

# Développement d'un modèle de prédiction intelligente des défaillances mécaniques dans un réducteur de convoyeur de minerais

M. C. Yakoubi<sup>1</sup>, N. Elkhenin<sup>1</sup>, H. Mrad<sup>1</sup>

<sup>1</sup> Université du Québec en Abitibi-Témiscamingue, Canada, [MohamedChadi.Yakoubi@uqat.ca](mailto:MohamedChadi.Yakoubi@uqat.ca), [Nour.Elkhenin@uqat.ca](mailto:Nour.Elkhenin@uqat.ca), [Hatem.Mrad@uqat.ca](mailto:Hatem.Mrad@uqat.ca).

**Résumé** — L'article examine la prédiction des défaillances mécaniques dans les équipements tournants miniers, mettant l'accent sur un réducteur de convoyeur. Un outil numérique d'aide à la décision développé sous Python utilise des données de vibrations et des fiches de maintenance. Les données sont analysées pour détecter les tendances, tandis qu'un algorithme de réseau de neurones récurrents prédit les premières signatures vibratoires. Deux algorithmes de détection d'anomalies, basés sur les données de vibration prédites et les dates de maintenance antérieures, sont utilisés pour prédire les signatures des défaillances.

**Mots clefs** — Défaillances mécaniques, Maintenance prédictive, Réseaux de Neurones Récurrents, Analyses des données, Apprentissage automatique.

## 1. Introduction

Dans le contexte de l'industrie 4.0, réside la nécessité de maintenir un fonctionnement fluide et sans interruption des équipements tournants complexes au sein des entreprises minières [1]. Parmi ces équipements, on cite le convoyeur minier qui joue un rôle central de transport de minerais vers l'usine de traitement. Cependant, cet équipement demeure un sujet à des défaillances mécaniques inattendues, mettant en péril l'efficacité opérationnelle, la sécurité et la rentabilité globale [2]. C'est précisément dans ce contexte exigeant que l'analyse de données et l'apprentissage automatique émergent comme des domaines essentiels pour la mise en œuvre de solutions de maintenance prédictive [3].

L'objectif principal de cette étude est d'anticiper et de prévenir les défaillances mécaniques au sein du système d'entraînement d'un convoyeur des minerais qui est le réducteur. En partenariat avec une entreprise minière de la région de l'Abitibi-Témiscamingue, l'étude s'appuie sur une approche combinant des données détaillées de vibrations acquises au bord de réducteur avec des informations issues des fiches de maintenance pour prédire les dates d'interventions futures afin de maintenir la continuité de la production dans l'industrie. La mise en œuvre de cette étude réside dans la conception d'un modèle d'apprentissage qui adapte un paradigme entre l'intelligence artificielle et les problématiques liées à la maintenance [4]. La première étape de l'approche développée consiste à traiter et codifier les données brutes via le logiciel OpenRefine pour les exporter à un modèle Réseau de Neurones Récurrents (RNN) afin de prédire les états vibratoires sur une période de 3 mois. Ces prédictions sont ensuite importées conjointement avec les historiques de maintenance à partir de deux modèles de détection des anomalies, soient le Local Outlier Factor (LOF) et l'Isolation Forest (IF). Bien que ces modèles aient montré leur fort potentiel en tant qu'outils fiables pour anticiper la maintenance, ces algorithmes peuvent présenter des limitations lorsqu'ils sont entraînés avec un nombre limité de données.

## 2. Mise en contexte

Le processus de transport des minerais dans une mine se base sur un équipement indispensable et central qui est le convoyeur. La figure 1 présente la composition de cet équipement constitué

principalement par un moteur asynchrone entraîné par un accouplement rigide à un réducteur étagé. Ce dernier fournit un couple suffisant pour entraîner le tambour de la bande transporteuse. Il est équipé d'un ensemble de capteurs et de sondes disposés de manière stratégique afin de surveiller leur état de fonctionnement. Ces instruments sont conçus pour enregistrer les indicateurs des vibrations. L'éventuelle étude se concentre sur les sondes de vibrations installées aux bords du réducteur couplé au convoyeur, ainsi que sur l'arbre de sortie du moteur. Un système de surveillance et de gestion des équipements est dédié à la collecte des données en temps réel provenant de ces capteurs, avec les désignations correspondantes : sonde de vibrations A du moteur et la sonde de vibrations B du réducteur.




