivent de manière probabiliste certains neurones au cours de l'apprentissage, créant ainsi un effet de régularisation sans altérer la dimensionnalité des données traitées. La complexification des caractéristiques extraites est poursuivie par une seconde couche LSTM qui élève la représentation à 256 dimensions, permettant l'extraction de caractéristiques plus abstraites et potentiellement plus informatives. Ensuite, une troisième couche LSTM affine ce traitement en réduisant la dimensionnalité à 128 unités, facilitant ainsi la convergence des caractéristiques essentielles vers une représentation plus dense, propice à la prédiction. Enfin, une couche dense, composée d'une seule unité, fournissant une estimation continue des valeurs vibratoires projetées pour les trois mois à venir. Ce modèle est particulièrement adapté aux tâches prédictives de

régression dans le domaine minier, notamment pour les équipements dont on peut suivre et prédire l'état vibratoire.

4.2.5.1. Evaluation de la performance du RNN

Après avoir entraîné le modèle et généré des prédictions, on a évalué ces prédictions en les comparant aux données réelles. L'Erreur Quadratique Moyenne (MSE) a été utilisée comme indicateur clé. Une MSE faible indique que les prédictions se rapprochent des valeurs réelles et que le modèle a bien saisi les motifs sous-jacents des vibrations. Une analyse qualitative des tendances émergentes dans les prévisions par rapport aux données réelles a été également réalisée. Ceci a permis d'évaluer la capacité du modèle à détecter les variations de comportement des vibrations. En effet, la Figure 4.10 démontre la capacité du modèle à fournir des données exploitables pour la surveillance et la gestion des vibrations. Toutefois, il est primordial d'ajuster les hyperparamètres du modèle pour maximiser la pertinence des résultats et raffiner ses capacités prédictives.




Figure 4.10 L'évolution de la perte entre les données d'entraînement et de validation

4.2.5.2. Ajustement des hyperparamètres et optimisation du modèle

Pour optimiser le modèle d'entraînement, l'ajustement des paramètres clés doit être fait, ce qui s'avère essentiel pour atteindre des performances optimales. Des expérimentations approfondies ont été conduites afin de déterminer les valeurs optimales de ces paramètres. La longueur des séquences d'entrée a été soigneusement évaluée pour trouver un juste équilibre entre la capture des tendances temporelles et la prévention du surapprentissage. De même, le taux de dropout a été finement réglé afin de minimiser la perte tout en préservant la capacité du modèle à généraliser de manière efficace. Le nombre d'époques d'entraînement a été optimisé pour assurer la convergence sans surajustement [69]. Ces ajustements ont permis de réduire la perte à un niveau très bas. De plus, à la suite des fiches de maintenance extraites à partir de la base de données du service de fiabilité de partenaire minier, il a été possible d'intégrer les dates d'interventions antérieures. Ainsi, l'augmentation observée au niveau de vibration au début a été suivie par des interventions correctives afin de stabiliser le système à leur fonctionnement idéal. Ensuite, quelques inspections systématiques ont été effectuées pour maintenir cette stabilité. Du fait, les temps de réparations préventives ont été pris en compte par le modèle RNN. Ces étapes ont permis la synchronisation entre les vibrations prédites et les actions de maintenance effectuées. La Figure 4.11 présente la courbe des vibrations réelles, les dates des interventions systématiques et le comportement vibratoire prédit avec les hyperparamètres optimisés.




Figure 4.11 Données de vibration réelles et prédites en fonction du temps et les maintenances effectuées

Pour garantir une performance optimale du modèle RNN, un ajustement systématique des hyperparamètres a été réalisé en utilisant la technique de Grid Search CV, implémentée via la bibliothèque Scikit-Learn en Python. Cette approche consiste à explorer méthodiquement un espace de recherche défini afin d'identifier la meilleure configuration possible.

Dans notre cas, cette méthode a permis de tester plusieurs combinaisons de paramètres et d'évaluer leurs performances sur un ensemble de validation. Pour chaque configuration, l'erreur moyenne quadratique (MSE) a été calculée afin de sélectionner celle offrant la meilleure convergence et la plus faible erreur de prédiction.

Le Tableau 4.1 ci-dessous récapitule les valeurs explorées ainsi que les choix finaux retenus après optimisation.

Tableau 4.1 Hyperparamètres optimisés du modèle RNN

Hyperparamètre	Plage explorée	Valeur optimisée
Nombre de couches LSTM	(1, 2, 3, 4)	3
Nombre de neurones LSTM	(32, 64, 128, 256, 512)	128 - 256 - 128
Activation (Dense Layer)	('relu', 'tanh', 'sigmoid')	ReLU
Dropout	(0.1, 0.2, 0.3, 0.4, 0.5)	0.3
Optimiseur	('adam', 'sgd', 'rmsprop')	Adam
Taux d'apprentissage	(0.001, 0.0005, 0.0001)	0.0005
Batch size	(16, 32, 64, 128)	64
Nombre d'époques	(20, 50, 100, 200)	100 (avec Early Stopping)
Longueur des séquences	(30, 50, 60, 100)	60
Fraction validation	(0.05, 0.1, 0.2)	0.1
Bruit ajouté aux prédictions	(0.01, 0.05, 0.1, 0.2)	0.05
Intervalle de prévision	(10 min, 20 min, 30 min, 60 min)	20 minutes

L'optimisation des hyperparamètres a significativement amélioré les performances du modèle RNN, réduisant l'erreur de prédiction à 0.016 RMSE. L'architecture retenue, composée de trois couches LSTM (128-256-128 neurones), a permis d'extraire efficacement les tendances vibratoires à court et long terme. L'ajout d'un dropout de 0.3 a limité le sur-apprentissage, garantissant une meilleure généralisation du modèle. Le choix de l'optimiseur Adam avec un taux d'apprentissage de 0.0005 a favorisé une convergence plus stable et progressive. L'entraînement sur 100 époques, avec Early Stopping, a évité les itérations inutiles tout en assurant une performance optimale. Une longueur de séquence de 60 pas de temps a été retenue pour capturer la dynamique des vibrations, tandis qu'un batch size de 64 a amélioré la stabilité de l'apprentissage. Pour refléter les variations naturelles, un bruit de 0.05 a été introduit dans les prédictions, rendant le modèle plus réaliste. Enfin, un intervalle de prévision de 20 minutes a été adopté pour équilibrer fréquence des prédictions et fiabilité des résultats.

4.2.5.3. Exploitation des résultats du RNN et détection des anomalies

L'objectif de cette phase est d'utiliser le résultat du modèle précédemment décrit (vibrations prédites) en conjonction avec les dates de maintenance antérieures comme entrées pour prédire les futures dates de maintenance. En exploitant ces deux entrées, on cherche à anticiper les moments où des interventions de maintenance pourraient être nécessaires, permettant ainsi une planification proactive des actions préventives. Deux modèles de détection d'anomalies, le LOF et l'IF, ont été utilisés pour identifier les dates de maintenance prédites pour les trois prochains mois. Pour bien mettre en évidence l'effet de la fiabilité de chacun des deux modèles, on a observé que le LOF a été capable de détecter une anomalie spécifique en avance de l'Isolation Forest. Plus précisément, il a généré une date présentant une anomalie sur les données de vibrations prédites en amont par l'Isolation Forest. Cette distinction découle d'une configuration spécifique des hyperparamètres pour chaque modèle, conçu pour maximiser leurs performances. De plus, chacun de ces deux modèles a prédit les dates de défaillance tout en classifiant les 29 actions d'interventions antérieures par ordre d'importance selon le type de maintenance. Cependant, il est important de noter que l'écart entre les dates de maintenance prédites par ces deux modèles doit encore faire l'objet d'une évaluation par une équipe pluridisciplinaire.

La Figure 4.12 décrit les résultats de ces deux modèles entraînés par les mêmes entrées.




Figure 4.12 Détections des anomalies à partir de deux méthodes : (a) Local Outlier Factor, (b) la forêt d'isolement

L'efficacité des modèles LOF et Isolation Forest pour la détection des anomalies repose principalement sur le choix judicieux de leurs hyperparamètres. Ces derniers influencent directement la sensibilité du modèle à identifier des points aberrants et à prédire avec précision les dates de maintenance. Afin d'optimiser leurs performances, plusieurs combinaisons d'hyperparamètres ont été testées, en évaluant leur impact sur la qualité des détections. Le Tableau 4.2 ci-dessous présente les plages explorées ainsi que les valeurs optimales retenues pour chaque paramètre.

