



Titre: Prédiction des temps de maintenance à partir d'un historique de
Title: bons de travail

Auteur: Cyril Tang
Author:

Date: 2024

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Tang, C. (2024). Prédiction des temps de maintenance à partir d'un historique de
Citation: bons de travail [Mémoire de maîtrise, Polytechnique Montréal]. PolyPublie.
<https://publications.polymtl.ca/59204/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/59204/>
PolyPublie URL:

**Directeurs de
recherche:** Michel Gamache, Bruno Agard, & Souheil-Antoine Tahan
Advisors:

Programme: Maîtrise recherche en génie industriel
Program:

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Prédiction des temps de maintenance à partir d'un historique de bons de travail

CYRIL TANG

Département de mathématiques et de génie industriel

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

Génie industriel

Août 2024

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

Prédiction des temps de maintenance à partir d'un historique de bons de travail

présenté par **Cyril TANG**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Christophe DANJOU, président

Michel GAMACHE, membre et directeur de recherche

Bruno AGARD, membre et codirecteur de recherche

Souheil-Antoine TAHAN, membre et codirecteur de recherche

Camélia DADOUCHI, membre

DÉDICACE

À mes parents.

REMERCIEMENTS

J'aimerais remercier mes directeurs de recherche qui m'ont guidé et m'ont permis de participer à des conférences pendant ma recherche.

J'aimerais remercier la compagnie minière qui a accepté de partager ses données pour ce projet. J'aimerais aussi remercier mes contacts dans l'entreprise qui ont pris de leur temps pour répondre à mes interrogations sur ces données.

J'aimerais remercier mes parents qui m'ont permis de faire de grandes études.

J'aimerais enfin remercier tous mes amis à Montréal qui ont rendu mon expérience à l'étranger bien plus qu'appréciable.

RÉSUMÉ

La planification des programmes de maintenance dans les exploitations minières est un problème complexe à plusieurs variables, parfois humaines. L'un des principaux problèmes est l'absence d'une bonne estimation du temps de réparation. Sans certitude sur cette estimation, on ne peut pas optimiser le remplissage des garages de maintenances et des véhicules de production pourraient se retrouver inutilement immobilisés, ce qui diminue la production de la mine. L'estimation est effectuée, grâce au jugement d'expert et aux données historiques, par les planificateurs et le contremaître durant une réunion hebdomadaire. Cependant, il apparaît un écart relativement important entre les temps prédits et les temps observés. Le travail proposé ici explore la possibilité de prédire le temps de maintenance (y compris l'inspection et la réparation) à partir des informations contenues dans les historiques des bons de travail de maintenance à l'aide d'algorithmes d'apprentissage automatique. Ces données sont généralement conservées par les entreprises et utilisées uniquement pour l'analyse statistique des performances et l'estimation des rendements (par exemple, la disponibilité, le rendement, la productivité, etc.). Les bons de travail peuvent contenir une description du problème, le temps de maintenance estimé et le temps de maintenance réel (lorsqu'ils sont clôturés). Dans ce travail, l'objectif est de prédire les temps de maintenance. Avant toute construction de modèle de prédiction, il faudra préparer les données grâce à une préanalyse utilisant des méthodes statistiques et des concepts de qualité des données. Les modèles entraînés seront majoritairement des variantes d'algorithmes d'arbres de décision et des réseaux de neurones. Enfin, plusieurs suggestions seront amenées pour améliorer la prédiction des temps de maintenance. Cette recherche fait partie d'un projet plus vaste : la numérisation des outils de maintenance dans l'industrie minière.

ABSTRACT

Planning maintenance programs in mining operations is a complex problem with many variables, including human factors. One of the main problems is the lack of a good estimate of repair time. Without certainty about this estimate, the filling of maintenance garages cannot be optimized, and production vehicles may be unnecessarily immobilized, reducing production of the mine. The estimate is made, using expert judgement and historical data, by the planners and the foreman at a weekly meeting. However, there appears to be a relatively large discrepancy between predicted and observed times. The work proposed here explores the possibility of predicting maintenance time (including inspection and repair) from information contained in maintenance work order histories, using machine learning algorithms. This data is generally retained by companies and used only for statistical analysis of performance and estimation of yields (e.g. availability, efficiency, productivity, etc.). Work orders may contain a description of the problem, the estimated maintenance time, and the actual maintenance time (when closed). In this work, the aim is to predict maintenance times. Before building any prediction model, the data will have to be prepared through pre-analysis using statistical methods and data quality concepts. The models trained will mainly be variants of decision tree algorithms and neural networks. Finally, suggestions will be made for improving the prediction of maintenance times. This research is part of a larger project: the digitization of maintenance tools in the mining industry.

TABLE DES MATIÈRES

DÉDICACE.....	III
REMERCIEMENTS	IV
RÉSUMÉ.....	V
ABSTRACT	VI
TABLE DES MATIÈRES	VII
LISTE DES TABLEAUX.....	X
LISTE DES FIGURES.....	XII
LISTE DES SIGLES ET ABRÉVIATIONS	XIV
LISTE DES ANNEXES.....	XV
CHAPITRE 1 INTRODUCTION.....	1
1.1 Enjeux actuels.....	1
1.2 Maintenance dans les mines souterraines.....	3
1.3 Étude de cas	5
1.4 Objectifs de recherche et Problématique	6
1.5 Plan du mémoire.....	7
CHAPITRE 2 REVUE DE LITTÉRATURE	8
2.1 Valorisation de données dans le domaine minier	8
2.2 Prédiction des temps de maintenance	13
2.3 Prédiction de durée d’opération chirurgicale.....	16
2.4 Qualité des données	20
2.5 Synthèse.....	23
CHAPITRE 3 MÉTHODOLOGIE	25
3.1 Compréhension de l’entreprise et des données.....	26
3.1.1 Évaluation de la situation et collecte des données initiales.....	26

3.1.2	Description des données.....	27
3.1.3	Exploration des données.....	27
3.1.4	Vérification de la qualité des données et détermination de nouveaux objectifs	27
3.2	Préparation des données	27
3.2.1	Sélection des données.....	28
3.2.2	Nettoyage des données	28
3.2.3	Intégration des données	28
3.2.4	Construction de nouvelles données et formatage	28
3.2.5	Séparation des données	29
3.3	Modélisation	29
3.3.1	Génération d'une conception de test	29
3.3.2	Sélection des techniques de modélisation	29
3.3.3	Création des modèles	30
3.3.4	Evaluation du modèle.....	30
3.4	Validation	30
3.4.1	Premier scénario – Prédiction du temps réel	31
3.4.2	Deuxième scénario – Prédiction de l'erreur d'estimation	31
3.4.3	Troisième scénario – Classification des BTs	31
3.4.4	Analyse des résultats	31
CHAPITRE 4	CAS D'ÉTUDE.....	32
4.1	Compréhension de l'entreprise et des données.....	32
4.1.1	Évaluation de la situation et collecte des données initiales.....	32
4.1.2	Description des données.....	35
4.1.3	Exploration des données.....	41

4.1.4	Vérification de la qualité des données et détermination de nouveaux objectifs	51
4.2	Préparation des données	53
4.2.1	Sélection des données.....	53
4.2.2	Nettoyage des données	65
4.2.3	Intégration des données	65
4.2.4	Construction de nouvelles données et formatage	65
4.2.5	Séparation des données	66
4.3	Modélisation	67
4.3.1	Génération d'une conception de test	67
4.3.2	Sélection des techniques de modélisation	69
4.3.3	Création des modèles	70
4.3.4	Évaluation du modèle.....	70
4.4	Validation	73
4.4.1	Premier scénario – Prédiction du temps réel	73
4.4.2	Deuxième scénario – Prédiction de l'erreur d'estimation	76
4.4.3	Troisième scénario – Classification des BTs	80
4.4.4	Analyse des résultats	82
CHAPITRE 5	CONCLUSION	83
5.1	Conclusion	83
5.2	Discussions	84
5.3	Recommandations	85
RÉFÉRENCES		88
ANNEXES		93

LISTE DES TABLEAUX

Tableau 2.1 Similarités entre maintenance et chirurgie	14
Tableau 4.1 Variables de la base de données	35
Tableau 4.2 Description des équipes	38
Tableau 4.3 Compléments d'information sur quelques équipes	39
Tableau 4.4 Description de la colonne "Centre de coûts"	39
Tableau 4.5 Description du type de bon de travail	39
Tableau 4.6 Description du statut du bon de travail	40
Tableau 4.7 Description de la priorité des bons de travail	40
Tableau 4.8 Description de la criticité du bon de travail	41
Tableau 4.9 Les 5 équipements avec le plus de sous-estimation	43
Tableau 4.10 Analyse des variables textuelles	51
Tableau 4.11 Indices de qualité pour chaque dimension	52
Tableau 4.12 Variables inexploitable	53
Tableau 4.13 Test de Games-Howell sur l'équipe 15003	58
Tableau 4.14 Tests statistiques sur les autres variables catégoriques	61
Tableau 4.15 Corrélation des variables numériques avec les heures réelles	61
Tableau 4.16 Variables retenues	62
Tableau 4.17 Ecart moyen et somme des écarts des 5 équipements qui créent le plus de sous-estimation	63
Tableau 4.18 Variables retenues pour la prédiction de l'écart	68
Tableau 4.19 Résultats de prédiction pour la prédiction du temps de maintenance avec des temps d'entraînement différents	71
Tableau 4.20 Résultats des algorithmes pour la prédiction du temps de maintenance	71

Tableau 4.21 Résultats des algorithmes pour la prédiction de l'écart entre estimation et temps réel	72
Tableau 4.22 Résultats des algorithmes pour la stratégie de classification	72
Tableau 4.23 Importance des variables via permutations	79
Tableau 4.24 Résultats de régression - chargeuses navettes	79
Tableau 4.25 Rapport de classification	81
Tableau 4.26 Matrice de confusion	81
Tableau A.1 Test de Games-Howell sur l'équipe 15003	94
Tableau A.2 Tests statistiques sur les autres variables catégoriques	96
Tableau A.3 Corrélation des variables numériques	96

LISTE DES FIGURES

Figure 4.1 Moyenne des heures estimées et réelles entre 2015 et 2022.....	42
Figure 4.2 Maintenances les plus courantes sur les 5 équipements les plus sous-estimés.....	44
Figure 4.3 Ecart moyen pour les maintenances les plus sous-estimées	45
Figure 4.4 Heures réelles et estimées de maintenance sur les fuites d'huiles des boulonneuses ..	46
Figure 4.5 Estimations de la durée de maintenance pour un changement de boyaux sur une boulonneuse en 2021	47
Figure 4.6 Durées de maintenance pour un changement de boyaux sur une boulonneuse en 2021	47
Figure 4.7 Durées de maintenance pour un remplacement de moteur sur une boulonneuse	48
Figure 4.8 Pourcentage d'heures estimées et réelles nulles entre 2012 et 2022	49
Figure 4.9 Les équipements avec le plus de BTs invalides à cause d'une estimation nulle (2012- 2022).....	50
Figure 4.10 Nombre de BTs invalides par mois entre 2012 et 2022 à cause d'une estimation nulle	50
Figure 4.11 Variances des heures réelles de maintenance par équipe (avec intervalle de confiance à 95%)	56
Figure 4.12 Moyennes des heures réelles de maintenance par équipe (avec intervalle de confiance à 95%)	57
Figure 4.13 Moyennes des heures réelles de maintenance par année et par équipe (2012 – 2022)	59
Figure 4.14 Les trois équipements avec le plus de BTs par équipe	60
Figure 4.15 Carte de chaleur des 3 BTs les plus récurrents pour les 5 équipements avec le plus de sous-estimation.....	64
Figure 4.16 Moyenne des Écarts en heures par année (2012 – 2022).....	68
Figure 4.17 Heures de maintenances prédites pour l'opération "changement d'huile moteur"	73

Figure 4.18 Prédiction des temps de maintenance pour 10 opérations	74
Figure 4.19 Analyse des résidus.....	75
Figure 4.20 Analyse des résidus.....	77
Figure 4.21 Prédiction et estimation des temps de maintenance pour 10 opérations.....	78
Figure 5.1 Processus d'ouverture et de fermeture de BTs semi-autonome	87
Figure A.1 Variances des écarts par équipe (avec intervalle de confiance à 95%).....	93
Figure A.2 Moyennes des écarts par équipe (avec intervalle de confiance à 95%)	94
Figure A.3 Écart moyen en heures par année et par équipe (2012 – 2022)	95

LISTE DES SIGLES ET ABRÉVIATIONS

BT(s)	Bon(s) de travail
GMAO	Gestion de la Maintenance Assistée par Ordinateur
MTBF	<i>Mean Time Between Failure</i> (Temps moyen entre défaillances)
AMDEC	Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité
MTTF	<i>Mean Time to Fail</i> (Temps moyen avant une panne)
MTTR	<i>Mean Time to Repair</i> (Temps moyen pour réparer)
GA	<i>Genetic Algorithm</i> (Algorithme génétique)
NN	<i>Neural Network</i> (Réseau de neurones)
SVM	<i>Support Vecteur Machine</i>
MSE	<i>Mean Square Error</i> (Erreur quadratique moyenne)
REQM	Racine de l'erreur quadratique moyenne
RFID	<i>Radio Frequency IDentification</i> (Radio-identification)
CRISP-DM	<i>Cross-Industry Standard for Data Mining</i>

LISTE DES ANNEXES

ANNEXE A ANALYSES COMPLEMENTAIRES	93
---	----

CHAPITRE 1 INTRODUCTION

L'industrie minière est un secteur clé de l'économie mondiale, fournissant des ressources essentielles à diverses industries. Elle est souvent confrontée à des défis opérationnels tels que la gestion de la sécurité des travailleurs dans des environnements dangereux, la fluctuation des prix des matières premières, la nécessité d'innover pour accroître l'efficacité et assurer l'entretien des machines (Ismail et al., 2021; Sánchez & Hartlieb, 2020). Notre travail se concentrera sur ce dernier défi dans le contexte d'une mine souterraine.

1.1 Enjeux actuels

La croissance future des compagnies minières va inévitablement passer par l'investissement dans l'industrie 4.0 et dans des solutions automatisées (Deloitte, 2020; Qi, 2020). Pour cela, l'intelligence artificielle et l'internet des objets apportent des solutions nouvelles pour des problématiques connues telles que la maintenance prédictive et l'automatisation des machines. Dans ce sens, l'industrie minière est de plus en plus équipée pour capturer et exploiter les données massives issues de toutes les activités liées aux mines, notamment grâce à la puissance des réseaux Wi-Fi, 4G et 5G qui permettent aujourd'hui un transfert des données en temps réel (Qi, 2020).