Figure 1 - Système d'entraînement : a) Accouplement moteur/réducteur et b) Emplacement des capteurs.

### 3. Analyses préliminaires

#### 3.1 Étude de la tête de Pareto

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 2 décrit le pourcentage cumulé des coûts des pièces défaillantes. L'étude démontre qu'environ 80 % des coûts totaux de maintenance correspondent à l'ensemble des pièces de rechange  $\Omega$ , également courroie-réducteur représentent 20% des causes. 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.




Figure 2 – Tête de Pareto des pièces de rechange pour l'année 2023 en CA\$.

Guidé par ces constatations, le développement d'une approche pour prédire les anomalies et minimiser les temps d'arrêt coûteux à travers les données de vibration du réducteur synchronisé avec l'historique des maintenances sera requis. Dans ce contexte, les travaux de Feng et al. [5] ont mis en évidence que l'usure des engrenages, comme montre la figure 3, peut provoquer des altérations dans la

géométrie du profil des dents ou une diminution de la surface de contact. Ces altérations ont un impact significatif sur les propriétés dynamiques du système d'engrenage, notamment sur la force de contact et sa répartition. Par conséquent, cela se traduit par une augmentation du niveau de vibrations et du bruit générés par le système.




Figure 3 – Les vibrations induites par l'interaction entre l'usure et la dynamique des engrenages.

En combinant l'analyse préliminaire des données et l'intelligence artificielle, l'étude vise à créer un environnement de traitement des minerais encore plus efficient et fiable. Une attention particulière était consacrée à la qualité et à la cohérence de nos données. L'usage du logiciel OpenRefine a permis d'effectuer une série d'opérations essentielles, telles que la détection et le nettoyage des valeurs manquantes (NaN), ainsi que la standardisation et la normalisation des données pour la garantie de leur homogénéité. Yip [6] a mis en place, une approche visant à utiliser la méthode de prétraitement des données de vibration synchrone dans le temps pour extraire des indicateurs à partir de ces données prétraitées. Leur approche avait pour objectif de détecter les réducteurs planétaires utilisés dans les opérations liées aux sables bitumineux. Basés sur le signal d'extraction, ils ont fait la moyenne de toutes les sources de vibrations qui ne sont pas synchrones avec l'impulsion du tachymètre, comme montre la figure 4. L'étude menée par Mark et al. [7] se concentrait sur une méthode fréquentielle visant à éliminer les perturbations dues aux transducteurs et les variations d'amplitudes induites par les caractéristiques structurales.

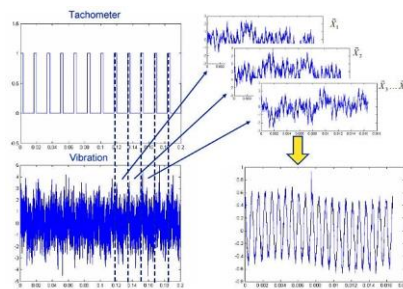


Figure 4 – Méthodologie d'extraction de signaux TSA [8].

### 3.2 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 5, représente l'interdépendance des sorties des différents capteurs.




Figure 5 – 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. Par la suite un modèle d’apprentissage pour la détection précoce des dates d’intervention sur le réducteur a été élaboré. Cette approche permet d’anticiper les problèmes potentiels en combinant les données de vibration de la sonde B avec les fiches des interventions.