Tableau 4.2 Hyperparamètres optimisés des modèles LOF et IF

Hyperparamètre	Plage explorée	Valeur optimisée	
		LOF	IF
Nombre de voisins (n_neighbors)	(50, 100, 150, 200, 250)	150	N/A
Contamination	(0.0005, 0.001, 0.002, 0.005)	0.002 (0.2%)	0.0015 (0.15%)
Normalisation des données	(Oui, Non)	Oui (MinMaxScaler)	
Nombre d'arbres (n_estimators)	(100, 200, 300, 400)	N/A	350
Seuil de détection (threshold)	(0.05, 0.10, 0.12, 0.15)	0.12	0.10

L'analyse des hyperparamètres optimisés met en évidence des différences spécifiques entre les deux modèles. LOF, basé sur l'analyse du voisinage local, a nécessité un réglage précis du nombre de voisins (150) afin de capter efficacement les tendances vibratoires tout en réduisant le bruit. Une contamination de 0.002 (0.2%) a été adoptée pour identifier un nombre équilibré d'anomalies, sans pour autant sur-détecter des variations normales. En revanche, Isolation Forest, qui repose sur un ensemble d'arbres décisionnels, a montré une meilleure capacité à isoler les points aberrants en augmentant le nombre d'arbres à 350. La contamination a été légèrement réduite à 0.0015 (0.15%) pour limiter les faux positifs et garantir une détection plus fiable des anomalies critiques. Pour garantir la cohérence des prédictions, une normalisation des données (MinMaxScaler) a été appliquée aux deux modèles afin de standardiser les échelles de valeurs. De plus, le seuil de détection a été fixé à 0.12 pour LOF et 0.10 pour IF, IF étant plus efficace pour isoler des points extrêmes avec une marge de confiance plus stricte. Ces optimisations ont renforcé la précision et la fiabilité de la détection des anomalies. Elles mettent en évidence la sensibilité accrue de LOF, qui a détecté certaines anomalies avant IF. Cela souligne l'importance d'un ajustement précis des hyperparamètres pour adapter chaque modèle aux variations vibratoires.

4.3. Digitalisation et prévision de la maintenance des camions miniers

4.3.1. Mise en contexte

Les conditions d'exploitation dans le nord du Canada sont particulièrement rigoureuses, mettant à rude épreuve la fiabilité des équipements. Les camions miniers tout-terrain, en particulier, sont fréquemment sujets à divers types de défaillances, notamment des problèmes liés au système de propulsion et une usure accrue des pneus, comme l'illustre la Figure 4.13. Ces défis entraînent une consommation excessive de carburant pendant les opérations. De plus, les coûts de maintenance représentent une part croissante des coûts d'exploitation, les arrêts de travail étant souvent causés par des pannes motrices. Bien que ces camions soient suffisamment robustes pour continuer à fonctionner malgré des problèmes de suspension, ces contraintes nécessitent une approche proactive pour optimiser leur performance et réduire les interruptions.



Figure 4.13 (a) Usure des pneus ; (b) Dysfonctionnement du système hydraulique de propulsion

Dans ce contexte, la digitalisation des données de maintenance et la mise en œuvre d'un modèle prévisionnel basé sur Power BI apparaissent comme des solutions stratégiques pour répondre à ces défis. Cette approche vise à améliorer la collecte, l'analyse et la visualisation des données de télémétrie, tout en permettant une anticipation efficace des défaillances et une gestion optimisée des interventions de maintenance.

4.3.2. Collecte et préparation des données

La collecte et la préparation des données constituent des étapes fondamentales pour assurer la qualité des analyses et des modèles développés. Dans le cadre de cette étude, deux catégories distinctes de données ont été collectées : celles relatives aux opérations de maintenance et celles issues de la télémétrie en temps réel des camions miniers. Ces ensembles de données, complémentaires, jouent un rôle clé dans la mise en place des outils numériques et des modèles prévisionnels développés. Tandis que les données de maintenance permettent de structurer les opérations en vue d'une digitalisation interactive, les données de télémétrie offrent une vue détaillée et dynamique des performances opérationnelles des équipements. Les sections suivantes détaillent ces deux types de données et leur préparation respective.

4.3.2.1. Données relatives aux opérations de maintenance

Dans le cadre de cette étude, les données relatives aux opérations de maintenance ont été fournies par le service de maintenance du partenaire industriel Canadian Malartic. Ces documents contiennent des informations essentielles sur les procédures de maintenance et sur le fonctionnement des sous-systèmes d'une pompe utilisée dans les camions miniers. En particulier, une gamme détaillant les étapes nécessaires à la maintenance d'une boîte d'engrenages de transmission de la pompe a été partagée, ainsi qu'un document technique décrivant les mécanismes des sous-systèmes hydrauliques associés à cette pompe.

Ces données constituent une base précieuse pour la digitalisation des processus de maintenance. Une vue éclatée de l'ensemble de la pompe est illustrée à la Figure 4.14, mettant en évidence les différents composants du système.

L'objectif est de se concentrer spécifiquement sur la boîte d'engrenages de transmission de la pompe dans le cadre de la digitalisation, afin de structurer les informations pour une meilleure intégration dans une interface interactive sur Power BI. Ce processus de digitalisation vise à rendre les gammes de maintenance

accessibles et intuitives pour les équipes opérationnelles, tout en facilitant le suivi et l'exécution des tâches de maintenance.




Figure 4.14 Vue éclatée des composants de la pompe hydraulique, incluant la boîte d'engrenage de transmission

La préparation de ces données a nécessité un travail de structuration afin d'extraire les étapes clés, de les organiser de manière hiérarchique et de les adapter au format requis pour leur intégration dans un environnement numérique interactif. Ces étapes sont synthétisées dans le Tableau 4.3, qui présente les figures associées et leurs descriptions respectives pour chaque phase du processus.

Tableau 4.3 Étapes de maintenance et description des composants

Éléments visuels	Description des étapes
	Installation des roulements cylindriques sur l'arbre principal, avec nettoyage préalable des composants pour garantir un alignement optimal et une rotation fluide, en utilisant un outillage spécialisé et en respectant les tolérances dimensionnelles.
	Insertion précise de l'arbre principal, équipé de ses roulements, dans le logement de la boîte d'engrenage, après un nettoyage minutieux pour assurer des surfaces de contact propres et optimales.
	Installation de l'arbre principal et de ses roulements dans le carter à l'aide d'un système de levage sécurisé, en veillant à préserver l'intégrité des surfaces d'appui et des roulements.
	Contrôle de l'alignement de l'arbre principal et des roulements à l'aide d'un pied à coulisse numérique, avec vérification des dimensions critiques et correction immédiate des écarts pour assurer un assemblage conforme.
	Mesure des dimensions critiques de la bride de fixation à l'aide d'un pied à coulisse pour garantir le respect des tolérances et éviter tout désalignement ou contrainte mécanique lors de l'assemblage final.

Après la collecte des documents nécessaires à la maintenance, une étape clé consiste à les numériser et à organiser les informations sous forme de fichiers au format CSV. Cette structuration permet une intégration fluide dans l'environnement interactif de Power BI, facilitant ainsi l'analyse et le suivi des opérations de maintenance. Le tableau 4.15 ci-dessous présente un extrait du fichier CSV structuré. Il regroupe les informations essentielles, notamment les identifiants d'emplacement, les noms des opérations, les descriptions détaillées des étapes et les outils nécessaires à chaque intervention. Ce format facilite une synchronisation efficace entre Power BI et Synoptics Designer, garantissant une représentation fidèle et un alignement précis de chaque étape de la gamme de maintenance dans l'interface numérique.

Identifiant d'emplacement (ID)	Nom de l'opération	Étapes de l'opération	Outils nécessaires
1	Assemblage des roulements	1- "Huiler l'arbre d'entraînement à la position 190°." 2- "Chauffer le roulement auto-alignant à la position 390° à environ 100°C à l'aide d'un four, puis le fixer sur l'arbre." 3- "Installer la rondelle de support à la position 500 et la sécuriser avec le circlip à la position 460°."	1- Huile (par ex., SAE 90). 2- Four chauffant. 3- Circlip pliers A4.
2	Assemblage de la bague de roulement	1- "Dégraisser l'arbre d'entraînement avec un nettoyant (par ex., Noba) et appliquer de l'adhésif (par ex., Loctite 648)." 2- "Chauffer la bague de roulement à la position 270° à environ 80°C et la fixer sur l'arbre."	1- Loctite 648. 2- Nettoyant (Noba). 3- Four chauffant.
3	Insertion de l'arbre	1- "Placer le support de roulement à la position 050 sur le dispositif n°7 et appliquer de l'huile sur le trou." 2- "Insérer l'arbre d'entraînement dans le support à roulement à l'aide d'un crochet et d'un œil boulonné."	1- Huile (par ex., SAE 90). 2- Crochet M24. 3- Crochet (jusqu'à 150 kg).
4	Mesure des surfaces externes/roulements	1- "Déterminer la profondeur entre les surfaces externes et le bord extérieur du roulement conique."	1- Jauge de profondeur numérique. 2- Jauge de mesure : 150 mm. 3- Lecture : 0,01 mm.
5	Vérification dimensionnelle des roulements/couvercles	1- "Attention ! La tolérance est impérative : +0 mm - 0,2 mm." 2- "Il ne doit y avoir aucune pénétration." 3- "Le jeu axial maximum est de 0,02 mm."	1- Jauge de profondeur numérique. 2- Jauge de mesure : 150 mm. 3- Lecture : 0,01 mm.
6	Assemblage du joint radial	1- "Lubrifier le joint radial à la position 420 avec de la graisse et l'insérer dans le couvercle d'étanchéité à la position 040 à l'aide de la plaque à mandrin n°4."	1- Plaque à mandrin n°4.