Cependant, d'après les observations de PwC Canada (2023), une grande partie des projets numériques n'aboutissent pas aux résultats escomptés. Les raisons évoquées sont les problématiques inhérentes à la collecte et à l'analyse de données, l'utilisation de plusieurs systèmes d'information et la difficulté de mener des projets technologiques dans ce secteur. Les points essentiels pour réussir sont la création de valeur pour toutes les personnes concernées et l'élaboration d'une stratégie d'exploitation des données.

D'après PwC Canada (2023), les pistes à envisager pour exploiter au maximum la masse de données actuelles et préparer l'exploitation des futures données sont :

- l'analyse automatique des données pour compléter et consolider les analyses réalisées par les employés ;
- le stockage centralisé et normalisé des données pour améliorer leur accessibilité ;

- les nouveaux systèmes de planification des ressources permettent de se soustraire des différentes architectures de stockage proposées par les multiples systèmes utilisés et de faire des liens entre les différentes bases de données.

Quand on parle d'amélioration des processus (amélioration continue, *Lean*, etc.), on pense aussi à la méthode Kaizen. Le rapport de PwC Canada (2023) insiste sur l'importance d'apporter des solutions de petite échelle au lieu de se lancer directement dans un grand plan de numérisation, à les mettre en place progressivement avec l'adhésion des employés(es) pour améliorer les indicateurs clés. Par exemple, l'introduction de nouveaux indicateurs de performance est une mesure de suivi qui peut être mise en œuvre par tout type de minière. Accumuler les petites améliorations procure de bons résultats sur le long terme.

La transition numérique est la priorité pour 49% des minières (PwC Canada, 2023). Par exemple, c'est le premier challenge rencontré dans le domaine de la maintenance minière (Christiansen, 2018).

L'Institut national des mines du Québec définit une mine 4.0 (Bellehumeur & Marquis, 2018; Institut national des mines (Québec), 2018) comme :

- une mine intelligente : capable d'acquérir des données machines et des données humaines et d'utiliser cette information ;
- une mine numérique : avec un modèle de simulation entièrement numérique pour élaborer différents scénarios opérationnels ;
- une mine automatisée : l'automatisation des opérations minières rend les résultats plus prédictibles et reproductibles ;
- une mine intégrée : l'ensemble des opérations, de l'exploitation à la livraison des ressources, sont prises en compte dans l'acquisition des données, dans les simulations et dans les prises de décision.

De plus, Robatto Simard et al. (2023) et Velasquez et al. (2023) constatent que l'industrie minière et la maintenance minière désirent tendre vers une autonomisation des opérations grâce à la captation et l'utilisation des données. Cependant, Qi (2020) soulève que peu de travaux scientifiques ont été menés sur la gestion des données massives dans cette industrie. C'est-à-dire

que la collecte des données, la transformation des données et l'exploitation des données ne suivent pas toujours une méthode ou une stratégie bien définie.

1.2 Maintenance dans les mines souterraines

D'après (Gackowiec et al., 2020), la maintenance joue un rôle essentiel dans l'efficacité de la mine. Chaque panne d'équipement peut mener à des diminutions dans la production de minerai, des changements de planning et une complexification de la gestion des pièces de rechange des équipements.

Le budget pour la maintenance représente jusqu'à 50% des coûts d'exploitation de la mine (Christiansen, 2018; Robatto Simard et al., 2023; Velasquez et al., 2023). En effet, les équipements miniers opèrent souvent dans des environnements complexes, où ils sont soumis à des conditions extrêmes telles que des températures élevées, des vibrations, de la poussière et de l'humidité. Ces conditions peuvent entraîner une usure prématurée des équipements, des défaillances (mécaniques, électriques, etc.) et des risques pour la sécurité. C'est pourquoi la maintenance joue un rôle crucial pour éviter ces problèmes (Velasquez et al., 2023). Chaque opération de maintenance est documentée dans un bon de travail (BT). On y retrouve des informations comme l'équipement concerné, la date, la description de la maintenance, le lieu et le temps estimé de maintenance.

Historiquement, l'objectif de la maintenance est passé de faire des actions correctives (maintenance curative) à réaliser des actions proactives voire prédictives (Leoni et al., 2021).

L'industrie minière réalise des activités de maintenance corrective pour réparer les équipements défectueux (sans alarme) ou endommagés par accident. Cela implique souvent des interventions urgentes pour minimiser les temps d'arrêt (indisponibilité des équipements) et rétablir la production dans les plus brefs délais (Robatto Simard et al., 2023; Said & Taghipour, 2016).

En plus des activités de maintenance corrective, la maintenance préventive est l'un des aspects clés de la maintenance dans l'industrie minière. Elle consiste à effectuer régulièrement des inspections, des révisions et des réparations planifiées pour détecter les signes de dégradation, remplacer des composants usés, prévenir les pannes et augmenter ainsi la fiabilité et la disponibilité de l'équipement. Cela permet de minimiser les temps d'arrêt non planifiés, d'optimiser l'utilisation des équipements, de prolonger leur durée de vie (en évitant des dommages) et de réduire ainsi les coûts

d'opération (Angeles & Kumral, 2020; Balaraju et al., 2018; Velasquez et al., 2023). Plusieurs maintenances de ce type peuvent être réalisées, plus ou moins conséquentes, mais la clé pour que ce soit vraiment efficace réside dans la stratégie adoptée. Par exemple, Angeles et Kumral (2020) proposent une stratégie déterminant l'intervalle optimal entre deux maintenances préventives pour un taux de fiabilité prédéfini, et Balaraju et al. (2018) proposent une stratégie de maintenance préventive pour maximiser la disponibilité de l'équipement. Tubis et al. (2022) proposent une autre vision minimisant les risques d'avoir des pannes dangereuses pour l'humain. Plusieurs indicateurs de performance comme le temps moyen entre défaillances (MTBF) et la disponibilité de l'équipement sont aussi utilisés pour peaufiner la stratégie de maintenance (Odeyar et al., 2022; Robatto Simard et al., 2023).

Enfin, la maintenance prédictive est une autre approche utilisée dans l'industrie minière. Ce n'est pas un nouveau type d'opération, mais un outil pour améliorer la stratégie globale de la maintenance. Elle repose sur l'utilisation de technologies de surveillance avancées telles que les capteurs, les systèmes de télémétrie et l'analyse des données et des signaux pour détecter les signes précurseurs de la défaillance (ex. niveau de l'énergie vibratoire, quantité de particules dans les huiles, etc.). Ces informations peuvent être structurées, semi-structurées ou non structurées d'après Qi (2020). En prévoyant les pannes potentielles, la maintenance prédictive permet d'effectuer des réparations ciblées avant que les problèmes ne deviennent critiques, réduisant ainsi les coûts de maintenance et les temps d'arrêt (Robatto Simard et al., 2023). Dans les années 80, les premières tentatives de prédiction de la fiabilité opérationnelle reposaient sur des approches statistiques (empiriques), ensuite des techniques comme les arbres de défaillance ou l'analyse des modes de défaillances (AMDEC) sont devenues plus populaires. Au début du 21^e siècle, le standard était l'utilisation de logiciels pour identifier la meilleure distribution de probabilité qui colle aux données empiriques des durées de fonctionnement d'un équipement (MTTF : *Mean Time to Fail*) ou encore son temps moyen pour le réparer (MTTR : *Mean Time to Repair*). Enfin, les solutions d'apprentissage machine et d'apprentissage profond sont apparues une dizaine d'années après, comme les algorithmes génétiques (GA), les réseaux de neurones (NN : *Neural Network*) et les supports vecteurs machine (SVM). L'apprentissage machine permet de surmonter la plupart des limites des anciennes méthodes quand il est bien exécuté avec les bonnes données (Odeyar et al., 2022).

En conclusion, la maintenance dans l'industrie minière est essentielle pour assurer la disponibilité, la fiabilité et la sécurité des équipements et de leurs utilisateurs. La combinaison de la maintenance corrective, préventive et prédictive permet de minimiser les temps d'arrêt, d'optimiser les performances et de maximiser la rentabilité des opérations minières.

1.3 Étude de cas

Ce travail a été réalisé dans le contexte industriel d'une mine souterraine au Québec. Les véhicules d'opération sont entretenus dans un garage souterrain. Plusieurs éléments complexifient la planification et l'exécution des maintenances du parc de véhicules : la taille du garage ne permet pas à n'importe quel équipement de rentrer et sortir quand on veut, il faut parfois déplacer un équipement pour qu'un autre sorte ou entre ; les mécaniciens travaillent par quart de travail de huit heures, si une maintenance n'est pas terminée pendant un quart, le mécanicien suivant prend le relais ; les mécaniciens n'ont pas tous le même niveau d'expérience ; il peut y avoir des erreurs dans l'estimation de la durée de la maintenance à réaliser.

La planification des opérations de maintenance doit donc prendre en compte la disposition des garages, la disponibilité des équipements et la disponibilité des équipes. Tout ceci complexifie l'estimation des temps de maintenance et d'après les analyses des données estimées, on observe en moyenne 50% de sous-estimation par rapport aux temps de maintenance réalisés.

Afin d'estimer les temps de maintenance, les planificateurs disposent de leur expérience et d'une base de données regroupant les historiques des bons de travail (BTs) fermés des équipements mobiles souterrains de 2012 à 2022. Pour l'instant, cette base de données est utilisée pour calculer quelques indicateurs de performance (nombre de BT réalisés par rapport au nombre planifié, etc.), corriger les erreurs d'estimations et pour des fins de traçabilité.

Sur un bon de travail, on retrouve trois types d'information :

- les informations textuelles qui décrivent le problème ;
- les informations catégoriques comme le numéro de l'équipement ou la priorité du BT ;
- les informations numériques comme le temps estimé.

Tous ces BTs sont stockés dans un logiciel de gestion de la maintenance assistée par ordinateur (GMAO). Dans ce logiciel, on peut parfois avoir des informations complémentaires comme les pièces utilisées pour un BT ainsi que les commentaires *a posteriori*.

On peut alors calculer la moyenne de l'erreur ($\bar{e}$) entre l'estimation du temps de maintenance (t_e), établi *a priori*, et la valeur réelle (t_r) telle qu'enregistrée *a posteriori*. On peut aussi calculer le coefficient de détermination de Pearson $R^2 \in [0,1]$ qui mesure la qualité d'estimation d'un modèle (en l'occurrence les planificateurs) : plus il est proche de 1, plus l'estimation est bonne.

En évaluant ces mesures sur tous les équipements de la banque de données, on obtient respectivement $\bar{e} = 4,5$ h et $R^2 = 0,22$. Sur les boulonneuses, machines utilisées pour sécuriser les tunnels, on obtient $\bar{e} = 5$ h et $R^2 = 0,38$.

Sachant que le temps moyen d'une maintenance, calculé sur tous les équipements de la mine, est de $\bar{t}_r = 5,3$ h et que le temps moyen d'une maintenance sur une boulonneuse est de $\bar{t}_r = 6,3$ h, l'erreur moyenne est donc presque égale au temps de maintenance moyen. L'estimation actuelle des temps de maintenance n'est donc pas satisfaisante.

Ce travail aura pour but de prédire les temps de maintenance des équipements miniers à partir d'un BT pour soulager le travail des planificateurs. Pour cela, il faudra déterminer comment exploiter l'historique des BTs afin de construire un modèle de prédiction. Ce travail fait partie d'un projet plus large comprenant l'élaboration d'une interface de planification des maintenance (Robatto Simard, 2023) avec un outil de planification automatique (Augustin, 2023).

1.4 Objectifs de recherche et Problématique

Le travail qui suit sera axé sur l'objectif suivant : Prédire le temps de maintenance des équipements miniers (t_r). Plusieurs sous-objectifs en découlent : (1) Analyser la base de données des BTs ; (2) Choisir les variables significatives ; (3) Transformer les variables pour les rendre exploitables ; (4) Construire un modèle de prédiction.

La problématique est donc la suivante : Comment prédire le temps de maintenance des équipements miniers à partir des bons de travail historiques ?

1.5 Plan du mémoire

La revue de la littérature présentée au chapitre suivant permettra d'identifier les travaux de recherche qui ont été faits sur ce sujet. Le chapitre 3 présentera notre méthodologie, le chapitre 4 présentera les analyses préliminaires des données disponibles afin d'évaluer la situation initiale, le chapitre 5 présentera les résultats des modèles de prédiction qui ont été retenus et le chapitre 6 conclura sur les améliorations qui peuvent être implémentées pour avoir de meilleures prédictions.

CHAPITRE 2 REVUE DE LITTÉRATURE

Dans ce chapitre, nous allons identifier les travaux similaires pour trouver quelles bases de données sont propices pour une prédiction du temps de maintenance et quels sont les meilleurs modèles de prédiction. Il faudra faire attention à l'utilisation du mot clé « *mining* » car c'est un homonyme désignant à la fois l'activité physique de miner de la roche et l'activité au sens informatique d'extraire des informations à partir des données. Ainsi, pour sélectionner les travaux liés à l'industrie minière, nous utiliserons l'expression entière « *mining industry* ». Notre revue de littérature porte sur des travaux de recherche portant sur la prédiction de temps de maintenance, effectués entre 2010 et 2023, car c'est la période où les nouvelles méthodes d'intelligence artificielle ont émergé en industrie. La recherche sera majoritairement faite sur la base de données *Web Of Science Core Collection* qui regroupe des articles publiés dans des journaux, des articles de conférence et des livres sur plus de 250 domaines de recherche (Clarivate, 2024). Nous allons toutefois commencer par une recherche sur la valorisation des données dans l'industrie minière dans la bibliothèque de Polytechnique Montréal. Cette bibliothèque nous offre un nombre de références réduit par rapport aux bases de données scientifiques connues mais permet de facilement trouver des travaux de référence pour commencer notre revue de littérature.