#### 4. Approche et méthodologie

La méthodologie adoptée dans cette étude est composée de quatre phases primordiales A, B, C et D. La hiérarchie proposée a permis de développer un outil d’aide à la prise de décision pour décider des dates de maintenance basées sur des algorithmes d’apprentissage automatique répondant au besoin de l’étude. La figure 6 présente un schéma global de la méthodologie. Le schéma illustre un processus structuré pour prédire les données de vibrations de la sonde B et détecter les dates de maintenance possibles. Le processus commence par l’acquisition et la collecte de données via PI SQL (Bloc A), suivi d’un prétraitement avec OpenRefine où les vibrations sont analysées et les redondances éliminées en introduisant la codification et l’étiquetage des fichiers CSV. Ensuite, le développement du modèle RNN (Bloc B) démarre avec la définition des ensembles de données pour l’entraînement (80 %), le test et la validation (20 %). La structure du modèle est établie, incluant la spécification du nombre et du type de couches de neurones, avant de passer à l’entraînement et au test du modèle. L’évaluation de la performance du modèle a été faite par le calcul de l’Erreur Moyenne Quadratique (MSE) entre les données réelles et prédites. Si sa valeur n’est pas satisfaisante, il faut faire un retour à l’étape de définition de la structure du modèle pour effectuer des ajustements. Une fois que les performances sont jugées adéquates, le modèle final est développé. Ce modèle est alors soumis à une validation, où les données réelles sont comparées aux données prédites. Si la validation est achevée, le processus implique la sélection des hyperparamètres optimaux et le choix de l’optimiseur, accompagné du calcul MSE pour affiner le modèle. Après la validation du modèle RNN, pour les étapes subséquentes impliquant les modèles Local Outlier Factor (LOF) et Isolation Forest (IF), on intègre les valeurs des vibrations prédites sur une période de trois mois ainsi que les fiches de maintenance antérieures (Bloc C). Cela permet d’affiner la détection des dates de maintenance en croisant les prédictions de vibration avec les interventions de maintenance historiques. L’étape de validation des résultats (Bloc D) a été franchie par la comparaison des dates documentées sur les fiches de maintenance récentes afin d’évaluer l’exactitude des prédictions et l’efficacité des modèles.

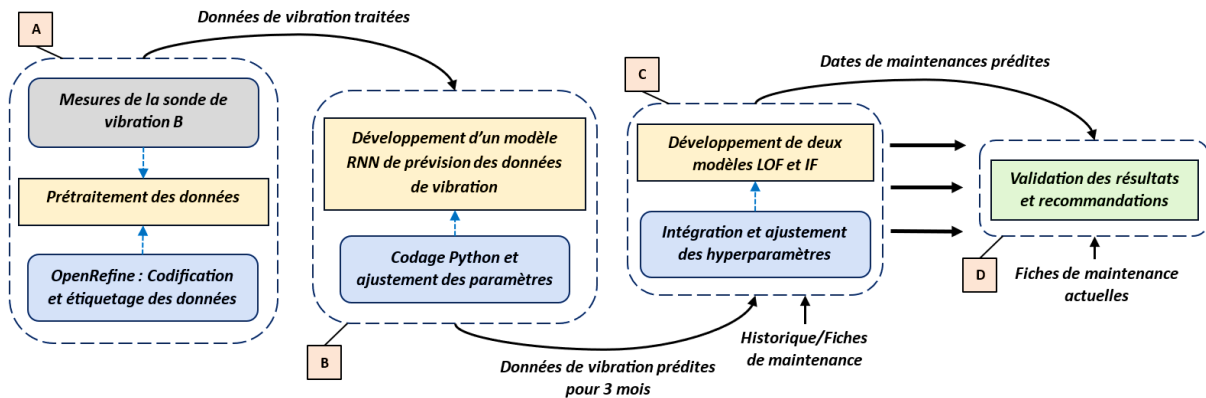


Figure 6 – Schéma de l'approche de prédiction des vibrations et détection des anomalies

#### 4.1 Architecture du RNN utilisé

Les réseaux de neurones récurrents (RNN) sont utilisés dans le diagnostic des défauts pour conserver les informations de l'état de la couche cachée. Cela surmonte les limites des réseaux neuronaux simples [9] qui ne peuvent pas résoudre des problèmes à long terme basés sur des séries chronologiques. Cependant, dans les analyses temporelles à long terme, des divergences significatives de prédiction peuvent survenir, avec des gradients qui peuvent devenir instables, s'amplifier ou disparaître complètement, comme mentionné dans [10]. Pour relever ces défis, l'architecture proposée, présentée dans la figure 7, 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 7 – 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 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 8 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 8 – L'évolution de la perte entre les données d'entraînement et de validation.