Figure 4.15 Extrait du fichier CSV des opérations de maintenance et des outils requis

4.3.2.2. Données de surveillance télématique en temps réel

Les données collectées, issues des capteurs installés sur le système de transmission de la pompe hydraulique des camions miniers, ont été extraites, centralisées et organisées dans la salle de contrôle dédiée [70]. Ces informations, disponibles en

fichiers CSV, permettent de structurer l'historique des opérations de maintenance et de surveiller en temps réel les performances des machines. Chaque fichier regroupe des informations spécifiques, qui sont présentées et décrites dans les tableaux suivants pour une analyse détaillée et une meilleure exploitation des données.

Les premières données concernent les mesures télémétriques, regroupées dans le Tableau 4.4. Ce fichier contient des paramètres critiques tels que le voltage, la rotation, la pression et les vibrations, associés à des identifiants uniques de machine et des horodatages précis. Ces informations permettent de surveiller en continu les conditions opérationnelles des camions miniers et d'identifier rapidement des variations anormales.

Tableau 4.4 Paramètres opérationnels de la boîte d'engrenage

Date / Heure	Machine ID	Voltage (V)	Rotation (RPM)	Pression (Pa)	Vibration (mm/s ²)
01/01/2024 6 :00	1	176,22	418,50	113,08	45,09
01/01/2024 11 :00	2	191,26	369,74	101,22	45,62
01/01/2024 18 :00	3	168,05	521,45	107,37	34,61
01/01/2024 22 :00	4	153,38	428,31	103,90	40,31
02/01/2024 6 :00	5	142,53	493,88	91,46	39,55
02/01/2024 11 :00	6	160,24	434,92	96,13	43,49

Ensuite, les défaillances des machines sont recensées dans le Tableau 4.5, où chaque panne est associée à un composant spécifique (par exemple, comp_1, comp_2), à une machine identifiée et au moment précis de l'incident. Ces informations facilitent l'analyse des défaillances, en identifiant les composants les plus susceptibles de dysfonctionner et en soutenant la planification d'actions correctives adaptées.

Tableau 4.5 Composants défaillants de la boîte d'engrenages par machine

Date / Heure	Machine ID	Composants défaillants
05/01/2024 6 :00	1	Comp_4
19/03/2024 6 :00	2	Comp_1
07/01/2024 6 :00	3	Comp_2
17/01/2024 6 :00	4	Comp_1
17/01/2024 6 :00	5	Comp_2
24/01/2024 6 :00	6	Comp_4

Le système a relevé diverses erreurs, chacune caractérisée par un identifiant unique et un moment précis de détection. Par exemple, ces erreurs peuvent inclure des alertes de surcharge sur le système hydraulique, des fluctuations anormales de pression, des vibrations dépassant les seuils tolérés ou encore des écarts de rotation non conformes. Ces informations jouent un rôle central dans l'identification des anomalies et la planification d'interventions de maintenance proactive. En regroupant ces données, comme le montre le Tableau 4.6, il devient possible de limiter les interruptions imprévues et d'optimiser la gestion des équipements.

Tableau 4.6 Liste des erreurs identifiées par machine

Date / Heure	Machine ID	Erreur ID
03/01/2024 7 :00	1	Erreur_1
12/01/2024 14 :00	2	Erreur_4
06/01/2024 6 :00	3	Erreur_2
04/01/2024 3 :00	4	Erreur_3
08/01/2024 6 :00	5	Erreur_2
26/01/2024 12 :00	6	Erreur_1

Finalement, le Tableau 4.7 regroupe les caractéristiques descriptives des machines, incluant leur modèle et leur âge en années. Ces informations permettent de classer les camions miniers selon des modèles spécifiques, tels que "Modèle_3" ou "Modèle_4", qui reflètent des configurations techniques variées. Par exemple, "Modèle_3" pourrait correspondre à des véhicules destinés à des opérations intensives, tandis que "Modèle_4" pourrait être conçu pour des environnements

spécifiques. Cette classification est essentielle pour analyser les performances des équipements, évaluer leur fiabilité en fonction de leur âge, et identifier des corrélations éventuelles entre le type de modèle et les défaillances ou erreurs recensées.

Tableau 4.7 Informations sur les modèles et l'ancienneté des camions miniers

Machine ID	Modèle	Age (ans)
1	Modèle_3	18
2	Modèle_4	7
3	Modèle_3	8
4	Modèle_3	7
5	Modèle_3	2
6	Modèle_3	7

La préparation des données de télémétrie, effectuée avec Power Query dans Power BI, a assuré leur qualité et leur cohérence pour les analyses et modèles prédictifs. Ce processus comprenait la détection et la correction des anomalies dans les paramètres tels que le voltage, la rotation, la pression et les vibrations, ainsi que l'imputation des données manquantes à l'aide de méthodes comme l'interpolation linéaire pour maintenir la continuité des séries chronologiques.

Un soin particulier a été apporté à la standardisation des formats de date et d'heure, garantissant une uniformité dans la colonne "**Date_et_heure**". Cela a facilité l'agrégation des données et leur alignement avec d'autres sources, si nécessaire. De plus, les unités des paramètres opérationnels ont été vérifiées et unifiées afin de garantir leur conformité avec les normes industrielles, ce qui est essentiel pour une analyse fiable. Comme illustré dans la Figure 4.16, le résultat de ces ajustements montre une préparation des données sans erreurs ni valeurs manquantes, prête pour des analyses approfondies. Des indicateurs supplémentaires, tels que des moyennes mobiles, peuvent également être calculés pour enrichir les analyses ultérieures.




Figure 4.16 Résultats de la préparation des données télémétriques dans Power Query

La barre de validation de Power Query permet de visualiser rapidement la qualité des données et confirme que le traitement a permis d’éliminer toutes les anomalies et incohérences. Cette étape constitue un fondement essentiel pour l’intégration des données dans des visualisations interactives et des modèles prévisionnels, garantissant une exploitation optimale des informations collectées.

4.3.3. Analyse exploratoire des données de télémétrie

Avant d’initier le processus de modélisation prédictive, une analyse exploratoire des données est réalisée afin de mieux comprendre les caractéristiques des séries chronologiques collectées. Cette étape permet d’explorer la distribution des données, d’identifier les tendances, les relations potentielles entre les paramètres, ainsi que de détecter d’éventuelles anomalies ou incohérences résiduelles. L’objectif principal est d’extraire des informations pertinentes pour orienter efficacement les étapes ultérieures de modélisation et de prise de décision.

Pour approfondir cette exploration, un résumé statistique des données collectées est présenté dans la Figure 4.17. Celui-ci fournit une synthèse des principales métriques descriptives, notamment la moyenne, l’écart-type, les valeurs extrêmes, ainsi que

les quartiles pour chaque paramètre mesuré, tels que le voltage, la rotation, la pression et la vibration.

Statistique	MachineID	Voltage	Rotation	Pression	Vibration
Std	28,87	15,51	52,67	11,05	5,37
Min	1,00	97,33	138,43	51,24	14,88
0,25	25,75	160,30	412,31	93,50	36,78
Mean	50,50	170,78	446,61	100,86	40,39
0,5	50,50	170,61	447,56	100,43	40,24
0,75	75,25	181,00	482,18	107,56	43,78
Max	100,00	255,12	695,02	185,95	76,79
Count	876 100,00	876 100,00	876 100,00	876 100,00	876 100,00

Figure 4.17 Statistiques descriptives des données opérationnelles

Après le prétraitement des séries chronologiques, une analyse approfondie est réalisée pour identifier les tendances et comportements spécifiques à chaque paramètre, tels que la vibration, la rotation, la pression et le voltage. Cette étape vise à extraire des informations significatives en lien avec les performances des camions miniers tout en mettant en évidence les variations pouvant signaler des problèmes mécaniques ou électriques. La comparaison entre les données brutes et lissées permet d'isoler les signaux pertinents tout en réduisant les effets de bruit, facilitant ainsi la prise de décisions éclairées pour les opérations de maintenance.