2.1 Valorisation de données dans le domaine minier

On aimerait entamer notre revue de littérature avec un livre qui traite de la valorisation des données dans le domaine minier. En effet, les livres peuvent donner un aperçu plus complet sur un sujet particulier par rapport à des articles scientifiques spécialisés dans leur sujet et qui sont souvent soumis à des contraintes de pages donc qui n'ont parfois pas le temps de bien détailler toute leur démarche. Cependant ces ouvrages ne sont pas toujours soumis à des jurys validant leur contenu. C'est aussi pour cela qu'on commence par une recherche dans la bibliothèque de Polytechnique Montréal (à l'aide de l'outil Sofia) qui constitue un premier filtre sur la qualité des contenus. Toutefois on n'exclura pas les autres types de référence dans nos premières recherche si le nombre de références à traiter ne l'oblige pas.

On réalise la requête suivante sur les mots contenus dans les titres, les résumés et les sujets:

kw:data AND kw:"mining industry" AND (yr:2010..2023) (kw désignant « mot-clé »)

On tombe sur 3800 résultats triés par meilleure correspondance, on ne peut pas examiner toutes ces références, mais grâce au premier résultat « *Data analytics applied to the mining industry* » de Soofastaei (2021) qui semble intéressant pour notre recherche, on peut affiner notre requête et chercher les œuvres qui sont répertoriées avec des sujets similaires.

On réalise donc une deuxième requête sur les sujets :

su:("Mining engineering" AND data AND processing) AND (yr:2010..2023) (su désignant « sujet »)

On obtient 31 résultats dont 27 articles. On vérifie les résumés et éventuellement les conclusions pour déterminer les références pertinentes. Parmi ceux là, il y a des articles qui traitent de modèles pour simuler le comportement d'une machine ou d'une roche, d'autres traitent de méthode pour automatiser la collecte de données capteur, certains traitent de modèles de gestion des coûts de l'entreprise et le reste ne traite pas de prédiction. Aucun n'est relié à notre cas d'étude mais on peut tout de même noter que l'exploitation des données intéresse l'industrie minière. Sur les cinq livres, on met de côté les recueils d'articles de conférence car quand on se focalisera sur une recherche sur les articles, on retrouvera ceux qui nous intéressent. On met aussi de côté un guide sur l'utilisation d'un logiciel de simulation minière.

On ne se retrouve qu'avec « *Data analytics applied to the mining industry* » de Soofastaei (2021). Dans ce livre, l'auteur relève dans son introduction que l'industrie minière est en retard par rapport aux autres industries dans la transformation numérique. Ensuite, il présente les stratégies les plus efficaces d'aide à la prise de décision (planification, nécessité de réparations, etc.) : l'apprentissage machine et l'apprentissage profond, en donnant quelques outils pour les appliquer (algorithmes génétiques, classificateurs, agrégateurs, réseaux de neurones, etc.). Dans le chapitre suivant, l'auteur présente les types de données (structurées et non structurées), les sources possibles (humain, machine, processus), le cycle de vie des données et la question de la qualité des données. Il en profite pour rappeler que la qualité est essentiel pour tout projet lié aux données. Pour qualifier la qualité des données, l'auteur donne cinq dimensions : la disponibilité, l'utilisabilité, la fiabilité, la pertinence et la qualité de la présentation. Les trois défis les plus communs sont : les données manquantes, les données redondantes et les données hétérogènes (de différents types). Ensuite, l'auteur présente plusieurs étapes de prétraitement des données : la collecte, le filtrage vers les

données qui servent au projet, le nettoyage des erreurs, la fusion de tableaux de données, la génération de données ou de variables, la transformation (normalisation, etc), la réduction de dimensionnalité (analyse en composantes principales, etc), la standardisation des dates et la transformation des images et du texte. Pour les données sous le format texte, plusieurs représentations en vecteurs ou en dictionnaires (informatiques) sont possibles. L'auteur propose ensuite plusieurs outils d'analyse des données. Dans un premier temps on réalise une analyse de la variance (ANOVA), une analyse de corrélation et une modélisation des données (Weibull). Il y a aussi une approche qui repose sur la représentation d'état dans la science de l'automatique. La dernière approche vise à utiliser des modèles de prédiction, par exemple les régressions, la prédiction de séries temporelles et les modèles d'apprentissage machine. L'auteur s'intéresse justement à ces dernières méthodes qui ont fait leur apparition en maintenance prédictive. Ainsi, les algorithmes les plus utilisés sont les forêts aléatoires, les réseaux de neurones, les supports vecteur machine, les k-moyennes et les algorithmes d'apprentissage profond (réseaux de neurones profonds, réseaux convolutionnels et réseaux récurrents). Enfin, l'auteur montre les avancées dans la réduction des gaz à effet de serre grâce à l'analyse de données et il donne des recommandations à l'échelle de l'entreprise pour prendre les bonnes décisions à partir des analyses faites.

On peut retenir plusieurs choses de cet ouvrage :

- Les algorithmes d'apprentissage machine et d'apprentissage profond donnent les meilleurs résultats. Par conséquent, on va axer la recherche sur ces outils si possible.
- On pourra aussi utiliser les méthodes statistiques classiques (ANOVA, ...) pour analyser les données.
- La qualité des données est essentielle. Sachant que l'industrie minière est en général en retard sur la transformation numérique, évaluer la qualité des données est donc essentielle pour expliquer d'éventuels mauvais résultats est une approche intéressante.
- L'étape de prétraitement des données et éventuellement leur transformation est essentielle.
- Les forêts aléatoires, les réseaux de neurones et les supports vecteur machine sont des potentiels algorithmes pour prédire une valeur.
- L'auteur ne fait pas mention de prédiction des temps de maintenance.

On a ainsi déterminé les principaux points-clé sur lesquels on pourra se concentrer lors de la lecture d'articles scientifiques. On souhaite maintenant chercher des articles qui résument et analysent les

connaissances actuelles sur un sujet particulier en se basant sur des études précédemment publiées, qu'on appelle par la suite des articles de synthèse, pour nous guider vers les travaux qui nous intéressent. On peut maintenant faire une recherche avec une requête qui comprend un large panel de travaux mais qui permettra d'identifier ces articles de synthèse (publiés après 2010). On réalise la requête suivante, restreint aux mots dans les titres, dans les résumés et dans les mots-clé, sur l'outil de recherche *Web Of Science*:

Data “mining industry”

On trouve 77 articles de synthèse. On repère après une lecture des titres et des résumés 5 articles qui pouvant traiter de la prédiction dans la maintenance minière.

Liang et al. (2023) identifient cinq sujets de recherche quand on parle de données : l'internet des objets, la visualisation des données, la gestion des données, l'analyse des données et les jumeaux numériques. Malheureusement pour nous, les auteurs ne développent pas sur l'exploitation des données en maintenance.

Gackowiec et al. (2020) ont regroupé les indicateurs de performances dans plusieurs catégories (indicateurs temporels, indicateurs de sécurité, etc.). L'une de ces catégories regroupe les indicateurs sur la maintenance. On a par exemple le nombre de défaillances par jour/semaine/mois/an, le temps moyen entre défaillances et le nombre total de minutes de pauses par quart de travail.

Noriega et Pourrahimian (2022) synthétisent des articles sur les mines à ciel ouvert. Trois types de sujets sont prédominants : la planification de la production, le contrôle du nivellement et la gestion de l'équipement. Sur ce dernier sujet, les principales applications sont le suivi des équipements, le contrôle de la consommation et la répartition des équipements, et la méthode privilégiée est la simulation d'événements discrets même si l'apprentissage supervisé est utilisée pour prédire le comportement des équipement et leur consommation. L'apprentissage supervisé comprend les réseaux de neurones, les algorithmes dérivés des arbres de décision, les supports vecteur machine et les k plus proches voisins.

Jung et Choi (2021) proposent une revue systématique des application de l'apprentissage machine dans les mines. Les auteurs regroupent les articles en plusieurs catégories : exploration des minerais, planification de la mine, forage, gestion de l'équipement, gestion géotechnique, sécurité, détection de surface et gestion du risque. Les modèles les plus utilisés sont ceux à base de réseaux

de neurones, les réseaux bayésiens, les modèles à base d'arbre de décision et les régressions. Il y a une trentaine de métriques différentes utilisées pour évaluer ces modèles, les plus populaires étant la racine de l'erreur quadratique moyenne, le coefficient de détermination, la précision et la moyenne de l'erreur absolue (dans l'ordre de popularité). Les algorithmes qui utilisent ces métriques sont en général les variantes de réseaux neuronaux, les supports vecteur machine et les arbres de décision. Le seul article traité qui porte sur la maintenance prédictive propose un modèle pour la prédiction de pannes.

Azhari et al. (2023) s'intéressent plus particulièrement aux articles utilisant des techniques d'apprentissage profond. Ces articles sont parus pour la majorité après 2019. L'algorithme le plus populaire est le réseau neuronal convolutionnel, suivi par les réseaux plus classiques et les réseaux récurrents. Les auteurs reprennent les catégories de Jung et Choi (2021). Ils relèvent deux articles traitant de la maintenance. L'un s'interroge sur la classification de type de courroie de transport à partir d'image et l'autre veut prédire les probabilités de défaillances d'équipement minier.

On peut compléter cette requête avec l'article de Brzychczy (2021), proposé par les directeurs de recherche de ce mémoire. L'auteur distingue plusieurs applications à l'utilisation des données dans les mines souterraines : la synthèse, le regroupement, les règles d'association, l'estimation, la classification et l'analyse de séries temporelles. Il observe une augmentation des publications dans le domaine à partir de 2015. Cette fois l'auteur a regroupé les articles en quatre catégories : diagnostique des équipements, géomécanique, risque et gestion de la mine. Les algorithmes les plus populaires sont les réseaux de neurones, les modèles à base d'arbre de décision, les modèles d'induction de règles et les régressions.

On remarque une similarité parmi les articles qui traitent de modèles d'analyse des données : les mêmes algorithmes ressortent, c'est-à-dire les dérivés des réseaux neuronaux et les dérivés des arbres de décision. Jung et Choi (2021) ont aussi montré que la racine de l'erreur quadratique moyenne est la métrique la plus utilisée pour les tâches d'estimation de valeur.

Cette requête a montré que les sujets étudiés se rapportant à la maintenance sont le suivi d'équipement avec la mise en place d'indicateurs de performance ou la prédiction de probabilité de panne.

On réalise quand même sur recherche plus précise au cas où les articles de synthèse n'auraient pas couvert le sujet de notre mémoire. On va ainsi utiliser des synonymes trouvés grâce à nos

connaissances et grâce au dictionnaire de synonymes de l'université de Cambridge (Cambridge University Press & Assessment, 2024). On réalise donc une requête du type « (maintenance OU synonymes) ET (prédiction OU synonymes) ET (temps OU synonymes) ET mines » pour trouver les travaux en rapport avec notre sujet :

(maint OR repair*) AND (estim* OR pred* OR forecast* OR anticipat*) AND (tim* OR duration OR cycle OR makespan OR downtime OR delay) AND "mining industry"*

(Dans *Web Of Science*, restreint aux mots dans les titres, dans les résumés et dans les mots-clé)

Nous obtenons 76 articles. Après examen des titres et des résumés, les sujets abordés en rapport avec la maintenance prédictive sont surtout les prédictions de temps avant la défaillance et les prédictions de fiabilité (Odeyar et al., 2022; Shukla et al., 2022). Ces travaux ne sont pas utiles dans notre cas parce que ces prédictions se basent sur des données télémétriques de capteurs sur les équipements.

2.2 Prédiction des temps de maintenance

Encore une fois, on commence par une recherche sur les articles de synthèse. Une nouvelle requête a donc été initiée pour élargir à toute la maintenance industriel (on retire le mot-clé « *mining* ») :

(maint OR repair*) AND (estim* OR pred* OR forecast* OR anticipat*) AND (tim* OR duration OR cycle OR makespan OR downtime OR delay) AND industry*

(Dans *Web Of Science*, restreint aux mots dans les titres, dans les résumés et dans les mots-clé)

Avec cette requête, nous avons obtenus 3920 articles dont 246 articles de synthèse. Aucun de ces articles de synthèse ne traite spécifiquement de la prédiction de temps si on en croit leur titre. Par exemple, Achouch et al. (2022) et Zonta et al. (2020) montrent que les chercheurs se concentrent sur l'évitement des pannes et la prédiction de quand aura lieu la panne. On fait une nouvelle requête pour réduire le nombre d'articles en retirant des synonymes et en cherchant directement les mots-clés "*maintenance time*" et "*repair time*" :

("maintenance time" OR "repair time") AND (estimation OR prediction OR forecast) AND industry

(Dans *Web Of Science*, restreint aux mots dans les titres, dans les résumés et dans les mots-clé)

On obtient ainsi 18 articles dont un seul article qui parle vraiment de temps de maintenance après une lecture rapide des articles accessibles.

L'étude de Arif et Wang (2018) aborde l'importance de la restauration du système électrique après des événements météorologiques extrêmes. Pour rétablir efficacement l'électricité, les services publics doivent estimer le temps de réparation des composants endommagés. Les auteurs affirment que les quelques tentatives de prédiction précédentes ont été réalisées avec des modèles probabilistes. Les auteurs analysent les données de pannes sur une période de 6 ans d'un service public d'électricité aux États-Unis. Ils présentent d'abord les caractéristiques statistiques des pannes et étudient les caractéristiques des pannes lors de différents événements météorologiques. Dans la deuxième partie, ils utilisent un réseau neuronal profond pour prédire les temps de réparation des systèmes endommagés. Les données pour chaque panne comportent : le temps de réparation, le nombre de clients interrompus, l'heure de début et de fin de la panne, le lieu, la cause et le numéro de circuit du réseau de distribution. Les auteurs ont fait une étude préliminaire sur la pertinence des variables. Dans le cas étudié, il y avait seulement huit causes possibles (panne, animal, neige...) ce qui diffère sensiblement de nos données où on a plusieurs centaines de causes de maintenance.

Cette dernière requête a identifié un article qui tente de prédire un temps de maintenance, mais les auteurs n'étaient pas confrontés à des données similaires aux nôtres (numériques, catégoriques et textuelles). Mis à part le fait qu'une analyse de l'importance des variables est faite, cet article est peu utile pour notre recherche. Nous sommes tombés sur quelques articles du domaine médical lors des requêtes précédentes. On peut faire un rapprochement entre une opération chirurgicale et une opération de maintenance. En effet, les termes de maintenance comme « diagnostic » sont tirés du domaine médical et on peut faire des parallèles entre « réparer » un humain et réparer une machine. On peut ainsi dresser un tableau de similarités entre la chirurgie et la maintenance (Tableau 2.1).