## 4.3 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 [11]. 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 9 présente la courbe des vibrations réelles, les dates des interventions systématiques et le comportement vibratoire prédit avec les hyperparamètres optimisés.

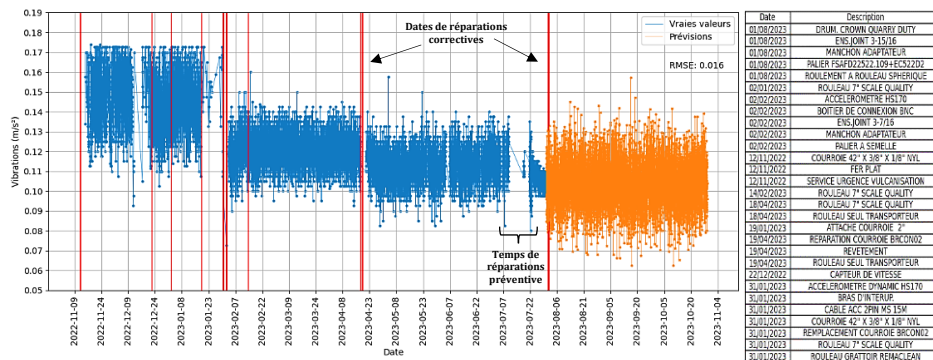


Figure 9 – Données de vibration réelles et prédites en fonction du temps et les maintenances effectuées.

## 4.4 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 Local Outlier Factor (LOF) et l'Isolation Forest, ont été utilisés pour identifier les dates de maintenance prédites pour les trois prochains mois. Le modèle LOF évalue la similarité d'un point de données par rapport à ses voisins les plus proches, attribuant un score d'anomalie en fonction de la densité locale des points. En revanche, l'Isolation Forest est un algorithme basé sur des arbres de décision qui isole les anomalies en les considérant comme des valeurs rares, plus faciles à isoler que les valeurs normales. La figure 10 décrit les résultats de ces deux modèles entraînés par les mêmes entrées.

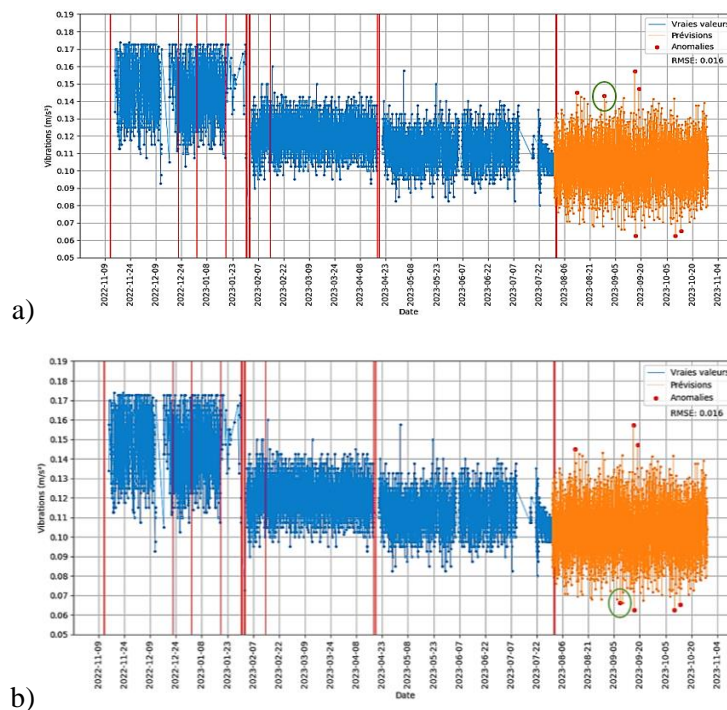


Figure 10 – Détections des anomalies à partir de deux méthodes : a) Local Outlier Factor, b) Isolation Forest.