Pour analyser les données de vibration, on commence par observer les deux graphiques présentés dans la Figure 4.18. Le graphique (a) représente les données brutes collectées sur une année, montrant des variations importantes des valeurs, tandis que le graphique (b) illustre les moyennes mobiles appliquées pour lisser les fluctuations et mettre en évidence les tendances générales. Les valeurs de vibration oscillent entre 38 mm/s² et 42 mm/s², avec des pics plus marqués autour des périodes de maintenance signalées. Ces variations peuvent indiquer des déséquilibres mécaniques ou des usures anormales, particulièrement au niveau des roulements ou des dents de la boîte d'engrenage. Par exemple, les pics de vibration

observés en mars 2024 et octobre 2024 coïncident avec des interventions signalées sur les composants défectueux (composant_1 et composant_4).




Figure 4.18 Évolution temporelle des vibrations : (a) données brutes et (b) moyennes lissées

La rotation, mesurée en tours par minute (tr/min), constitue un indicateur essentiel pour évaluer le fonctionnement de la boîte d'engrenage. Comme le montrent les graphiques de la Figure 4.19, les données révèlent des variations régulières autour d'une valeur moyenne proche de 445 tr/min. Ces fluctuations peuvent indiquer des phases de dégradation progressive des composants, comme observé entre avril et mai 2024, suivies d'une stabilisation après une maintenance effectuée début juin 2024.




Figure 4.19 Variation moyenne de la rotation de la boîte d'engrenage en fonction du temps

La mesure de la pression dans le système hydraulique, exprimée en Pascal (Pa), permet de surveiller le fonctionnement des composants critiques, tels que les pompes hydrauliques et les régulateurs de débit, au sein de la boîte d'engrenage. Comme le montre la Figure 4.20, les données mettent en évidence des variations autour d'une valeur moyenne de 101 Pa. Des pics inhabituels sont observés en juillet 2024 et janvier 2025, pouvant indiquer des anomalies telles qu'un déséquilibre de pression dans les circuits hydrauliques ou une usure des joints d'étanchéité.




Figure 4.20 Pression moyenne du système hydraulique (Pa) au cours du temps

L'alimentation électrique du système de transmission, mesurée en volts (V), reflète la santé du réseau alimentant des composants tels que les actionneurs et les capteurs. La Figure 4.21 révèle des fluctuations modérées autour de 171 V, traduisant un fonctionnement globalement stable, bien que des variations notables aient été enregistrées, notamment une hausse exceptionnelle en janvier 2024, probablement liée à une surcharge électrique ou une surchauffe nécessitant un diagnostic approfondi des circuits.




Figure 4.21 Fluctuations du voltage moyen (V) au cours du temps

Pour approfondir l'analyse des relations entre les paramètres opérationnels, une matrice de corrélation a été établie, illustrée à la Figure 4.22. Cette matrice met en évidence les interactions entre la pression, la rotation, la vibration et le voltage à travers des graphiques de dispersion et des histogrammes. L'analyse révèle que les relations entre les paramètres sont généralement faibles, avec une dispersion importante des points dans la majorité des paires de variables, indiquant une indépendance relative.




Figure 4.22 Matrice de dispersion et distributions des paramètres opérationnels

Les résultats révèlent des relations globalement faibles entre les différents paramètres, comme l'indiquent les répartitions des points de dispersion autour des axes. Par exemple :

- **Pression et vibration** : Une corrélation modérée suggère que les fluctuations de pression influencent les vibrations, possiblement dues à des déséquilibres hydrauliques.
- **Vibration et rotation** : Une légère corrélation est perceptible, suggérant une interaction mécanique possible entre les vibrations générées et la rotation des composants.

- **Voltage et pression :** Une relation modérée est visible, probablement en lien avec l'effet des variations électriques sur la stabilité du système hydraulique.

les histogrammes en diagonale confirment la variabilité propre à chaque paramètre. La pression montre une distribution asymétrique, tandis que le voltage et la rotation présentent une distribution plus symétrique. Ces observations soulignent l'importance d'une analyse individualisée pour chaque paramètre dans les modèles prédictifs, tels que Holt-Winters, afin de capturer les dynamiques spécifiques tout en intégrant les interactions identifiées pour une compréhension complète du fonctionnement de la boîte d'engrenage.

4.3.4. Détection d'anomalies dans les données de télémétrie

La détection des anomalies dans les données de télémétrie constitue une étape essentielle pour assurer la fiabilité des systèmes de transmission. En utilisant les outils analytiques de Power BI, comme l'arborescence hiérarchique (Decomposition Tree Visual) et les algorithmes de détection d'anomalies, il est possible d'identifier des écarts significatifs dans des paramètres tels que la pression, la rotation, la vibration et le voltage. Ces anomalies, indicatives de dysfonctionnements, permettent des interventions proactives pour prévenir des pannes coûteuses. La Figure 4.23 illustre une analyse hiérarchique des données de vibration, mettant en évidence des variations anormales et leurs causes.




Figure 4.23 Analyse hiérarchique des anomalies dans les données de vibration

L'analyse hiérarchique, appliquée aux données de vibration, met en évidence un pic de vibration maximal de 76,79 mm/s², enregistré le 6 avril 2024. Ce pic est directement lié à des fluctuations spécifiques des paramètres opérationnels, notamment une pression de 88,17 Pa, une rotation de 373 tr/min et un voltage de 174,84 V. Ces observations confirment l'efficacité de l'arborescence hiérarchique pour isoler les facteurs contributifs majeurs et orienter les priorités en maintenance [71]. En identifiant avec précision les sources potentielles des anomalies, cet outil constitue un levier stratégique pour garantir la continuité opérationnelle et réduire les risques de pannes.

L'identification des irrégularités dans les séries chronologiques de télémétrie repose sur le modèle SR-CNN, intégré à Power BI et basé sur un algorithme détaillé dans la méthodologie. Cette approche permet de détecter des écarts significatifs, essentiels pour anticiper les dysfonctionnements et optimiser les performances des systèmes surveillés. Pour la vibration, comme présenté dans la Figure 4.24, les résultats affichent une précision ajustée à un seuil de confiance de 93 %. Cette sensibilité permet de capter efficacement les variations anormales tout en réduisant le risque de faux positifs. Les résultats, expliqués par les données de défaillance « Failure », suggèrent une corrélation directe entre les pics de vibration.




Figure 4.24 Détection des anomalies de vibration avec seuil de 93 %

Chaque point rouge représente une anomalie identifiée par le modèle SR-CNN, qui a détecté un dépassement des seuils attendus de manière statistiquement significative. Par exemple, une anomalie enregistrée en juillet 2024 avec une valeur de 41,03 mm/s² dépasse la plage normale attendue de 40,01 à 40,85 mm/s².

Après l'analyse des anomalies détectées pour la vibration, la Figure 4.25 présente les résultats obtenus pour les autres paramètres opérationnels. En s'appuyant sur la transformée de Fourier logarithmique pour examiner les fréquences dominantes et le calcul du résidu spectral, l'algorithme identifie efficacement les écarts significatifs par rapport à la moyenne.




Figure 4.25 Détection des anomalies dans les paramètres opérationnels : (a) rotation, (b) pression et (c) voltage

Les résultats présentés ci-dessus, mettent en évidence les anomalies détectées dans les séries temporelles des paramètres opérationnels restants : rotation, pression et

voltage. Ces détections, obtenues via le modèle SR-CNN, reflètent des fluctuations anormales spécifiques, révélant des comportements inattendus liés aux dynamiques mécaniques et électriques du système. En complément de la vibration, ces paramètres offrent une perspective élargie sur les dysfonctionnements potentiels affectant divers sous-systèmes critiques. L'intégration des hyperparamètres spécifiques, tels que la résolution spectrale et la taille de la fenêtre glissante, a permis d'ajuster avec précision la sensibilité de l'algorithme, garantissant une identification fiable des anomalies [72]. Cette configuration, couplée à l'analyse multivariée des cartes de saillance générées par le modèle, valide non seulement la pertinence des résultats obtenus, mais aussi leur utilité pour orienter des stratégies de maintenance ciblées, en anticipant efficacement les défaillances critiques des systèmes surveillés.

4.3.5. Prévision des séries temporelles avec le modèle Holt-Winters

L'anticipation des tendances et des variations des paramètres opérationnels est essentielle pour une maintenance prédictive efficace. Le modèle Holt-Winters, intégré dans Power BI, permet de modéliser les séries temporelles en tenant compte des tendances et de la saisonnalité des données. Cette approche repose sur un lissage exponentiel triplement adapté pour capturer les évolutions à court et long terme, offrant ainsi une vision prévisionnelle fiable.