Tableau 2.1 Similarités entre maintenance et chirurgie

Maintenance	Chirurgie
Machine	Patient
Réparation	Opération
Mécanicien	Chirurgien
Garage	Bloc opératoire
Ordonnancement des maintenances	Ordonnancement des opérations
Bon de travail	Fiche d'opération

De plus, pendant la maintenance, le mécanicien peut réaliser des réparations qui ne sont pas toujours prévues dans les temps estimés des BTs, de même, pendant une opération chirurgicale, le chirurgien peut être amené à gérer des hémorragies ou d'autres complications.

La réparation d'équipements miniers nécessite une connaissance de chaque organe de la machine et des pièces et des outils nécessaires. De même, un chirurgien possède une expertise dans son domaine mais doit savoir comment chaque élément du corps humain interagit avec la zone opérée. Le temps de maintenance ou le temps d'opération peuvent aussi être affectés par l'expérience du mécanicien ou du chirurgien.

Il reste cependant quelques différences entre la chirurgie et la maintenance. Dans le premier cas, le diagnostic est toujours posé avant l'opération pour déterminer si elle est nécessaire. Dans le deuxième cas, un diagnostic est posé pour les maintenance conditionnelles et après les maintenances préventives mais le diagnostic complet n'est pas toujours connu avant les maintenances correctives. On peut donc trouver plus d'information dans les fiches d'opération que dans les BTs concernant ce qu'il y a à faire.

La chirurgie humaine est caractérisée par la diversité d'un individu à l'autre, ce qui rend la standardisation plus difficile. Les chirurgiens doivent faire preuve d'une grande adaptabilité et personnaliser leurs interventions en fonction des caractéristiques uniques de chaque patient. On ne retrouve pas une telle diversité dans les équipements miniers mais on peut quand même noter qu'il y a plusieurs types de machines remplissant différentes fonctions et parmi celles-là on peut retrouver dans une même mine plusieurs modèles différents et plusieurs constructeurs différents. Même s'il y a moins d'informations dans un BT qu'une fiche d'opération, il y a besoin de moins d'informations pour une maintenance que pour une chirurgie.

Enfin, la chirurgie impose des contraintes uniques qui modifient radicalement l'approche par rapport à la maintenance industrielle. La gestion de la durée, l'anesthésie, la surveillance des fonctions vitales, les considérations éthiques, et l'irremplaçabilité du patient créent un environnement où la précision, l'efficacité, et la prise de décision rapide sous pression sont beaucoup plus cruciales que dans le contexte industriel. Toutefois, la flotte d'équipements miniers doit assurer une certaine disponibilité pour atteindre les objectifs de production quotidiens, les machines doivent être lavées avant les maintenances et remplacer un équipement est possible mais coûteux et chronophage pour une mine souterraine.

On retrouve donc plusieurs similarités entre la maintenance et la chirurgie au niveau des processus, des opérations, de l'environnement et les personnes concernées.

D'après Wu et al. (2016), les salles d'opération sont parmi les services les plus coûteux dans les hôpitaux. Un défi pour optimiser l'efficacité des salles d'opération est d'améliorer la planification des chirurgies, ce qui nécessite l'estimation de la durée des interventions chirurgicales ou durée d'opération, défini comme le temps entre l'entrée du patient dans le bloc opératoire et sa sortie. C'est un enjeu pareil au notre. Actuellement, ce temps découle de l'estimation des chirurgiens qui se basent sur leur expérience, ce qui peut entraîner des biais. On constate ainsi que dans ce domaine, on retrouve les mêmes défis.

Grâce à toutes ces similarités, nous pouvons nous inspirer des travaux faits sur la prédiction de temps d'opération pour espérer avoir des données plus semblables à ce que nous avons.

2.3 Prédiction de durée d'opération chirurgicale

On réalise directement une recherche précise sur les articles et on pourra élargir vers des articles de synthèse avec une requête large si on ne trouve pas de travaux pertinents pour notre travail. Voici la requête qui a été utilisée pour chercher les articles dans ce domaine :

("surgical procedure duration" OR "surgical duration" OR "surgical procedure time" OR "surgical time") AND (estimation OR prediction OR forecast)

(Dans *Web Of Science*, restreint aux mots dans les titres, dans les résumés et dans les mots-clé)

On obtient 138 articles. Après une lecture des titres et des résumés, nous retenons 8 articles, car ils proposent un modèle de prédiction des temps d'opération.

Wu et al. (2016) et Wu et al. (2017) proposent un modèle qui utilise les 20 dernières estimations du chirurgien pour corriger l'estimation de sa prochaine opération. Ce modèle est entraîné dans le cadre d'une seule opération (arthroplastie du genou ou remplacement de la valve de l'aorte principale). L'idée est de calculer les moyennes des 2, 3, 5, 10 et 20 dernières estimations puis d'analyser si ces dernières seraient meilleures que la prochaine estimation du chirurgien.

Taaffe et al. (2021) travaillent à partir du type de procédure, d'anesthésie, de l'expérience des équipes et d'autres variables numériques ou catégoriques pour prédire un temps d'opération. Les

auteurs utilisent une autre méthode de prédiction par rapport à Wu et al. (2016); (2017). Ils montrent qu'avec la méthode d'estimation par noyau on peut avoir des résultats plus parlants et aussi précis que les méthodes statistiques traditionnelles comme la modélisation par une loi log-normale ou par un mélange gaussien. De plus, l'estimation par noyau requiert moins de données que les méthodes précédentes. En outre, les auteurs insistent sur le fait que beaucoup de travaux mélangent tout type d'opérations ce qui complexifie la prédiction. Les auteurs mettent en garde sur l'interdépendance des variables, ils analysent donc l'importance de leurs variables en conséquence.

Edelman et al. (2017) utilisent encore une autre méthode comparent un modèle simple de prédiction de durée de procédure opératoire (temps d'anesthésie et temps d'opération) qui consiste à multiplier le temps estimé par le chirurgien par 1.33 et une régression linéaire utilisant plusieurs variables indépendantes dont le temps estimé par le chirurgien. Les modèles sont comparés en calculant l'erreur moyenne absolue, la moyenne des erreurs au carré et le coefficient de détermination R^2 . Les procédures utilisées pour entraîner les modèles sont en moyenne de 150 minutes. L'importance des variables est testée en comparant plusieurs modèles de régression linéaire où on change le jeu de variables d'entrée, les auteurs examinent la p – *valeur* de chaque variable pour déterminer si elle est pertinente. Ils concluent ainsi que les variables qui n'améliorent que très peu les métriques précédentes ne sont pas utiles au modèle. D'autres modèles sont aussi entraînés sans l'estimation du chirurgien pour prédire seulement le temps pour l'anesthésie. Ces derniers sont moins performants que les modèles qui prédisent directement le temps de procédure. Les données qui ont été utilisées pour l'entraînement datent de 2012 à 2015 et les données de 2016 ont été utilisées pour l'évaluation.

Tan et al. (2019) utilisent des méthodes d'apprentissage machine par rapport aux auteurs précédents. Ils se confrontent à des données qui présentent plusieurs défis : le temps de 45% des opérations n'est pas estimé, le chirurgien principal peut déléguer une opération à un autre chirurgien et les données patients et chirurgiens sont sensibles donc seulement accessibles par les chirurgiens. Les données sont soit numériques, soit catégoriques. 1308 opérations différentes sont considérées et il y a en moyenne 8 opérations identiques dans leur base de données. Deux hypothèses sont testées : au moins un des facteurs concernant l'équipe de chirurgiens est pertinent pour la prédiction et l'expérience du chirurgien principal est une information suffisante pour prédire la durée de l'opération. Plusieurs modèles de renforcement du gradient sont entraînés après avoir réalisé une analyse d'importance des variables. Pour déterminer le niveau d'expérience du

chirurgien principal à partir de ses informations non sensibles, les auteurs ont recours à un arbre de décisions qui utilise plusieurs données catégoriques concernant ce chirurgien. Ensuite, trois modèles sont entraînés : le premier prend en compte toutes les données sauf l'expérience du chirurgien principal ; le second ne prend pas en compte les données sur les chirurgiens ; et le dernier prend en compte l'expérience du chirurgien principal. Les modèles sont évalués avec la racine de la moyenne de l'erreur carrée. Les hypothèses sont testées avec une variante du test de *Student* et les deux sont rejetées. Les données sur l'équipe de chirurgiens sont donc essentielles et l'expérience calculée du chirurgien principal suffit à remplacer son expérience réelle.

Martinez et al. (2021) analysent une solution basée sur l'apprentissage automatique pour prédire le temps chirurgical. Les auteurs comparent quatre algorithmes d'apprentissage automatique (régression linéaire, support vecteur machine, arbres de régression et arbres bagués) pour prédire la durée des interventions chirurgicales dans un hôpital universitaire. Les données historiques de 2004 à 2019 ont été utilisées pour entraîner ces algorithmes et les deux derniers mois de cette période ont servi pour l'évaluation. La comparaison entre les quatre algorithmes a été réalisée en fonction de l'erreur quadratique moyenne (EQM) entre la durée chirurgicale prédite et le temps réel. Les meilleures performances globales ont été obtenues avec la méthode des arbres bagués sur un sous-ensemble de la base de données représentant 80% des interventions chirurgicales. Les arbres bagués ont également surpassé la méthode basée sur l'expérience, mais on passe d'une surestimation prédominante à une sous-estimation de la durée des interventions chirurgicales. Les données utilisées sont numériques et catégoriques. On y retrouve plus de 1200 codes d'opérations possibles et 300 codes chirurgiens possibles.

Tan et al. (2019) se sont concentré sur l'influence des variables sur la prédiction alors que Martinez et al. (2021) ont analysé l'influence sur choix de l'algorithme sur la prédiction.

Jiao et al. (2020) développent une nouvelle approche qui utilise des variables structurées (numériques ou catégoriques) et du texte écrit par un humain. Les auteurs construisent des modèles qui prédisent la loi de distribution de la durée d'opération, grâce à une prédiction de la moyenne et de l'écart type. En effet, des études précédentes ont montré que les durées d'opérations suivent une loi log-normale. Les auteurs transforment ainsi les durées d'opération de leur base de données pour avoir une moyenne nulle et un écart-type de 1 pour leur modèle de prédiction. Ils transforment de même la durée estimée. Les autres variables d'entrée sont le jour de la semaine, le lieu, les données

sur la procédure, sur le chirurgien et le patient. Elles sont toutes utilisées par les modèles de prédiction. Les variables catégoriques sont encodées en vecteurs binaires (*one-hot encoding*). Le nom de la procédure et le diagnostic chirurgical sont des variables textuelles non contraintes, cette dernière est la description de la procédure correspondante. Les déterminants et les pronoms (*stop words*) sont retirés de ces variables. L'âge des patients a été normalisé et si l'information est manquante, elle est remplacée par l'âge moyen. Les variables catégoriques manquantes sont représentées par un vecteur nul et les textes manquants comme vides. Les données de 2013 à 2016 sont utilisées pour entraîner les modèles et les données de 2017 servent à l'évaluation des modèles. Une validation croisée à cinq blocs est utilisée pour optimiser les modèles. Trois modèles d'arbres de décision sont entraînés : simple, forêt aléatoire et renforcement du gradient. Pour ces modèles, les données textuelles sont transformées en uni-grammes et bi-grammes puis encodées en l'inverse de leur fréquence dans toutes les données. Un réseau de neurones multimodal (à plusieurs types d'entrées) a été entraîné. Les données de la façon suivante : les variables textes sont transformées en tenseurs numériques qui sont transformés en vecteurs grâce à un réseau de neurones récurrent ; les données catégoriques sont représentées par plongement en un vecteur ; les données continues sont normalisées. Les vecteurs obtenus sont concaténés puis la résultante passe dans un réseau de neurones à une couche. Les résultats des trois têtes représentent ainsi les paramètres d'un mélange gaussien. La fonction objectif utilisée est la log-vraisemblance. Ces modèles sont comparés à une méthode bayésienne adaptée au problème. La métrique de comparaison est une méthode statistique qui compare des distributions à des valeurs réelles (*continuous ranked probability score*). Parmi les 53 783 opérations recensées, 1048 sont écartées car la durée d'opération réelle ou estimée par le chirurgien est manquante. Le modèle le plus performant est le réseau à trois têtes, suivi par l'arbre à renforcement du gradient.

Zhong et al. (2023) exploitent une base de données d'opérations orthopédiques avec des variables similaires. Cette fois les données de test (70% des données) et les données d'évaluation (30%) sont choisies aléatoirement. La validation croisée à 10 blocs est utilisée pour calculer l'erreur quadratique moyenne des modèles. Trois modèles sont testés : régression linéaire, forêt aléatoire et réseau de neurones. Le texte est traité de plusieurs façons : premièrement, on ignore les variables textuelles ; deuxièmement, on retire les caractères spéciaux, les mots vides et on ne prend que la racine de chaque mot pour les représenter sous forme d'un sac de mots ; troisièmement (seulement testé avec le réseau de neurones), le texte est dépourvu de mots vides puis encodé grâce à

ClinicalBERT, un encodeur bidirectionnel pré-entraîné sur des notes du dossier médical de patients. Ces modèles sont aussi comparés à un modèle simple qui prend la moyenne des trois dernières mêmes opérations faites par le même chirurgien. Les variables texte, ainsi transformées en vecteurs numériques, sont concaténées avec les autres variables pour pouvoir être traitées par les modèles. Les données utilisées comportent 201 entrées et la durée d'opération dure entre 65 et 90 minutes. Les réseaux de neurones se sont montrés les plus performants dans les différents cadres. Le modèle qui utilise *ClinicalBERT* a une racine de l'erreur quadratique moyenne deux fois inférieure au modèle simple. Les autres modèles n'améliorent que de 10% au maximum cette métrique.

Tan et al. (2019) et Martinez et al. (2021) ont utilisé des algorithmes d'apprentissage machine alors que Jiao et al. (2020) et Zhong et al. (2023) ont pu utiliser des algorithmes d'apprentissage profond grâce à une bonne exploitation des variables textuelles. Par ailleurs, on retrouve les mêmes algorithmes d'apprentissage machine que dans la section 2.1 Valorisation de données dans le domaine minier.