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.

## 5. Conclusion et perspectives

En conclusion, cette étude de cas a mis en évidence l'efficacité des modèles Local Outlier Factor et Isolation Forest pour la détection précoce d'anomalies dans les données de vibrations. L'identification

anticipée, par le modèle LOF, d'une date présentant une anomalie spécifique, renforce sa pertinence dans la suivie de l'état des réducteurs de vitesse. L'application de ce modèle est fondamentale pour anticiper les interventions de maintenance. De plus lorsque le modèle LOF est associé au modèle de prédiction basé sur des RNN, ceci a permis de maximiser le taux de succès et la fiabilité de prediction. L'intégration de données de maintenance en temps réel permettra une surveillance anticipative, fournissant ainsi des réponses immédiates aux variations du comportement du système de transmission. Les résultats ont été discutés avec l'équipe de maintenance et de fiabilité du partenaire minier, et ont été validés en correspondance avec les données spécifiques de la période prédite. En combinant ces approches, des contributions significatives ont été apportées pour améliorer la fiabilité des machines industrielles et réduire considérablement les coûts liés aux arrêts imprévus dans les industries minières.

## 6. Références

- [1] P. Odeyar, D.B. Apel, R. Hall, B. Zon, K. Skrzypkowski, Examen de la fiabilité et des méthodes d'analyse des défaillances de l'équipement lourd et de ses composants utilisés dans l'exploitation minière. *Énergies*, 2022.
- [2] L. Giraud, S. Massé. Sécurité des convoyeurs à courroie : guide de l'utilisateur, CSST, 2004.
- [3] J. Dalzochio, R. Kunst, E. Pignaton, A. Binotto, S. Sanyal, J. Favilla, J. Barbosa. Machine learning et raisonnement pour la maintenance prédictive dans l'industrie 4.0 : état actuel et défis, *Computers in Industry*, 123, 103298, 2020.
- [4] B.A. Tama, M. Vania, S. Lee, S. Lim. Progrès récents dans l'application de l'apprentissage profond pour le diagnostic des défauts des machines tournantes à l'aide de signaux de vibration, *Artificial Intelligence Review*, 56(5), 4667-4709, 2023.
- [5] K. Feng, J.C. Ji, Q. Ni, M. Beer. Un examen des techniques de surveillance et de prévision de l'usure des engrenages basées sur les vibrations, *Systèmes mécaniques et traitement du signal*, 182, 109605, 2023.
- [6] L. Yip. Analysis and modeling of planetary gearbox vibration data for early fault detection, University of Toronto, 2011.
- [7] W.D. Mark, H. Lee, R. Patrick, J.D. Coker. A simple frequency-domain algorithm for early detection of damaged gear teeth, *Mechanical Systems and Signal Processing*, 24 (8), 2807-2823, 2010.
- [8] K. Saini, S.S. Dhama, Vanraj. Surveillance prédictive des défauts naissants dans les machines rotatives : une revue systématique de l'acquisition de données à l'intelligence artificielle, *Archives of Computational Methods in Engineering*, 29, 4005-4026, 2022.
- [9] W. Jiang, C. Wang, J. Zou, S. Zhang. Application of Deep Learning in Fault Diagnosis of Rotating Machinery, *Processes*, 9, 919, 2021.
- [10] A. Malhi, R. Yan, R.X. Gao. Prognosis of defect propagation based on recurrent neural networks, *IEEE Transactions on Instrumentation and Measurement*, 60 (3), 703-711, 2011.
- [11] I. Salehin, D.K. Kang. A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain, *Electronics*, 12 (14), 3106, 2023.