La suite présente les résultats obtenus à partir des données de télémétrie, illustrant les prévisions du modèle Holt-Winters appliquées aux paramètres clés du système. La Figure 4.26 illustre les résultats de la prévision des vibrations obtenus, en mettant en évidence les différentes phases du processus de prévision. L'analyse des résultats repose sur l'interprétation des données de test et validation, des prévisions générées, ainsi que des plages de confiance, tous influencés par les paramètres du modèle. Dans la première phase (zone en bleu), on distingue les données historiques utilisées pour entraîner le modèle. Cette période permet au modèle de calibrer les coefficients de lissage, en ajustant la tendance et la saisonnalité. L'algorithme Holt-Winters exploite ces données pour estimer les composantes sous-jacentes et ajuster

les pondérations des paramètres de lissage. Une mauvaise calibration sur cette phase pourrait entraîner des prévisions instables ou biaisées. La ligne noire représente les valeurs prédites, tandis que l'enveloppe grise définit les plages de confiance associées aux prévisions.

- **Impact du réglage de l'intervalle de confiance (85 %) :**

Dans le cadre du modèle Holt-Winters, cet intervalle est influencé par la variance résiduelle des erreurs de prévision. Un intervalle trop large indiquerait une grande incertitude dans les projections, tandis qu'un intervalle trop restreint pourrait ne pas refléter la variabilité réelle des données.

- **Évolution de la plage de confiance :**

L'élargissement progressif de cette plage est une conséquence du caractère récursif du modèle, où chaque nouvelle prédiction dépend des précédentes, amplifiant l'incertitude au fur et à mesure de l'horizon de prévision.

La section en jaune représente les prévisions produites sur une période de 14 mois, correspondant à la longueur de la prévision définie dans les paramètres du modèle.

Dans le modèle Holt-Winters :

- La tendance identifiée dans les données passées est extrapolée en fonction des coefficients de lissage, avec une pondération progressive des nouvelles observations.
- La saisonnalité détectée (53 points) est répétée dans les projections, assurant une continuité des cycles périodiques observés.




Figure 4.26 Prévision des vibrations basée sur le modèle Holt-Winters

Après l'analyse des prévisions de vibration, le modèle Holt-Winters a été appliqué à la pression, la rotation et le voltage pour anticiper leurs évolutions. La Figure 4.27 illustre la transition des données historiques vers les projections futures.




Figure 4.27 Prévisions des paramètres opérationnels à l'aide du modèle Holt-Winters – (a) Rotation, (b) Pression, (c) Voltage

L'application du modèle Holt-Winters a nécessité un ajustement des paramètres de réglage en fonction des dynamiques propres à chaque série temporelle [73]. Ces ajustements visent à optimiser la capture des tendances, des variations saisonnières et des fluctuations locales. Le Tableau 4.8 présente une comparaison des configurations appliquées, mettant en évidence les différences d'adaptation du modèle et leur impact sur la prévision.

Tableau 4.8 Comparaison des paramètres de réglage Holt-Winters

Paramètres opérationnels	Longueur de la prévision (mois)	Fenêtre d'exclusion (Points)	Caractère saisonnier (Points)	Intervalle de confiance (%)
Vibration	14	6	53	85
Rotation	12	7	46	95
Pression	10	5	57	95
Voltage	10	6	53	95

Les paramètres de réglage du modèle Holt-Winters, présentés dans le tableau, révèlent des ajustements spécifiques en fonction des caractéristiques propres à chaque série temporelle. La longueur de la prévision varie en fonction de la stabilité des données : pour la vibration, une prévision sur 14 mois a été retenue, tandis que les autres paramètres affichent des horizons plus courts (10 à 12 mois), traduisant une sensibilité accrue aux fluctuations opérationnelles.

La fenêtre d'exclusion, ajustée entre 5 et 7 points, correspond aux données ignorées à la fin de la série temporelle et utilisées pour la validation du modèle. Une fenêtre plus grande, comme pour la rotation (7 points), réserve davantage de données pour l'évaluation du modèle, ce qui est utile en présence de variations marquées. À l'inverse, une fenêtre plus réduite, comme pour la pression (5 points), signifie que le modèle s'appuie sur une période d'apprentissage plus large pour mieux capturer les tendances globales. Cet équilibre est important : une fenêtre trop grande limite l'apprentissage, tandis qu'une fenêtre trop petite réduit la fiabilité de l'évaluation.

Concernant le caractère saisonnier, la pression affiche une périodicité plus marquée (57 points), indiquant des cycles récurrents plus longs, tandis que la rotation et le voltage suivent des comportements plus réguliers (46 et 53 points). L'intervalle de confiance, fixé à 95 % pour la majorité des paramètres, témoigne d'une variabilité importante dans les projections, à l'exception de la vibration (85 %), où les prévisions sont plus resserrées en raison de la stabilité des tendances historiques.

Ces ajustements influencent directement la dynamique du modèle : un caractère saisonnier plus long induit une inertie accrue dans l'adaptation des prévisions, tandis qu'un intervalle de confiance plus large traduit une plus grande incertitude [74]. L'analyse des résultats montre ainsi que le modèle Holt-Winters s'adapte différemment selon les paramètres, captant efficacement les tendances dominantes tout en tenant compte des spécificités structurelles de chaque variable.

4.3.6. Conception des tableaux de bord interactifs

L'exploitation efficace des données issues de la maintenance 4.0 repose sur une visualisation dynamique et interactive, permettant aux opérateurs et aux décideurs d'accéder rapidement aux informations pertinentes. Dans cette optique, Power BI a été utilisé pour concevoir des tableaux de bord interactifs, intégrant à la fois les résultats des analyses prévisionnelles et les informations relatives aux interventions de maintenance.

4.3.6.1. Architecture des relations entre les données

La modélisation des relations entre les différentes tables constitue une étape fondamentale dans la conception d'un tableau de bord interactif. Elle permet de structurer les données pour faciliter l'analyse et la navigation entre les différentes sources d'information [75]. L'objectif principal de cette approche relationnelle est de garantir une cohérence des données et d'optimiser la performance des requêtes et des visualisations dynamiques, comme illustré dans la Figure 4.28.




Figure 4.28 Modélisation relationnelle des données

Les relations établies suivent une logique directionnelle adaptée aux besoins analytiques. Le **MachineID** assure la mise à jour réciproque des filtres entre les tables dans les relations bidirectionnelles, permettant ainsi d’explorer les corrélations entre les anomalies détectées et les mesures de fonctionnement en temps réel. À l’inverse, les relations unidirectionnelles, notamment entre la gamme de maintenance et les autres tables, garantissent une segmentation structurée des informations sans risque de rétroaction indésirable. Cette hiérarchisation relationnelle permet d’accéder aux données pertinentes sans compromettre la performance des requêtes.

4.3.6.2. Tableau de bord de la gamme de montage de la pompe

L’intégration des données de maintenance dans un tableau de bord interactif optimise la visualisation des étapes clés du montage du système d’entraînement de la pompe. Conçu sous Power BI, cet outil centralise les procédures détaillées et les ressources nécessaires, facilitant ainsi leur consultation et leur mise en application.

La Figure 4.29 présente l'architecture de ce tableau de bord et son interaction avec l'environnement opérationnel.




Figure 4.29 Tableau de bord interactif pour l'installation du système d'entraînement

Ce tableau de bord, offre une interface interactive et ergonomique permettant aux équipes de maintenance d'accéder aux informations détaillées pour chaque étape standardisée du processus d'installation. En sélectionnant une étape spécifique, les utilisateurs peuvent consulter les détails correspondants ainsi que les outils requis pour sa réalisation. Cette fonctionnalité interactive améliore considérablement l'efficacité et la précision des procédures de maintenance en consolidant l'ensemble des données essentielles, incluant des supports visuels et des instructions détaillées [76]. Son intégration dans le processus de maintenance réduit les erreurs d'exécution en minimisant les risques liés aux objets étrangers (Foreign Object Debris - FOD), ce qui contribue à renforcer la sécurité des opérations minières. De plus, cet outil constitue un support précieux pour les opérateurs moins expérimentés en leur fournissant des directives claires et structurées, facilitant ainsi l'exécution correcte des tâches de maintenance. Grâce à sa publication sur Power BI Service, ce tableau de bord garantit une synchronisation en temps réel avec des appareils mobiles sous iOS ou Android, permettant aux équipes d'intervenir avec plus de réactivité et de flexibilité, que ce soit en zone souterraine ou dans d'autres contextes d'intervention [77].