2.4 Qualité des données

Comme mentionné au début du chapitre, nous effectuons une recherche sur la qualité des données pour mieux préparer le prétraitement des données. Par ailleurs, d'autres auteurs tels que Achouch et al. (2022) soulignent l'importance de la qualité des données dans les défis de la maintenance prédictive. Les autres défis sont plus reliés à l'organisation et la gouvernance de l'entreprise donc nous allons nous concentrer sur ce défi de qualité des données. On cherche donc plusieurs travaux proposant une méthode ou des solutions pour avoir des données de qualité. On cherche d'abord s'il y a des travaux centrés sur l'industrie minière pour avoir plus de chance de trouver des défis similaires à notre étude de cas.

Nous avons effectué une recherche sur Web of Science et Google Scholar les articles entre 2010 et 2023 avec les requêtes suivantes, limitées aux titres dans un premier temps pour sélectionner seulement les articles qui nous intéressent (on pourra élargir aux mots dans les résumés si besoin) : [Titre: "data quality" AND mining AND industry] et [Titre: industry AND "data quality"]

On trouve un article sur Google Scholar et six sur Web of Science.

Les travaux de Anastasova et Yanev (2021) portent sur les approches modernes du stockage et du traitement des données, ainsi que sur les technologies permettant d'obtenir des données de bonne qualité dans l'industrie minière. Deux architectures de base de données sont proposées, NoSQL et NewSQL, car elles sont faites pour gérer les grands volumes de données et elles permettent des changements de structure des données, ce qui les rend idéales pour des processus interconnectés. En outre, les auteurs présentent cinq critères structurels pour qualifier la qualité des données :

- l'exhaustivité qui consiste à s'assurer que tous les attributs ont été introduits ;
- l'exactitude qui consiste à s'assurer que les données entrantes dans le système d'information sont correctes ;
- la validité qui consiste à s'assurer que les valeurs des données sont correctement mesurées conformément aux conditions préétablies ;
- la cohérence qui consiste à s'assurer que les données sont enregistrées dans le même format et que ce format reste le même ;
- la consistance qui consiste à s'assurer que les données sont captées en continu et qu'il n'y a pas d'interruption dans le temps.

Les auteurs présentent aussi quatre critères du point de vue des utilisateurs pour qualifier la qualité des données :

- la disponibilité qui consiste à s'assurer que les données sont toujours disponibles pour les utilisateurs ;
- la facilité d'utilisation qui consiste à s'assurer que les données sont faciles à utiliser ;
- la compréhensibilité qui consiste à s'assurer que les données sont compréhensibles ;
- la sécurité qui consiste à s'assurer que les données sont protégées contre tout accès non autorisé.

L'article présente aussi plusieurs techniques pour assurer une bonne qualité des données.

- Standardisation des données : établir une base de règles et de critères préétablis qui garantit que les données correspondent aux attentes de chaque utilisateur et qui est contrôlée tout au long du cycle de vie de la donnée.

- Profilage des données : analyser le contenu, la qualité et la structure des données de sortie. Il faut une évaluation initiale des données pour déterminer la perte d'information et identifier les lacunes potentielles et réelles.
- Correspondance des données : comparer des ensembles de données provenant de sources différentes pour garantir la cohérence des données.
- Contrôle des données : surveiller l'évolution de la qualité des données au fil du temps et de signaler les écarts par rapport aux indicateurs de qualité prédéfinis.

Les auteurs concluent sur le fait que chaque entreprise minière doit adapter ces notions suivant ses propres besoins.

Goknil et al. (2023) résument les travaux qui ont été faits sur la qualité des données dans les systèmes cyber-physiques et l'internet des objets de l'industrie 4.0. Leur synthèse présente les problèmes de qualité, les meilleures pratiques et les solutions pour mieux gérer les données. Les principaux problèmes rencontrés sont les valeurs aberrantes, les valeurs manquantes, le grand nombre de dimensions et le bruit. Les principales causes recensées sont les pannes de capteurs, les sources hétérogènes des données, les problèmes de réseau et la fréquence d'échantillonnage. Plusieurs métriques, rassemblées dans plusieurs dimensions, ont été utilisées pour qualifier la qualité des données. Elles peuvent être quantitatives, qualitatives ou un mélange des deux. Ensuite, plusieurs techniques de réparation et de nettoyage des données sont rassemblées. Ces techniques visent principalement à corriger les valeurs manquantes à vérifier la véracité des données, à détecter les valeurs aberrantes, à filtrer le bruit et à réduire la dimension des données. Les analyses de qualité des données ont été majoritairement faites avec *Python*, *R* et *C*.

Selon l'article de Juddoo et al. (2018), les dimensions clés de la qualité des données qui sont importantes dans le secteur de la santé sont l'exactitude, l'exhaustivité, la cohérence, la fiabilité et le caractère à jour.

Dans le domaine ferroviaire, on retrouve les mêmes dimensions que dans les articles précédents (Fu & Easton, 2017). Les auteurs proposent aussi une définition globale de la donnée et de la qualité des données. Chaque critère concernant la base de données correspond à une ou plusieurs dimensions et à un ou plusieurs indicateurs de qualité.

Shardt et al. (2020) proposent un algorithme de partition des données en plusieurs régions. Le but est de séparer des modes de fonctionnement d'une machine à partir de l'évolution dans le temps

des variables. Il s'agit de calculer des métriques comme la variance et la moyenne en considérant pas à pas les observations suivantes dans le temps et dès qu'on a un écart trop grand par rapport à un seuil défini, on considère qu'on change de mode.

Forti et al. (2019) testent deux modèles d'apprentissage machine qui classifient des événements comme fonctionnement normal ou anomalie. Le but est d'automatiser l'analyse de la qualité des données sans besoin de choisir et tester manuellement quelles métriques sont adaptées pour cette tâche. Le premier modèle, un réseau de neurones, nécessite l'étiquetage d'une base de données d'événements jugés bons ou mauvais. Le deuxième modèle, un auto-encodeur, n'a pas besoin de l'étiquetage de toutes les données pour être entraîné.

Finalement, Eskandarzadeh et al. (2023) montrent que la charge de travail, la fatigue et l'implication des gestionnaires ont une influence sur l'adhérence des opérateurs à des procédures standards pour la collecte des données. Plus on augmente la charge de travail et la fatigue, moins les opérateurs vont suivre à la lettre de telles procédures. Des interventions des gestionnaires comme une bonne communication, la mise en place de formation adéquates, des mesures incitatives et un bon suivi améliorent l'adhérence des opérateurs. Un bon usage des technologies avec des interfaces simples d'utilisation et l'automatisation de certaines tâches permettent de réduire le fardeau des travailleurs.

2.5 Synthèse

Nous avons vu que peu d'études opèrent avec des données à la fois numériques, catégoriques et textuelles. En général, pour la prédiction des temps, les chercheurs font tous une analyse de la pertinence des variables, à travers une analyse de corrélation pour les variables numériques ou une comparaison des résultats de prédictions en ajoutant les variables type par type. Quelques auteurs ont utilisé des méthodes plus classiques (Edelman et al., 2017; Taaffe et al., 2021; Wu et al., 2016) mais nous allons suivre les indications de Soofastaei (2021) et nous concentrer sur l'utilisation des modèles d'apprentissage machine. Les meilleurs modèles pour traiter les données numériques et catégoriques sont des réseaux de neurones (Arif & Wang, 2018; Martinez et al., 2021) et des variantes des arbres de décision (Martinez et al., 2021; Tan et al., 2019). Pour les variables textuelles, il faut utiliser des modèles plus adaptés pour extraire les informations, comme la transformation en n-grammes puis en données fréquentielles, les réseaux de neurones récurrents

(Jiao et al., 2020) ou les encodeurs bidirectionnels pré-entraînés (Zhong et al., 2023). Cette dernière méthode n'est pas praticable notre cas, car un modèle pré-entraîné comme dans l'étude de Zhong et al. (2023) n'existe pas dans le domaine de la maintenance industrielle.

En termes de pré-traitement des données, on peut retenir la normalisation des données continues, l'encodage des données catégoriques en vecteurs binaires. On retient aussi le nettoyage des textes : enlever les mots vides (déterminants, pronoms, ...) et réduire les mots à leur racine. Les trois types de données peuvent être simplement concaténées pour pouvoir être traitées par un modèle de prédiction. Quelques articles parlent aussi de leurs résultats d'analyse (moyennes, nombre de catégories, ...). Enfin, la majeure partie des articles choisissent la dernière année ou les derniers mois de leur base de données comme données de validation. Les autres pratiquent la validation croisée.

D'autre part, nous avons vu que les travaux sur la qualité des données s'appuient sur des dimensions pour qualifier la qualité et dégager des indicateurs (Anastasova & Yanev, 2021; Fu & Easton, 2017; Goknil et al., 2023; Juddoo et al., 2018). Les solutions pour améliorer la qualité sont sur mesure par rapport aux problèmes rencontrés (Goknil et al., 2023). On peut cependant s'en inspirer pour recommander des améliorations à apporter à notre base de données. Plusieurs catégories de solutions peuvent être envisagées. En effet, la qualité des données est impactée par les processus de collecte, la structure des données, la technologie de la base de données et l'entretien de la base de données.

Dans le chapitre suivant nous aborderons la méthode utilisée pour traiter notre cas d'étude.

CHAPITRE 3 MÉTHODOLOGIE

On rappelle que l'objectif est d'avoir un modèle pour prédire les temps de maintenances. On rappelle aussi qu'on dispose de données, provenant d'une exploitation minière souterraine, contenant plus de 300 000 bons de travail présentant trois types d'informations (numériques, catégoriques et textuelles).

Nous allons nous inspirer de la méthode *Cross-Industry Standard Process for Data Mining* (CRISP-DM), Schröer et al. (2021) soulignent que cette méthode est très utilisée dans les projets de valorisation de données industrielles en raison de sa robustesse et de son applicabilité à une grande variété de projets. Cette méthodologie offre un cadre structuré en six étapes principales qui permettent de mener à bien un projet d'analyse de données, de la phase de définition des objectifs à la phase de déploiement. Les six étapes sont :

- La compréhension des besoins industriels : il faut comprendre les objectifs du projet et les besoins de l'entreprise. Cette étape consiste à définir les objectifs du projet, comprendre les exigences commerciales, et à traduire ces besoins en un problème de valorisation des données bien défini.
- La compréhension des données : en lien avec l'étape précédente, il faut collecter les données initiales et se familiariser avec elles. Cette étape comprend l'exploration des données, l'identification de la qualité des données et la découverte des premières tendances, anomalies ou relations entre les données.
- La préparation des données : il faut nettoyer et préparer les données pour le modèle. Cela inclut la sélection des variables pertinentes, le traitement des valeurs manquantes, la transformation des données et la fusion des différentes bases de données.
- La modélisation : il faut choisir et appliquer différentes techniques de modélisation aux données préparées. Cette étape implique de sélectionner les algorithmes appropriés, d'ajuster les paramètres des modèles et d'évaluer les performances des modèles créés.
- L'évaluation par rapport aux objectifs industriels : il faut évaluer la qualité et l'efficacité des modèles développés par rapport aux objectifs commerciaux définis. Cette étape consiste à vérifier si les modèles répondent aux critères de succès et à déterminer s'ils peuvent être déployés dans un environnement opérationnel.

- Le déploiement : Il s'agit de mettre en œuvre le modèle dans un environnement réel où il peut être utilisé pour prendre des décisions. Cela peut inclure la création de rapports, l'intégration du modèle dans des systèmes décisionnels ou même l'automatisation des prédictions.

CRISP-DM est une méthodologie flexible et itérative, ce qui signifie qu'il est possible de revenir en arrière ou de réviser certaines étapes à mesure que de nouvelles informations sont découvertes au cours du projet. Nous exploiterons toutes ces étapes sauf la phase de déploiement.

3.1 Compréhension de l'entreprise et des données

Premièrement, nous allons réaliser l'étape de compréhension du cas industriel et des données. Nous avons choisi de regrouper ces deux étapes en une car elles peuvent se faire en parallèle, l'une venant avec l'autre.

Dans la méthode de IBM (2021), la compréhension de l'entreprise comprend la détermination des objectifs commerciaux, l'évaluation de la situation (données disponibles, personnel nécessaire, facteurs de risque et plan de secours), la détermination des objectifs de l'exploration de données et la production d'un plan de projet.

L'objectif du mémoire a déjà été dégagé donc les étapes d'évaluation de la situation et de détermination des objectifs de l'exploration des données sont celles que nous réaliserons.

Dans la méthode de IBM (2021), la compréhension des données comprend la collecte des données initiales, la description des données, l'exploration des données et la vérification de la qualité des données.

Dans notre cas, nous réaliserons toutes ces étapes.

3.1.1 Évaluation de la situation et collecte des données initiales

Il s'agira d'abord de mieux cerner l'environnement physique des machines et l'environnement virtuel des données.

Environnement physique des machines

Nous rappellerons l'environnement des garages souterrains, les principaux équipements entretenus dans les garages et les différents acteurs de la maintenance.

Environnement virtuel des données

Nous pourrions examiner quel outil gère l'interface entre les humains et les données, quel est le cycle de vie des données, de quelles données nous pouvons disposer.

Autres informations mêlant les deux environnements

Nous pourrions aussi relever d'autres informations, surtout sur les processus, relevant des deux environnements.

3.1.2 Description des données

Comme indiqué dans l'œuvre de Soofastaei (2021), il faudra déterminer ce que désigne chaque attribut de la base de données, les relations entre les attributs, leur format et leurs valeurs possibles.

3.1.3 Exploration des données

Nous explorerons ensuite les données pour essayer de retrouver le constat des planificateurs à propos de la sous-estimation globale des temps de maintenance. Nous pourrions aussi dégager quels équipements et quelles maintenances sont en cause.

3.1.4 Vérification de la qualité des données et détermination de nouveaux objectifs

Après cela, nous allons évaluer la qualité des données pour déceler d'autres spécificités. Nous positionnerons donc notre jeu de données dans les dimensions de l'article de Anastasova et Yanev (2021), car c'est celui qui se rapporte au domaine minier et les autres articles énoncent plus ou moins les mêmes dimensions. On pourra ainsi définir nos attentes et potentiellement d'autres sous-objectifs.

3.2 Préparation des données

Avec toutes ces informations sur les données, nous allons donc pouvoir préparer nos données.