4.3.6.3. Tableau de bord des prévisions et indicateurs clés

L'exploitation d'un tableau de bord interactif optimise l'analyse des tendances opérationnelles et la surveillance en temps réel des équipements. En intégrant les prévisions du modèle Holt-Winters et des indicateurs clés, cette interface facilite l'anticipation des défaillances et l'optimisation des stratégies de maintenance. La Figure 4.30 met en avant son interactivité, avec des filtres dynamiques permettant une analyse ciblée des tendances par Machine ID et périodes spécifiques.




Figure 4.30 Tableau de bord interactif des paramètres et défaillances

Les graphiques de vibration, rotation, pression et voltage offrent une lecture claire des tendances historiques et des prévisions à court et moyen terme. La bande grise d'incertitude représente la plage de confiance des prévisions, permettant d'évaluer la fiabilité des projections. Selon la Figure 4.26, la sélection du **MachineID_1** permet d'afficher les informations spécifiques à cette unité, facilitant ainsi une analyse ciblée et une intervention plus efficace sur l'équipement concerné [78].

L'interface contribue également à une gestion proactive de la maintenance. L'affichage du nombre de composants défaillants par catégorie permet d'identifier rapidement les équipements nécessitant une intervention immédiate. L'intégration

des prévisions favorise une approche de maintenance conditionnelle et prédictive, réduisant ainsi les coûts et limitant les arrêts imprévus. En analysant l'évolution des indicateurs, les responsables peuvent ajuster les programmes de maintenance préventive afin de minimiser l'usure prématurée des composants.

Un autre aspect clé concerne la gestion des stocks et des pièces de rechange. L'anticipation des tendances de défaillance optimise la gestion des stocks et prévient les ruptures critiques [79]. La corrélation entre les anomalies des paramètres et les pannes permet également d'ajuster les niveaux de réapprovisionnement en pièces essentielles, garantissant ainsi une continuité opérationnelle sans perturbations majeures.

4.4. Conclusion

Cette étude a démontré l'efficacité des modèles Local Outlier Factor (LOF) et Isolation Forest (IF) pour la détection précoce des anomalies dans les équipements miniers. Le modèle LOF s'est avéré particulièrement pertinent pour identifier des anomalies spécifiques, permettant ainsi d'anticiper efficacement les interventions de maintenance. En complément, l'intégration d'un modèle de prédiction basé sur les réseaux de neurones récurrents (RNN) a renforcé la fiabilité des prédictions, optimisant la maintenance préventive. Les résultats obtenus, validés en collaboration avec l'équipe de maintenance et de fiabilité du partenaire minier, ont confirmé leur pertinence et leur applicabilité, contribuant à une réduction significative des coûts liés aux arrêts imprévus dans l'industrie minière. Par ailleurs, la digitalisation des données de maintenance via Power BI a permis d'optimiser la gestion et la surveillance des camions miniers en temps réel. Grâce à l'intégration des données de télémétrie dans un tableau de bord interactif, l'analyse des tendances et la détection des anomalies ont été facilitées. Cette approche combinée, mêlant modélisation prédictive et digitalisation, constitue une avancée majeure vers une gestion proactive et intelligente des opérations minières.

CHAPITRE 5 : CONCLUSION GÉNÉRALE ET PERSPECTIVES

La présente recherche s'inscrit dans une démarche d'optimisation de la maintenance prédictive appliquée aux équipements miniers, en mettant l'accent sur deux études complémentaires : la prédiction des défaillances dans un réducteur de convoyeur de minerais et la digitalisation des données de maintenance des camions miniers à l'aide de Power BI. L'objectif principal était de démontrer l'efficacité des techniques d'apprentissage automatique et des outils analytiques avancés pour améliorer la fiabilité des équipements et réduire les interruptions imprévues des opérations minières.

Dans la première étude, nous avons développé un modèle de prédiction des défaillances dans un réducteur de convoyeur de minerais en exploitant des données de capteurs mesurant les vibrations, la température et la vitesse de rotation. Les modèles de détection d'anomalies LOF et IF ont permis d'identifier efficacement les variations anormales, avec une performance notable du modèle LOF pour détecter de manière anticipée les anomalies critiques. L'association du modèle LOF avec les réseaux de neurones récurrents (RNN) a renforcé la fiabilité des prédictions, facilitant ainsi l'anticipation des interventions de maintenance. La validation des résultats auprès des équipes de maintenance et de fiabilité du partenaire minier a confirmé la pertinence des modèles développés, démontrant leur impact positif sur la réduction des arrêts imprévus et l'optimisation des coûts de maintenance. Dans la seconde étude, nous avons intégré la digitalisation des données de maintenance des camions miniers via un tableau de bord interactif sur Power BI. Ce système a permis une structuration efficace des données et une analyse en temps réel des indicateurs critiques, tels que les vibrations, la pression et la rotation. Avant d'exploiter les modèles de prévision, une phase essentielle a consisté en la détection des anomalies par Spectral Residual Convolutional Neural Network (SR-CNN), qui a permis d'identifier les variations atypiques dans les séries temporelles de télémétrie. Cette approche a amélioré la qualité des données

d'entrée pour la prédiction et renforcé la détection précoce des défaillances. L'intégration de modèles de prévision, notamment Holt-Winters, a ensuite permis d'anticiper les pannes critiques et d'améliorer la gestion des équipements. L'interactivité du tableau de bord a facilité une analyse dynamique des tendances, permettant d'optimiser les stratégies de maintenance et de mieux planifier les ressources. Cette approche a ainsi contribué à une gestion plus efficace des interventions tout en réduisant les coûts et en renforçant la disponibilité des équipements.

Afin de prolonger les travaux réalisés dans cette recherche et d'améliorer davantage la maintenance prédictive dans l'industrie minière, plusieurs axes d'évolution concrets et réalisables sont proposés pour chaque étude. Ces perspectives permettront d'optimiser les performances des modèles et de renforcer l'intégration des outils numériques pour une prise de décision plus efficace.

➤ **La prédiction des défaillances dans un réducteur de convoyeur de minerais :**

- Amélioration des modèles de détection d'anomalies : L'intégration de modèles plus avancés tels que One-Class SVM, Autoencoders et VAE pourrait affiner la détection des anomalies en capturant des comportements complexes et en réduisant les faux positifs. Une approche hybride combinant SR-CNN et Isolation Forest (IF) permettrait d'améliorer la robustesse du système de détection d'anomalies en exploitant à la fois les caractéristiques spectrales et les structures des séries temporelles.
- Développement d'un modèle prédictif plus performant : L'exploration de transformer et de modèles hybrides associant réseaux neuronaux récurrents (LSTM, GRU) avec des modèles basés sur des arbres de décision comme XGBoost ou CatBoost permettrait de mieux capter les tendances complexes des séries temporelles et d'optimiser la fiabilité des prédictions.
- Validation expérimentale sur d'autres types de convoyeurs : Étendre l'application du modèle développé à d'autres convoyeurs opérant dans des environnements différents permettrait de vérifier sa généralisable et d'affiner

les ajustements nécessaires en fonction des conditions d'exploitation spécifiques.

➤ **La digitalisation et la prévision des données de maintenance des camions miniers sur Power BI :**

- Optimisation du calcul des KPIs de maintenance avec DAX : Une extension de l'analyse actuelle consisterait à intégrer des indicateurs avancés tels que MTBF, MTTR, OEE et d'autres métriques de maintenance. En exploitant DAX sur Power BI, il serait possible d'automatiser ces calculs et d'améliorer la visualisation des performances des équipements en temps réel.
- Amélioration de la prévision des pannes : La mise en place de modèles de validation plus précis pour évaluer la performance du modèle Holt-Winters serait une avancée majeure. L'utilisation de métriques comme MSE, RMSE, MAE, et R^2 directement intégrées au tableau de bord permettrait un ajustement continu du modèle de prévision en fonction des données récentes.
- Automatisation des alertes et recommandations sur Power BI : Un développement intéressant serait la création d'un système d'alerte intelligent, qui enverrait automatiquement des notifications aux équipes de maintenance lorsqu'une anomalie est détectée ou lorsqu'un KPI atteint un seuil critique.
- Intégration avec un système de gestion de maintenance assistée par ordinateur : L'un des développements futurs serait de connecter Power BI à une GMAO, permettant ainsi d'automatiser la planification des interventions de maintenance en fonction des prévisions et des tendances identifiées sur le tableau de bord interactif.

RÉFÉRENCES BIBLIOGRAPHIQUES

- [1] "Mining delivers record \$455 billion in export revenue in FY23." <https://minerals.org.au/resources/mining-delivers-record-455-billion-in-export-revenue-in-fy23/> (accessed June 6, 2023).
- [2] "Economic Impacts and Drivers for the Global Energy Transition Report Highlights State of Canada's Mining Industry." <https://mining.ca/resources/press-releases/economic-impacts-and-drivers-for-the-global-energy-transition-report-highlights-state-of-canadas-mining-industry/> (accessed June 6, 2023).
- [3] "What is the Mining Industry? Why is it Important?" <https://www.brimco.io/mining/what-is-the-mining-industry-why-is-it-important/> (accessed August 13, 2023).
- [4] "National Mining Association " <https://nma.org> (accessed August 13, 2023).
- [5] "Implementing Effective Maintenance Strategies for Long Term Production Goals." <https://miningdigital.com/supply-chain-and-operations/implementing-effective-maintenance-strategies-long-term-production-goals> (accessed March 10, 2024).
- [6] "Comprehensive Guide to Mining Equipment Maintenance." <https://www.fieldinsight.com/blog/comprehensive-guide-to-mining-equipment-maintenance/> (accessed November 15, 2023).
- [7] "Heavy Mining Equipment Category Overview." <https://www.grandviewresearch.com/pipeline/heavy-mining-equipment-procurement-intelligence-report> (accessed March 10, 2024).
- [8] "Changing the conversation on mine maintenance costs." <https://www.canadianminingjournal.com/featured-article/changing-the-conversation-on-mine-maintenance-costs/> (accessed November 20, 2023).
- [9] A. Althubaiti, F. Elasha, and J. A. Teixeira, "Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis— a review," *Journal of Vibroengineering*, vol. 24, no. 1, pp. 46-74, 2022.
- [10] K. Al-Kahwati, W. Birk, E. F. Nilsfors, and R. Nilsen, "Experiences of a digital twin based predictive maintenance solution for belt conveyor systems," in *PHM Society European Conference*, 2022, vol. 7, no. 1, pp. 1-8.
- [11] H. Shiri, J. Wodecki, B. Ziętek, and R. Zimroz, "Inspection robotic UGV platform and the procedure for an acoustic signal-based fault detection in belt conveyor idler," *Energies*, vol. 14, no. 22, p. 7646, 2021.
- [12] A. Shakenov, A. Ślaskowski, and I. Stolpovskikh, "HAUL ROAD CONDITION IMPACT ON TIRE LIFE OF MINING DUMP TRUCK," *Scientific Bulletin of National Mining University*, no. 6, 2022.
- [13] D. Meneses and F. D. Sepúlveda, "Modeling productivity reduction and fuel consumption in open-pit mining trucks by considering the temporary deterioration of mining roads through discrete-event simulation," *Mining*, vol. 3, no. 1, pp. 96-105, 2023.

- [14] P. Chaowasakoo, H. Seppälä, H. Koivo, and Q. Zhou, "Improving fleet management in mines: The benefit of heterogeneous match factor," *European journal of operational research*, vol. 261, no. 3, pp. 1052-1065, 2017.
- [15] F. K. Fasuludeen Kunju, N. Naveed, M. N. Anwar, and M. I. Ul Haq, "Production and maintenance in industries: impact of industry 4.0," *Industrial Robot: the international journal of robotics research and application*, vol. 49, no. 3, pp. 461-475, 2022.
- [16] "L'industrie 4.0, c'est quoi ?" <https://www.andromediatech.com/lindustrie-4-0-cest-quoi/> (accessed March 10, 2024).
- [17] A. Amelio, G. Bonifazi, E. Corradini, D. Ursino, and L. Virgili, "A multilayer network-based approach to represent, explore and handle convolutional neural networks," *Cognitive Computation*, vol. 15, no. 1, pp. 61-89, 2023.
- [18] X. Wang, M. Liu, C. Liu, L. Ling, and X. Zhang, "Data-driven and Knowledge-based predictive maintenance method for industrial robots for the production stability of intelligent manufacturing," *Expert Systems with Applications*, vol. 234, p. 121136, 2023.
- [19] H. Meriem, H. Nora, and O. Samir, "Predictive maintenance for smart industrial systems: a roadmap," *Procedia Computer Science*, vol. 220, pp. 645-650, 2023.
- [20] "Predictive Maintenance." <https://www.mathworks.com/discovery.html> (accessed July 16, 2023).
- [21] S. B. Abkenar, M. H. Kashani, E. Mahdipour, and S. M. Jameii, "Big data analytics meets social media: A systematic review of techniques, open issues, and future directions," *Telematics and informatics*, vol. 57, p. 101517, 2021.
- [22] P. Nunes, J. Santos, and E. Rocha, "Challenges in predictive maintenance—A review," *CIRP Journal of Manufacturing Science and Technology*, vol. 40, pp. 53-67, 2023.
- [23] G. Bello-Orgaz, J. J. Jung, and D. Camacho, "Social big data: Recent achievements and new challenges," *Information Fusion*, vol. 28, pp. 45-59, 2016.
- [24] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91-99, 2022.
- [25] S. Wu, H. Yu, Y. Gu, C. Shao, and S. Gao, "SNN-PDM: An Improved Probability Density Machine Algorithm Based on Shared Nearest Neighbors Clustering Technique," *Journal of Classification*, pp. 1-24, 2024.
- [26] S. Sajid, A. Haleem, S. Bahl, M. Javaid, T. Goyal, and M. Mittal, "Data science applications for predictive maintenance and materials science in context to Industry 4.0," *Materials today: proceedings*, vol. 45, pp. 4898-4905, 2021.
- [27] F. Rocha *et al.*, "Rosi: A robotic system for harsh outdoor industrial inspection-system design and applications," *Journal of Intelligent & Robotic Systems*, vol. 103, pp. 1-22, 2021.

- [28] P. Bortnowski, W. Kawalec, R. Król, and M. Ozdoba, "Types and causes of damage to the conveyor belt—Review, classification and mutual relations," *Engineering Failure Analysis*, vol. 140, p. 106520, 2022.
- [29] L. Yip, *Analysis and modeling of planetary gearbox vibration data for early fault detection*. University of Toronto Toronto, ON, Canada, 2011.
- [30] K. Saini, S. Dhami, and Vanraj, "Predictive monitoring of incipient faults in rotating machinery: a systematic review from data acquisition to artificial intelligence," *Archives of Computational Methods in Engineering*, vol. 29, no. 6, pp. 4005-4026, 2022.
- [31] K. Feng, J. Ji, Q. Ni, and M. Beer, "A review of vibration-based gear wear monitoring and prediction techniques," *Mechanical Systems and Signal Processing*, vol. 182, p. 109605, 2023.
- [32] W. D. Mark, H. Lee, R. Patrick, and J. D. Coker, "A simple frequency-domain algorithm for early detection of damaged gear teeth," *Mechanical Systems and Signal Processing*, vol. 24, no. 8, pp. 2807-2823, 2010.
- [33] D. Mazurkiewicz, "Maintenance of belt conveyors using an expert system based on fuzzy logic," *Archives of Civil and Mechanical Engineering*, vol. 15, no. 2, pp. 412-418, 2015.
- [34] F. Alharbi *et al.*, "A brief review of acoustic and vibration signal-based fault detection for belt conveyor idlers using machine learning models," *Sensors*, vol. 23, no. 4, p. 1902, 2023.
- [35] A. Rao, H. Gupta, P. Singh, S. Mittal, U. Singh, and D. K. Vishwakarma, "Optimizing Electric Vehicle Efficiency with Real-Time Telemetry using Machine Learning," in *2024 10th International Conference on Mechatronics and Robotics Engineering (ICMRE)*, 2024: IEEE, pp. 213-219.
- [36] D. Jung and Y. Choi, "Systematic review of machine learning applications in mining: Exploration, exploitation, and reclamation," *Minerals*, vol. 11, no. 2, p. 148, 2021.
- [37] R. Jain, M. Rohit, A. Kumar, A. Bakliwal, A. Makwana, and M. Rahevar, "Prediction of telemetry data using machine learning techniques," *International Journal of Engineering Research & Technology*, vol. 11, no. 9, pp. 1-7, 2022.
- [38] A. F. Ünal, A. Y. Kaleli, E. Ummak, and Ö. Albayrak, "A Comparison of State-of-the-Art Machine Learning Algorithms on Fault Indication and Remaining Useful Life Determination by Telemetry Data," in *2021 8th International Conference on Future Internet of Things and Cloud (FiCloud)*, 2021: IEEE, pp. 79-85.
- [39] A. Hébert, I. Marineau, G. Gervais, T. Glatard, and B. Jaumard, "Can we estimate truck accident risk from telemetric data using machine learning?," in *2021 IEEE International Conference on Big Data (Big Data)*, 2021: IEEE, pp. 1827-1836.
- [40] K. T. Selvi, N. Praveena, K. Pratheeksha, S. Ragunathan, and R. Thamilselvan, "Air pressure system failure prediction and classification in scania trucks using machine learning," in *2022 Second International*