Dans la méthode de IBM (2021), la préparation des données comprend la sélection des données, le nettoyage des données, la construction de nouvelles données, l'intégration de données et le formatage de données.

Nous ajoutons simplement l'étape de séparation des données propre à la construction de modèle d'apprentissage automatique à toutes ces étapes.

3.2.1 Sélection des données

Nous allons choisir les variables pertinentes pour notre objectif avec des méthodes statistiques. Les variables numériques seront retenues suivant leur corrélation de Pearson avec la variable cible (celle qu'on doit prédire) et les variables catégoriques seront choisies en menant des tests ANOVA qui permettront de déterminer si deux échantillons avec des valeurs différentes pour un même attribut se comportent différemment. Nous pourrons aussi définir si on garde toutes les données pour l'entraînement de notre modèle.

3.2.2 Nettoyage des données

Nous allons nettoyer les données incomplètes et les données aberrantes.

3.2.3 Intégration des données

Nous allons voir comment fusionner nos bases de données potentielles.

3.2.4 Construction de nouvelles données et formatage

Nous expliquerons la transformation des données catégoriques et des textes qui va être réalisée à la manière de Jiao et al. (2020). Cette étape va être réalisée automatiquement par une fonction de la librairie Python *AutoGluon* (Erickson et al., 2020), avec sa version 0.8.2. D'après Wang et al. (2024) et Paladino et al. (2023), l'utilisation de librairies d'apprentissage machine automatisé comme *AutoGluon* donne de meilleurs résultats dans leur domaine médical que la construction traditionnelle de modèles de prédiction. César de Sá et al. (2022) confirme cela dans la prédiction de la taille d'herbe dans le domaine des géosciences. Quant à eux, Pan et Dagneu (2022) utilisent *AutoGluon* pour estimer le taux d'oxygène dans des systèmes d'aération et Witvoet et al. (2023) l'utilisent pour prédire l'autonomie de véhicules électriques. Nous détaillerons lors de la mise en œuvre de la méthodologie la fonction qui nous intéresse dans cette librairie.

3.2.5 Séparation des données

De plus, pour entraîner un modèle de prédiction à base d'algorithmes d'apprentissage automatique, il faut séparer les données en deux ensembles (trois si on veut optimiser les hyperparamètres des modèles) d'entraînement et de validation lors d'une validation classique. Il est aussi possible de faire de la validation croisée.

3.3 Modélisation

Dans la méthode de IBM (2021), l'étape de modélisation comprend la sélection des techniques de modélisation, la génération d'une conception de test, la création des modèles et l'évaluation du modèle. Nous interchangeons les deux premières sous-étapes pour la compréhension du mémoire.

3.3.1 Génération d'une conception de test

Vu qu'il n'y pas de certitudes sur la faisabilité de la prédiction après avoir effectué notre recherche bibliographique, nous allons mener trois stratégies de prédiction :

- Prédire le temps de maintenance sans utiliser l'estimation des planificateurs (estimation qu'on est censé remplacer grâce au modèle de prédiction)
- Prédire l'erreur d'estimation des planificateurs, on prendra donc leur estimation en compte et on pourra introduire une variable représentant l'écart entre le temps estimé et le temps réel
- Prédire si l'estimation des planificateurs est sous-estimée ou surestimée, cela revient à une correction incomplète de leur estimation

Chacune de ces stratégies permettrait d'aider le planificateur dans sa tâche à plus ou moins grande échelle en cas de résultats satisfaisants. Pour les deux dernières stratégies, nous prendrons soin de réaliser une nouvelle étape de sélection des données parce qu'on modifie la variable à prédire.

3.3.2 Sélection des techniques de modélisation

Nous allons tester plusieurs algorithmes vus dans le chapitre précédent comme nous n'avons pas trouvé de travaux qui ont travaillé sur la prédiction du temps de maintenance à partir d'un bon de travail. Nous allons donc tester les algorithmes basés sur les arbres de décision, les forêts aléatoires,

les réseaux de neurones et les réseaux récurrents si les données sont adéquates pour ce genre d'algorithme.

3.3.3 Création des modèles

Pour construire plusieurs modèles de prédiction, la librairie *AutoGluon* s'apparente bien à ce genre de cas, elle contient des fonctions qui permettent d'entraîner plusieurs modèles et d'identifier leurs meilleurs paramètres automatiquement. Ces fonctions peuvent entraîner des réseaux de neurones, des algorithmes basés sur les arbres de décisions, des forêts aléatoires, des RNN et des encodeurs bidirectionnels. Ce qui est intéressant avec une librairie comme *AutoGluon*, c'est que nous ne sommes pas obligés de définir un seul algorithme pour faire la prédiction, c'est-à-dire que grâce à une fonction de la librairie, nous pouvons entraîner les algorithmes relevés dans la littérature et obtenir un modèle de prédiction qui utilise le meilleur algorithme parmi ceux entraînés. Comme nous ne sommes pas certain de la supériorité d'un des algorithmes par rapport aux autres, entraîner tous les algorithmes qui peuvent potentiellement être les meilleurs permet d'éviter d'en écarter certains qui peuvent donner de meilleurs résultats en changeant quelques hypothèses de départ. Nous sommes exactement dans ce cas avec nos trois scénarios.

3.3.4 Evaluation du modèle

Nous allons quand même pouvoir identifier le meilleur algorithme et quels scénarios de prédiction précédemment établis sont réalisables. Pour cela, nous utiliserons la racine de l'erreur quadratique moyenne (REQM) comme vu dans la revue de littérature ou la précision ($= \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux positifs}}$) pour la classification.

3.4 Validation

Dans la méthode de IBM (2021), l'étape de validation comprend l'évaluation des résultats, le processus de révision et la détermination des étapes suivantes.

Nous ferons simplement une évaluation des résultats et une analyse de ces résultats avant de pouvoir conclure notre mémoire.

3.4.1 Premier scénario – Prédiction du temps réel

Nous allons formaliser une évaluation des résultats du premier scénario par rapport aux objectifs du mémoire. Nous évaluerons aussi l'influence des variables sur la prédiction.

3.4.2 Deuxième scénario – Prédiction de l'erreur d'estimation

De même pour le deuxième scénario.

3.4.3 Troisième scénario – Classification des BTs

De même pour le troisième scénario.

3.4.4 Analyse des résultats

Nous expliquerons les résultats obtenus au regard du travail sur la qualité des données.

Dans le chapitre suivant, nous pourrons mettre en œuvre cette méthodologie avant de conclure sur les résultats du cas d'étude.

CHAPITRE 4 CAS D'ÉTUDE

Avant de commencer la préparation des données et la modélisation, nous présentons le contexte du cas d'étude.

4.1 Compréhension de l'entreprise et des données

Dans cette section, nous présenterons l'environnement (la base de données, ses liens avec l'entreprise et le logiciel associé) et le processus de création et de modification des BTs.

4.1.1 Évaluation de la situation et collecte des données initiales

Environnement physique des machines

Il existe plusieurs types d'équipements miniers mais les principales machines mobiles utilisées pour l'exploitation d'une mine souterraine sont :

- Les chargeuses-navettes transportent le minerai extrait depuis le front de taille jusqu'aux systèmes de convoyage, aux camions miniers ou à des points de transfert intermédiaires.
- Les boulonneuses sont utilisées pour stabiliser le toit et les parois des tunnels dans les mines souterraines. Elles installent des boulons d'ancrage dans la roche pour prévenir les effondrements.
- Les camions miniers sont utilisés pour transporter de grandes quantités de minerai, de terre ou de déchets. Ils sont essentiels pour le déplacement du matériau extrait vers les zones de traitement ou de stockage.
- Les foreuses sont utilisées pour forer des trous dans la roche, généralement pour le placement d'explosifs.
- Les excavatrices servent à creuser et déplacer de grandes quantités de roche.

Comme dit dans l'introduction, ces équipements sont réparés dans des garages souterrains, relativement proches de la zone d'exploitation, avec des problèmes d'encombrement.

Environnement virtuel des données

La mine utilise un système de GMAO. C'est un logiciel informatique utilisé pour gérer et optimiser les opérations de maintenance. La GMAO aide à suivre, planifier, exécuter et analyser les activités de maintenance, que ce soit pour des équipements, des machines, des installations ou des infrastructures.

Généralement, dans un système de GMAO, on y retrouve les fonctionnalités suivantes :

- Gestion des actifs : Suivi des informations détaillées sur chaque actif, y compris les caractéristiques techniques, les spécifications, les dates d'achat et de garantie, etc.
- Planification de la maintenance : Programmation des tâches de maintenance préventive, telles que les inspections régulières, les opérations d'entretien et les révisions périodiques.
- Suivi des interventions : Enregistrement de toutes les interventions de maintenance effectuées, y compris les détails sur les problèmes résolus.
- Gestion des stocks : Gestion des stocks de pièces de rechange et des fournitures nécessaires pour les opérations de maintenance.
- Suivi des coûts : Analyse des coûts liés à la maintenance pour identifier les domaines où des économies peuvent être réalisées ou encore où des améliorations peuvent être apportées.
- Suivi des performances : Collecte de données sur les temps d'arrêt, les taux de défaillance, les temps de réponse et d'autres métriques de performance de la maintenance.

En automatisant les processus de gestion de la maintenance et en fournissant des informations pertinentes en temps réel, la GMAO contribue à améliorer l'efficacité opérationnelle globale d'une organisation. C'est dans ce système que les bons de travail (BT) sont gérés et stockés depuis 2012. On peut aussi retrouver une fenêtre « annexe » associé à un BT et une fenêtre concernant les pièces utilisées.

Il y a deux types de bons de travail : ceux générés **automatiquement** par le système (pour les maintenances préventives) et ceux ajoutés **manuellement** dans le système de GMAO (pour les maintenances correctives). Ces derniers peuvent être créés par un utilisateur, que ce soit le mécanicien, le superviseur ou le planificateur, mais ils doivent être approuvés lors de réunions périodiques, sinon ils ne sont pas retenus.

Ensuite, l'équipe de planification évalue le temps et identifie les pièces requises ainsi que la main-d'œuvre et ressources nécessaires. Une fois que le matériel est en magasin, le BT sera en attente de planification. Des réunions entre superviseur et planificateurs sont organisées pour planifier ces BTs. Quand le superviseur reçoit la planification, il répartit les mécaniciens sur chaque BT. À la fin de leur quart de travail, ces derniers inscrivent dans leur carte de travail le temps qu'ils ont passé sur chaque BT. Enfin, le superviseur rajoute des écritures au journal du système de GMAO et les heures de maintenance des BTs sont comptabilisées

Autres informations mêlant les deux environnements

D'autres informations ont été mis en avant par les planificateurs :

- Les heures estimées sont d'abord inscrites par la personne de métier et elles sont ensuite révisées lors de la rencontre quotidienne où participent le superviseur général et le planificateur.
- Le temps de lavage estimé est compris dans l'estimation et dépend de la taille de l'équipement.
- L'assignation des employés dépend de la nature de la maintenance à effectuer. L'information des employés est accessible, mais prendre note que ce n'est pas tous les BT qui sont estimés par métier.
- Il existe un outil complémentaire qui permet de catégoriser en codes Action et Composant le bon de travail avec une liste préétablie de mots-clés par un algorithme de reconnaissance de texte. Mais personne ne l'utilise.
- Il existe quelques BTs modèles pour les opérations courantes.
- Le niveau de connaissance des employés attribués aux bons de travail est disponible dans le système de GMAO lorsque le temps réel est entré dans le bon de travail.
- Une petite partie (<5%) des BTs sont traités en externe. Dans ce cas les heures réelles sont égales à 0.
- Il ne devrait pas y avoir de BTs où les heures estimées de maintenance ou les heures réelles de maintenance sont nulles. Si c'est le cas, c'est une faute de frappe ou un oubli.

De plus, les planificateurs révèlent qu'il y a beaucoup de données où les heures réelles sont additionnées et notées sur un même bon de travail. Pour analyser les données, il faudra écarter

celles où les heures réelles sont nulles. Cependant, il n'est pas possible de trouver sur quels bons de travail sont reportées les heures manquantes ni de quantifier quel taux d'erreur cela engendre. Nous devons ignorer cette agrégation des bons de travail et, par conséquent, les erreurs qu'elle peut engendrer dans notre analyse des données et nos modèles de prédiction.

4.1.2 Description des données

Nous disposons d'une base de données regroupant les bons de travail « fermés » (complétés) des équipements mobiles souterrains qui couvre la période de 2012 à 2022 inclusivement. Dans ces BTs, on retrouve notamment la description de la maintenance, les heures estimées ($t_e \in \mathbb{R}_+ [\text{h}]$) par la personne de métier ainsi que la durée réelle de maintenance ($t_r \in \mathbb{R}_+ [\text{h}]$). On rappelle qu'idéalement on souhaite prévoir cette durée réelle à partir des autres informations sur le bon de travail.

Dans le Tableau 4.1 on retrouve toutes les variables (colonnes) recensées dans cette base de données.

Tableau 4.1 Variables de la base de données

Colonne (sans transformation)	Explication des abréviations	Type	Exemple
No bon de travail	Numéro BT	Catégorique	572818
Équipe		Catégorique	15010
T. D.	Type de demande	Catégorique	WO
No Unité	Numéro de l'équipement	Catégorique	CN6101
Parent		Catégorique	CN6
Description condensée		Catégorique	CHARGEUSE NAVETTE ECJ 210
Fabr.	Fabricant	Catégorique	JAR

Tableau 4.1 Variables de la base de données (suite)

Catég. Equip.	Catégorie équipement	Catégorique	EQU
Stat. Eq.	Statut équipement	Catégorique	VE
Groupe équipement		Catégorique	S-T
Type équipement		Catégorique	MOB
Type BT		Catégorique	1
Priorité BT		Catégorique	2
Statut BT		Catégorique	99
Description		Texte	FUITE OIL
Travail effectué		Texte	CHANGER UNE HOSE
BT ppal	BT principal	Catégorique	572818
Sté	Société	Catégorique	11
Centre Coûts		Catégorique	11406
Magasin		Catégorique	1101
Date Création		Date	01/01/2012
Date début planifié		Date	01/01/2012
Date fin planifiée		Date	01/01/2012
Date fin demandée		Date	01/01/2012
Date fin Réelle		Date	01/01/2012
Composante 1		Catégorique	1

Tableau 4.1 Variables de la base de données (suite et fin)

Composante 1 Desc	Description	Catégorique	ACCESSOIRE
Code Action 1		Catégorique	10
Code Action 1 Desc	Description	Catégorique	AJUSTER
Composante 2		Catégorique	1
Composante 2 Desc	Description	Catégorique	ACCESSOIRE
Code Action 2		Catégorique	10
Code Action 2 Desc	Description	Catégorique	AJUSTER
Heures estimées		Numérique	1
Estimation M.O.	Main-d'œuvre	Numérique	1
estim. Matières	Estimation	Numérique	6.48
Montant estimé		Numérique	6.48
Divers estimés		Numérique	0
Heures réelles		Numérique	3
MO Réelle	Main-d'œuvre	Numérique	189.96
Matières réelles		Numérique	6.48
Montant (\$) réel		Numérique	349.03

« No bon de travail » est juste un numéro attribué arbitrairement qui sert au logiciel de GMAO. « N° Unité », « Parent », « Description condensée », « Fabr. » sont des variables qui permettent de savoir quel équipement est concerné. « N° Unité » désigne le code de la machine, il peut y avoir plusieurs machines du même modèle donc il faut pouvoir les différencier. « Parent » et

« Description condensée » désignent le modèle de la machine et « Fabr. » désigne le fabricant du modèle. « Description » et « Travail effectué » sont les variables les plus importantes car elles définissent la maintenance qui va être effectuée. « Groupe équipement » désigne si l'équipement concerné est utilisé pour l'exploitation souterraine ou en surface. « Type équipement » désigne si l'équipement concerné est une machine mobile ou une installation fixe.

À la suite d'échanges concernant la base de données avec l'entreprise minière partenaire du projet, nous avons obtenus quelques informations complémentaires sur les colonnes restantes. « T. D. » ou « Type de demande » définit si c'est une maintenance qui n'a pas pu être complètement réalisée précédemment ou une nouvelle maintenance. « Catég. Equip. » ou « Catégorie équipement » qualifie le type d'équipement (exploitation ou transport). « Stat. Eq. » ou « Statut équipement » qualifie si l'équipement est hors-service ou partiellement hors-service. « Sté » ou « Société » qualifie si la maintenance est une maintenance recommandée par le fabricant (souvent des inspections et des maintenance préventives).

Le Tableau 4.2 présente la description et le nombre d'employés associés à chaque équipe.

Tableau 4.2 Description des équipes

Équipe	Description	Nombre d'employés
15003	Équipe mobile S/T 1	4
15004	Équipe mobile S/T 2	28
15010	Équipe mécanique chantier	16
15013	Équipe Élect S-T Mobile	3
15020	Équipe mobile S/T 3	40
15050	Équipe frigoristes Mobile	4
25651	Équipe électrique chantier	11
15063	Équipe mobile 4	20
15067	Équipe Élect. Mobile 4	3

En pratique ce n'est pas toute une équipe qui travaille sur une maintenance mais un seul membre de cette équipe dans la très grande majorité des cas. Le Tableau 4.3 montre que certaines équipes sont associées à un seul garage.

Tableau 4.3 Compléments d'information sur quelques équipes

Équipe	Garage
15003	134
15004	206
15020	278
15063	Surface

Les garages ne se situent pas à la même profondeur. Ainsi, ces équipes ne travaillent pas dans les mêmes garages. Par conséquent, elles ne travaillent pas sur les mêmes équipements et les mêmes outils. On peut donc supposer que l'équipe joue un rôle sur le temps de maintenance.

Les opérations diffèrent selon le métier (les sigles des métiers sont expliqués dans le Tableau 4.4), donc on peut aussi supposer que cette variable joue un rôle sur le temps de maintenance.

Tableau 4.4 Description de la colonne "Centre de coûts"

Code	Description
WEL	Soudeur
MEC	Mécanicien
CON	Contracteur
ELE	Électricien
ACT	Frigoriste
MET	Mécanicien de tracteur

Le type de bon de travail est une information essentielle. Entre une maintenance corrective et une maintenance préventive, le temps d'opération peut varier. Le Tableau 4.5 donne la description du type de BT.

Tableau 4.5 Description du type de bon de travail

Type	Description
1	Bon de travail correctif
2	Bon de travail correctif après inspection
4	Bon de travail modification
6	Maintenance préventive
7	Bon de travail parent
8	Bon de travail permanent

Le statut du bon de travail résume sa position dans son cycle de vie. Normalement, les bons de travail de notre base de données ont pour statut « 99 ». Cette variable est utile lors de l'extraction des données, mais pas pour la prédiction.

Le Tableau 4.6 donne la description du statut du BT.

Tableau 4.6 Description du statut du bon de travail

Statut	Description
08	Maintenance préventive générée
10	Nouvelle demande
15	Demande approuvée
30	En planification
48	En attente d'approbation ou d'ingénierie
50	En attente de matériel
60	Prêt à être ordonnancé (banque de travail)
65	Ordonnancé
70	En exécution
76	Fermeture d'un BT permanent
80	Fermeture partielle
95	Fermeture finale
98	Annulé
99	Fermeture définitive

Les priorités sont importantes pour l'ordonnancement des activités de maintenance. Par conséquent, il faudra vérifier que cette variable joue un rôle sur le temps de maintenance.

Le Tableau 4.7 donne la signification de la priorité des BT.

Tableau 4.7 Description de la priorité des bons de travail

Priorité	Description	Définition
1	Immédiat (urgent)	Intervention immédiate et sans délai
2	Bris de calendrier	Intervention durant la semaine en cours. N'est pas urgent, mais ne peut pas attendre à la semaine prochaine.
3	Date requise	Indication d'une date, doit être plus tard que la semaine en cours
4	Équipement en arrêt	Prochain arrêt de l'équipement ou lors de la prochaine maintenance
5	Travaux en arrêt	Prochain arrêt du secteur (« shutdown »)

Le niveau de criticité d'un équipement est fonction des conséquences liées à sa défaillance sur la productivité des opérations minières, ainsi que le degré associé de sécurité. La criticité peut être aussi justifiée par le nombre d'unités dans une flotte. Par exemple, la foreuse « DL » est unique et par conséquent est considérée comme critique. Le Tableau 4.8 donne la description de la criticité des BT.

Tableau 4.8 Description de la criticité du bon de travail

Criticité	Description
A	Élevé
B	Modéré
C	Faible
D	Non critique

De la même manière que la priorité, il est intéressant de vérifier si cette variable joue un rôle significatif sur le temps de maintenance.

Les colonnes « Composante X » et « Code action X » sont automatiquement remplies par le logiciel de GMAO à l'aide d'une reconnaissance de mots-clés dans la description. « Composante » désigne la partie de la machine où il faut intervenir et « Code action » représente un verbe d'action comme « changer » désignant la tâche à effectuer.

Il reste encore des colonnes à décrire mais on verra dans la section suivante (qui a été réalisée en majeure partie, chronologiquement, avant de cribler les planificateurs de questions) que ces colonnes ne pourront pas être exploitées dans notre travail.

4.1.3 Exploration des données

La base de données regroupe 335 730 BTs fermés concernant les équipements mobiles souterrains de 2012 à 2022.

D'abord, nous retrouvons le constat des planificateurs en représentant les moyennes des heures de maintenance estimées en bleu et les moyennes des heures de maintenance réelles en orange par année entre 2015 et 2022 dans la Figure 4.1.




Figure 4.1 Moyenne des heures estimées et réelles entre 2015 et 2022

On remarque tout de suite le problème que rencontrent les planificateurs. Les barres bleues sont largement en dessous des barres orange donc les estimations sont largement en dessous de la réalité. Même si cela s'améliore d'années en années, les temps de maintenance restent largement sous-estimés. Nous investiguerons d'où vient cet écart.

Avant cela, on remarque rapidement que plusieurs colonnes sont redondantes, vides ou quasi-vides (5% des lignes sont renseignées au maximum), ou constantes ou quasi-constantes (au moins 95% des lignes sont égales). Les attributs « Parent », « Description Condensée », « Modèle » sont redondants entre eux, désignant le modèle de la machine. Les attributs « Catég. Equip. », « Groupe équipement », « Type équipement », « Statut BT » et « Divers Estimés » sont constants ou quasi-constants. L'attribut « BT ppal » est une copie de l'attribut « No bon de travail ». Les attributs « Composante X » et « Code action X » sont quasi-vides. L'attribut « Estimation M.O. » est redondant avec l'attribut « Heures Estimées ». Les attributs « Estim. Matières », « Montant Estimé » et « Matières Réelles » sont égaux donc redondants. Pour les attributs redondants, il faut en retenir un pour la suite, on garde donc « No bon de travail », « Description Condensée », « Heures Estimées » et « Estim. Matières ». Les autres attributs redondants ou constants ne sont pas exploitables. On vérifie par ailleurs que « Groupe équipement », « Type équipement », « Statut BT » sont respectivement égaux à « S-T » (équipements souterrains), « MOB » (équipements mobiles) et « 99 » (BTs fermés).

Nous continuons d'explorer cette base de données en relevant les équipements qui impactent le plus les retards de maintenance, c'est-à-dire les équipements qui créent le plus de volume horaire de sous-estimation. Sur le Tableau 4.9, on sort les cinq équipements qui ont le plus d'écart ($|t_e - t_r|$) en volume.

Tableau 4.9 Les 5 équipements avec le plus de sous-estimation

Description Condensée	Ecart moyen	Somme des Ecarts	Nombre de BTs
CHARGEUSE TORO 1400 8 VERGES	-3.517322	-29408.33	8361
CHARGEUSE CAT R2900	-5.184834	-19883.84	3835
BOULONNEUSE	-4.603251	-19117.30	4153
CAMION TORO 50D	-2.734080	-15614.33	5711
BOULONNEUSE MEM946	-3.172771	-14448.80	4554

Ce sont donc les maintenances sur les chargeuses Toro qui causent le plus de sous-estimations suivies de loin par les chargeuses CAT, les boulonneuses et les camions Toro.

Sur ces équipements, il est intéressant de voir quelles sont les maintenances qui peuvent causer le plus de sous-estimation. Nous représentons donc des cartes de chaleur des trois maintenances pour chaque équipement qui créent le plus de retard dans les plannings de maintenance. Dans la Figure 4.2, on retrouve les trois maintenances les plus courantes sur ces cinq équipements.




Figure 4.2 Maintenances les plus courantes sur les 5 équipements
les plus sous-estimés

On peut voir que les chargeuses ont des mêmes maintenances. Nous pourrions donc utiliser les données des deux chargeuses en commun pour entraîner un modèle de prédiction mais nous voyons aussi que la maintenance « INSPECTION A/C » est présente en très grand nombre. Nous pourrions donc se confronter à un problème d'équilibrage de données, cette maintenance pourrait polluer l'information contenue dans d'autres BTs en influençant trop le modèle à se concentrer sur la prédiction de la maintenance majoritaire. Nous remarquons aussi la présence de « REPARATIONS SUITE MAINTENANCE » qui sont des maintenances qu'on ne peut pas estimer comme il n'est pas possible d'en connaître la nature avant l'inspection ou la maintenance préventive précédant cette maintenance.

Ensuite, nous représentons, dans la Figure 4.3, l'écart ($t_e - t_r$) moyen pour chacune de ces maintenances.




Figure 4.3 Ecart moyen pour les maintenances les plus sous-estimées

On remarque tout de suite que les BTs « réparations suite maintenance » créent le plus d'écart en moyenne. Cela peut se comprendre car on ne peut pas estimer à l'avance le temps de ces réparations qui sont déterminées pendant les phases d'inspection pendant la maintenance. Il faudra aussi retirer ces BTs de l'ensemble d'apprentissage car on ne peut pas avoir d'information sur ceux-là. On remarque aussi que même si les maintenances sont courantes comme pour les entretiens électriques, les certifications du système d'incendie, les changements de boyaux et les maintenances préventives 250 heures, il peut y avoir un écart conséquent entre l'estimation et le temps réel de maintenance. Pendant ces maintenances, le mécanicien peut commencer des réparations implicitement prévues dans ces BTs mais impossible à prévoir avant d'inspecter la machine. La prédiction sur ce genre de BTs peut donc s'avérer infaisable.

Nous allons maintenant vérifier si sur une maintenance plus standard du type « fuite d'huile » sur les boulonneuses, on observe aussi des erreurs d'estimation. Nous représentons donc dans la Figure 4.4 les heures réelles en bleu et les heures estimées en orange des BTs avec « fuite huile » en description.




Figure 4.4 Heures réelles et estimées de maintenance sur les fuites d'huiles des boulonneuses

On remarque déjà dans les descriptions que la fuite d'huile peut provenir de plusieurs endroits différents (différents moteurs). Les heures de maintenances réelles ne sont pas du tout uniformes. Pour le label « FUITE HUILE MOTEUR » cela peut aller de 3 heures de maintenance à presque 50 heures de maintenance. On remarque aussi que les planificateurs arrivent à prédire quand il y aura un gros volume d'heures nécessaire pour certaines fuites d'huile alors que dans notre base de données de BTs, rien ne peut nous donner cette information.

Par ailleurs, pour les opérations assez récurrentes, l'estimation est corrigée une fois par an. On peut voir ça sur la Figure 4.5 qui trace l'évolution des heures estimées pour un changement de boyaux sur une boulonneuse sur l'année 2021.




Figure 4.5 Estimations de la durée de maintenance pour un changement de boyaux sur une boulonneuse en 2021

On voit qu’au cours de l’année, l’estimation est passée de 25 à 35 heures. Cependant, en regardant les temps de maintenance réels, on se rend compte qu’il y a parfois un grand écart avec l’estimation. La Figure 4.6 représente l’évolution des heures réelles pour ces mêmes maintenances.




Figure 4.6 Durées de maintenance pour un changement de boyaux sur une boulonneuse en 2021

Il y a jusqu’à 30 heures de plus ou de moins entre l’estimation de la durée et le temps réel. De plus, nous ne pouvons pas distinguer de tendance particulière. Observons maintenant une opération moins courante :




Figure 4.7 Durées de maintenance pour un remplacement de moteur sur une boulonneuse

Sur la Figure 4.7, on a représenté les opérations contenant les mots « changer » et « moteur » dans leur description (en haut de chaque barre) sur une boulonneuse : en bleu le temps de maintenance réel et en orange le temps de maintenance estimé. On remarque qu'il y a une estimation différente pour chaque opération, certainement parce que ces opérations sont moins courantes (maximum une opération par année) et plus complexes.