- Conference on Artificial Intelligence and Smart Energy (ICAIS)*, 2022: IEEE, pp. 220-227.
- [41] S. Katreddi, S. Kasani, and A. Thiruvengadam, "A review of applications of artificial intelligence in heavy duty trucks," *Energies*, vol. 15, no. 20, p. 7457, 2022.
 - [42] R. Marin, "Telemetry: connectivity and productivity in real time-project implementation guide," in *MassMin 2020: Proceedings of the Eighth International Conference & Exhibition on Mass Mining*, 2020: University of Chile, pp. 1359-1374.
 - [43] "Telematics." https://www.cat.com/en_US/by-industry/industrial-power/services/connectivity/telematics.html (accessed April 3, 2024).
 - [44] M. Farahpoor, O. Esparza, and M. Soriano, "Comprehensive IoT-driven fleet management system for industrial vehicles," *IEEE access*, 2023.
 - [45] "Rocktechnology Sandvik. AutoMine remote control." <https://www.rocktechnology.sandvik/en/products/automation/automine-equipment-and-teleoperation-systems/automine-tele-remote-for-loading-and-hauling/> (accessed April 5, 2024).
 - [46] "Caterpillar Global Mining. Building technologies for the mine sites of the future." <http://viewpointmining.com/article/building-the-technologies-for-the-mine-sites-of-the-future> (accessed April 10, 2024).
 - [47] L. C. C. Torres, "Effects of simulation in a mining system to optimize the hauling and loading process."
 - [48] N. A. Aluko, *Evaluating the influence of operator practices on hydraulic shovel productivity and energy consumption using telemetry data*. Missouri University of Science and Technology, 2023.
 - [49] F. R. von Glehn, B. H. P. Gonçalves, M. G. F. Neto, and J. P. da Silva Fonseca, "Telematics and machine learning system for estimating the load condition of a heavy-duty vehicle," *Procedia Computer Science*, vol. 232, pp. 2616-2625, 2024.
 - [50] M. Šverko and T. G. Grbac, "Automated HMI design as a custom feature in industrial SCADA systems," *Procedia Computer Science*, vol. 232, pp. 1789-1798, 2024.
 - [51] S. García, J. Luengo, and F. Herrera, *Data preprocessing in data mining*. Springer, 2015.
 - [52] "sklearn.preprocessing.MinMaxScaler. Scikit-Learn n.d. ." <https://scikit-learn/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html> (accessed August 10, 2023).
 - [53] "sklearn.preprocessing.StandardScaler. Scikit-Learn n.d. ." <https://scikit-learn/stable/modules/generated/sklearn.preprocessing.StandardScaler.html> (accessed August 10, 2023).
 - [54] "sklearn.preprocessing.RobustScaler. Scikit-Learn n.d. ." <https://scikit-learn/stable/modules/generated/sklearn.preprocessing.RobustScaler.html> (accessed August 10, 2023).
 - [55] "Réseau de neurones récurrents." <https://metalblog.ctif.com/2021/09/06/les-reseaux-de-neurones-recurrents-pour-lesseries-temporelles/> (accessed August 20, 2023).

- [56] L. DE MATTEIS, S. Janny, S. Nathan, and W. Shu-Quartier, "Introduction à l'apprentissage automatique," ed, 2022.
- [57] A. Sherstinsky, "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network," *Physica D: Nonlinear Phenomena*, vol. 404, p. 132306, 2020.
- [58] J. Kang, X. Zhu, L. Shen, and M. Li, "Fault diagnosis of a wave energy converter gearbox based on an Adam optimized CNN-LSTM algorithm," *Renewable Energy*, vol. 231, p. 121022, 2024.
- [59] S. Bouktif, A. Fiaz, A. Ouni, and M. A. Serhani, "Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting," *Energies*, vol. 13, no. 2, p. 391, 2020.
- [60] M. M. Breunig, H.-P. Kriegel, R. T. Ng, and J. Sander, "LOF: identifying density-based local outliers," in *Proceedings of the 2000 ACM SIGMOD international conference on Management of data*, 2000, pp. 93-104.
- [61] S. Chigurupati, K. Raja, and M. Babu, "An Extensive Survey on Outlier Prediction Using Mining and Learning Approaches," in *Evolutionary Computing and Mobile Sustainable Networks: Proceedings of ICECMSN 2021*: Springer, 2022, pp. 593-610.
- [62] F. T. Liu, K. M. Ting, and Z.-H. Zhou, "Isolation forest," in *2008 eighth ieee international conference on data mining*, 2008: IEEE, pp. 413-422.
- [63] Z. Huang, E. Cuenca, and L. Ferrara, "Optimized data-driven method to study the self-healing and durability of ultra-high performance concrete," *Engineering Applications of Artificial Intelligence*, vol. 143, p. 110043, 2025.
- [64] S.-V. Oprea, A. Bâra, F. C. Puican, and I. C. Radu, "Anomaly detection with machine learning algorithms and big data in electricity consumption," *Sustainability*, vol. 13, no. 19, p. 10963, 2021.
- [65] A. R. Nair, A. Laddha, A. Munson, and A. Sebastian, "A Study on Machine Learning-Based Predictive Modelling for Pick Profiling at Distribution Centers," in *Proceedings of International Conference on Machine Intelligence and Data Science Applications: MIDAS 2020*, 2021: Springer, pp. 27-34.
- [66] E. Primera, D. Fernández, A. Cacereño, and A. Rodríguez-Prieto, "Predictive Analytics-Based Methodology Supported by Wireless Monitoring for the Prognosis of Roller-Bearing Failure," *Machines*, vol. 12, no. 1, p. 69, 2024.
- [67] M. J. Alam, B. K. Mahanta, and N. Nawghade, "Comparative performance study of mine trucks by Overall Equipment Effectiveness (OEE)," *International Research Journal of Engineering and Technology (IRJET)*, vol. 5, no. 11, pp. 448-453, 2018.
- [68] "Processus de traitement des minerais." <https://www.agnicoeagle.com/French/exploitations/exploitations/laronde/default.aspx> (accessed May 23, 2023).
- [69] I. Salehin and D.-K. Kang, "A review on dropout regularization approaches for deep neural networks within the scholarly domain," *Electronics*, vol. 12, no. 14, p. 3106, 2023.

- [70] "Predictive Maintenance | ANAI." <https://www.kaggle.com/code/d4rklucif3r/predictive-maintenance-anai/notebook> (accessed May 16, 2024).
- [71] M. Ehrenmueller-Jensen and M. Ehrenmueller-Jensen, "Drilling Down and Decomposing Hierarchies," *Self-Service AI with Power BI Desktop: Machine Learning Insights for Business*, pp. 81-101, 2020.
- [72] F. K. Sufi, "AI-GlobalEvents: A Software for analyzing, identifying and explaining global events with Artificial Intelligence," *Software Impacts*, vol. 11, p. 100218, 2022.
- [73] S. Hansun, V. Charles, and C. R. Indrati, "Revisiting the Holt-Winters' additive method for better forecasting," *International Journal of Enterprise Information Systems (IJEIS)*, vol. 15, no. 2, pp. 43-57, 2019.
- [74] Ó. Trull, J. C. García-Díaz, and A. Troncoso, "Stability of multiple seasonal holt-winters models applied to hourly electricity demand in Spain," *Applied Sciences*, vol. 10, no. 7, p. 2630, 2020.
- [75] E. A. ALHARBI, "COOLING LOAD PREDICTION MODEL DURING THE DESIGN OF MOSQUES IN MADINAH," *Universiti Teknologi Malaysia*, 2022.
- [76] C. T. Gonçalves, M. J. A. Gonçalves, and M. I. Campante, "Developing Integrated Performance Dashboards Visualisations Using Power BI as a Platform," *Information*, vol. 14, no. 11, p. 614, 2023.
- [77] P. Picozzi, U. Nocco, A. Pezzillo, A. De Cosmo, and V. Cimolin, "The Use of Business Intelligence Software to Monitor Key Performance Indicators (KPIs) for the Evaluation of a Computerized Maintenance Management System (CMMS)," *Electronics*, vol. 13, no. 12, p. 2286, 2024.
- [78] B. Purdon, L. Piyathilaka, J.-H. Sul, and D. Preethichandra, "Mining Haulage Road Maintenance Prediction Dashboard Utilising Machine Learning Techniques," in *2024 6th International Conference on Advancements in Computing (ICAC)*, 2024: IEEE, pp. 193-198.
- [79] A. F. Jamaludin and M. N. Razali, "Identification of Business Intelligence in Managing Maintenance Management for Government Office Buildings in Putrajaya," *International journal of academic research in business & social sciences*, vol. 11, no. 6, 2021.