Explorons plus en détail la répartition des données avec heures estimées et heures réelles nulles. La Figure 4.8 présente les pourcentages de données avec des heures estimées et réelles.




Figure 4.8 Pourcentage d'heures estimées et réelles nulles entre 2012 et 2022

Les barres bleues représentent le pourcentage de BTs avec une heure estimée nulle. De moins en moins de données présentent ce problème. C'est le phénomène inverse pour les BTs avec une heure réelle nulle. Ce qui explique sûrement la stagnation avant 2020. On remarque aussi que beaucoup plus de BTs ont une heure estimée nulle qu'une heure réelle nulle.

La Figure 4.9 présente les équipements les plus affectés par le manque de données. Pour un équipement, la partie bleue de la barre représente la proportion de BTs invalides et la partie orange représente la proportion de BTs valides. Cet aspect ne présente pas de problèmes particuliers.




Figure 4.9 Les équipements avec le plus de BTs invalides à cause d'une estimation nulle (2012-2022)

La Figure 4.10 présente l'évolution du nombre de BTs invalides par mois à cause d'une estimation nulle.




Figure 4.10 Nombre de BTs invalides par mois entre 2012 et 2022 à cause d'une estimation nulle

On ne remarque pas de comportement particulier à part en juillet 2014 et en avril 2020. Ainsi, nous avons un problème d'exhaustivité des données réparti sur toute la base de données.

On résume l'analyse des variables textuelles dans le tableau ci-dessous:

Tableau 4.10 Analyse des variables textuelles

Variable	Problèmes rencontrés	Pertinence
Description	Mélange de français et d'anglais Fautes de frappe Abréviations inconsistantes Autres inconsistances	Possible après travail de nettoyage et de correction
Travail effectué	Cette donnée est remplie après la maintenance (90 % de « Ok fait »)	Non

La description devrait être une des variables les plus discriminantes dans la prédiction des temps de maintenance. Cependant, il est difficile de juger la qualité d'une variable textuelle présentant ces problèmes. On a remarqué que parmi 100 BTs, environ 5 révèlent des fautes de frappes dans leur description. Ces descriptions contiennent en moyenne trois mots dont en moyenne 2.5 mots en français et 0.5 en anglais.

En outre, en examinant les annexes qui peuvent être ajoutés aux BTs, on se rend compte qu'ils peuvent être complétés après la maintenance donc on ne pourra pas en tenir compte pour entraîner un modèle. Concernant les pièces qui peuvent être associées aux BTs, nous ne pouvons pas non plus être certains qu'elles soient renseignées avant la maintenance d'après les planificateurs. Nous vérifions aussi que la colonne « Travail effectué » est aussi remplie après la maintenance comme son nom l'indique

Maintenant que nous avons tous ces éléments de contexte, nous pouvons passer à l'analyse des données. On pourra expliquer certains résultats avec les informations rassemblées précédemment. On rappelle aussi que le but premier de la section suivante est de déterminer quelles variables vont être utiles pour la prédiction

4.1.4 Vérification de la qualité des données et détermination de nouveaux objectifs

Nous allons regrouper les informations vues dans notre analyse précédente selon les dimensions de Anastasova et Yanev (2021) dans le Tableau 4.11.

Tableau 4.11 Indices de qualité pour chaque dimension

Dimensions	Observations
Exhaustivité	• Il manque des variables telles que le niveau d'expertise de l'opérateur et son ancienneté • Les heures réelles et les heures estimées ne sont pas toujours référencées • 75% des BTs ont un temps réel non nul • 33% des BTs ont un temps estimé non nul
Exactitude	• Il n'y a pas de moyen pour être sûr de l'exactitude des informations d'après les planificateurs • Les heures passées sur une maintenance peuvent être rapportées sur une autre maintenance
Validité	• Les temps sont remplis à la main par le mécanicien sur une carte de travail : le mécanicien est simplement encouragé à bien la remplir et il n'y a pas de directive particulière pour la comptabilisation des pauses et des trajets. • Les temps sont intégrés par le superviseur dans la GMAO ce qui crée une deuxième source d'erreur
Cohérence	• Pour les données numériques et catégoriques, il n'y a pas de problème • Pour les données textuelles, il n'y a pas de directive
Consistance	• Nous n'avons pas remarqué de période sans données

On relève trois causes majeures aux problèmes de qualité des données.

On rencontre des problèmes de standardisation dans les descriptions des BTs, ce qui n'aide pas pour comprendre et catégoriser les BTs que ce soit pour l'humain ou pour un modèle de prédiction.

Il manque actuellement des informations cruciales dans les bons de travail pour permettre une prédiction. Notamment l'information indiquant le mécanicien qui fera la maintenance, son niveau d'expertise, etc. De plus, nous n'avons pas d'exactitude sur l'opération de maintenance. L'information contenue dans la description qui nous a été fournie représente l'observation du problème rencontré et non les opérations qui vont être réalisées.

L'étude des processus met en évidence que les mécaniciens ne renseignent pas toujours le nombre exact d'heures passées sur chaque BT.

On peut « localiser » ces trois problèmes dans le cycle de vie d'un bon de travail. On identifie les causes suivantes :

1. À la création du BT, l'utilisateur peut commettre des fautes de frappe et n'a pas de modèle standard à suivre pour chaque problème.
2. L'affectation du mécanicien sur chaque BT est réalisée le jour même, nous ne pouvons donc pas avoir cette information pour prédire le temps de maintenance.
3. Lors de la maintenance, le mécanicien ne note pas toujours combien d'heures consacrées à la tâche.

Grâce à cette analyse sur la qualité des données, on peut clarifier la construction du modèle de prédiction. Pour les problèmes d'exhaustivité, on ne peut pas se passer de l'information du temps réel de maintenance donc il faudra écarter les données incomplètes. Par rapport à l'exactitude des informations, on ne peut pas y faire grand-chose. Pour la cohérence des données textuelles, il n'y a pas de standard donc il faudra traiter ces données comme du texte non structuré. Les remarques sur les autres dimensions ne changent rien à la construction du modèle.

4.2 Préparation des données

Dans cette section, nous faisons surtout une étape de sélection des variables pertinentes. C'est-à-dire que nous allons dégager le comportement de chaque variable pour vérifier si elle est utile pour la prédiction des temps de maintenance et pour vérifier si elle a besoin d'être transformée pour être comprise par un modèle de prédiction.

4.2.1 Sélection des données

Le Tableau 4.12 rassemble les variables inexploitable.

Tableau 4.12 Variables inexploitable

Variable	Raison
Groupe équipement	Cette variable est toujours égale à « S-T »
Type équipement	Cette variable est toujours égale à « MOB »
Statut BT	Cette variable est toujours égale à « 99 »

Tableau 4.12 Variables inexploitable (suite et fin)

Diverses estimations	Cette variable est toujours égale à « 0 »
Composante 1	Le champ est trop peu renseigné
Composante 1 Desc	Le champ est trop peu renseigné
Composante 2	Le champ est trop peu renseigné
Composante 2 Desc	Le champ est trop peu renseigné
Code action 1	Le champ est trop peu renseigné
Code action 1 Desc	Le champ est trop peu renseigné
Code action 2	Le champ est trop peu renseigné
Code action 2 Desc	Le champ est trop peu renseigné
No bon de travail	Aucune incidence sur le temps de maintenance
Parent	Variable redondante avec « Description Condensée »
Catég. Equip.	Variable redondante avec « Description Condensée »
Travail effectué	Rempli après la maintenance
BT ppal	Cette variable est égale à la variable « No bon de travail »
Date création	Aucune incidence sur le temps de maintenance
Date début planifié	Aucune incidence sur le temps de maintenance
Date fin planifiée	Aucune incidence sur le temps de maintenance
Date fin demandée	Aucune incidence sur le temps de maintenance
Date fin réelle	C'est une variable définie après la maintenance
Montant estimé	Cette variable est égale à la variable « Estim. Matière »
MO Réelle	C'est une variable définie après la maintenance
Matières réelles	C'est une variable définie après la maintenance
Montant réel	C'est une variable définie après la maintenance

On retient d'office les variables « N° Unité », « Description Condensée », « Fabr. », « Description » car elles sont évidemment pertinentes pour la prédiction. Il faut donc relever la pertinence des autres variables.

Pour déterminer la pertinence d'une variable catégorique, on vérifie si cette catégorie présente une contribution significative à la variance totale observée dans les données. Pour cela nous procédons à des tests statistiques inspirés de l'ouvrage de Soofastaei (2021). En première étape, l'homogénéité des variances est examinée avec un test de *Levene* (Moore et al., 2021). Dans ce test, les hypothèses testées sont :

$$H_0: \sigma_i^2 = \sigma_j^2 \forall i, j \text{ (Hypothèse nulle)}$$

$$H_a: \sigma_i^2 \neq \sigma_j^2 \exists i \neq j \text{ (Hypothèse nulle rejetée)}$$

En deuxième étape, l'homogénéité des moyennes est testée avec un test ANOVA (Moore et al., 2021). Dans ce test, les hypothèses testées sont :

$$H_0: \mu_i = \mu_j \forall i, j \text{ (Hypothèse nulle)}$$

$$H_a: \mu_i \neq \mu_j \exists i \neq j \text{ (Hypothèse nulle rejetée)}$$

On examine d'abord l'homogénéité des variances, car suivant le résultat, on ne mettra pas en œuvre le deuxième test ANOVA tel quel (Moore et al., 2021).

Lors d'un test statistique, le *p – valeur* est définie comme étant la probabilité associée à la plausibilité du test. Elle s'interprète comme la probabilité d'un résultat au moins aussi extrême que le résultat observé sachant l'hypothèse nulle comme vraie ($p = P(x|H_0)$). Pratiquement, si la *p – valeur* est inférieure au seuil prédéfini (ex. $p < 0,05$), on rejette l'hypothèse nulle H_0 et on conclut dans le cas du test de *Levene* qu'au moins deux variances ne sont pas égales. Dans notre cas, on trouve *p – valeur* ≈ 0 . Il y a donc au moins deux équipes qui n'ont pas la même variance. On peut voir cela sur la Figure 4.11 qui donne la variance des équipes.




Figure 4.11 Variances des heures réelles de maintenance par équipe (avec intervalle de confiance à 95%)

La barre noire correspond à l'intervalle de confiance sur la variance à 95%. Pour des raisons de clarté, nous représentons que les équipes les plus sollicitées, c'est-à-dire ces 7 équipes.

Si les variances des groupes ne sont pas égales, on ne peut pas réaliser un test ANOVA classique. Il faut appliquer une transformation sur les données. Par exemple, l'ANOVA à corrections de *Welch* utilise une méthode de correction pour les degrés de liberté et pour la statistique de Fisher *F* afin de tenir compte des différences de variances (Moore et al., 2021).

Pour un test ANOVA :

- *F – valeur* mesure la variation entre les moyennes des groupes (inter) par rapport à la variation à l'intérieur des groupes (intra). Une *F – valeur* élevée indique une variation significative entre les moyennes des groupes, ce qui suggère qu'au moins un des groupes diffère des autres en termes de moyenne. En revanche, une *F – valeur* faible suggère qu'il n'y a pas de différence significative entre les moyennes des groupes.
- *p – valeur* mesure la probabilité d'obtenir une statistique de Fisher *F – valeur* supérieure à celle observée si l'hypothèse nulle était vraie. Si la *p – valeur* est inférieure à un seuil prédéfini (ex. *p – valeur* < 0,05), on rejette l'hypothèse nulle et conclut qu'il y a des différences significatives entre au moins deux groupes. En revanche, si la *p – valeur* est supérieure au seuil, on ne peut pas rejeter l'hypothèse nulle et on conclut qu'il n'y a pas de différences significatives entre les groupes.

Ici, on obtient $F - valeur = 687.5$ et $p - valeur \approx 0 < 0.05$. Il existe donc au moins deux équipes avec différentes moyennes d'heures réelles. En d'autres mots, on peut avancer que l'équipe semble exercer bel et bien une influence sur la moyenne. On peut aussi le vérifier sur la Figure 4.12 qui donne les moyennes des heures réelles par équipe.




Figure 4.12 Moyennes des heures réelles de maintenance par équipe (avec intervalle de confiance à 95%)

La barre noire correspond à l'intervalle de confiance sur la moyenne à 95%. On observe six sous-ensembles si on regroupe les équipes avec des intervalles de confiance qui se superposent : (15003, 15004)₁ ; (15010)₂ ; (15013)₃ ; (15020)₄ ; (15050)₅ ; (15063)₆.

On peut aussi réaliser le test de *Student* qui vérifie l'égalité des moyennes entre chaque paire d'échantillons à la fois (Moore et al., 2021). Pour ce test, les hypothèses testées sont :

$$H_0: \mu_1 = \mu_2 \text{ (Hypothèse nulle)}$$

$$H_a: \mu_1 \neq \mu_2 \text{ (Hypothèse nulle rejetée)}$$

Comme pour le test ANOVA, il existe une variante pour des échantillons de variances différentes : le test de *Games-Howell* (Moore et al., 2021).

- La valeur de $T - valeur$ mesure la différence entre les moyennes des groupes comparés, ajustée pour la taille de l'échantillon et la variance estimée. Une valeur de $T - valeur$

élevée (en valeur absolue) suggère une plus grande différence entre les moyennes des groupes comparés, tandis qu'une $T - valeur$ faible indique une similarité entre les moyennes. Une valeur $T - valeur$ positive indique que le premier groupe comparé a une moyenne plus élevée que le second groupe, tandis qu'une $T - valeur$ négative indique le contraire.

- La $p - valeur$ est la probabilité associée à la $T - valeur$ observée. Comme pour l'ANOVA, elle mesure la probabilité d'obtenir une $T - valeur$ aussi extrême (ou plus extrême) que celle observée, sachant l'hypothèse nulle ($p = P(x|H_0)$). Si la $p - valeur$ est inférieure au seuil prédéfini ($p < 0,05$), on rejette l'hypothèse nulle et conclut qu'il y a une différence significative entre les moyennes des groupes comparés. En revanche, si la $p - valeur$ est supérieure au seuil, on ne peut pas rejeter l'hypothèse nulle et on conclut qu'il n'y a pas de différence significative entre les moyennes des groupes comparés.

Par exemple, entre l'équipe 15003 et les autres, on retrouve le résultat précédent. On ne peut donc pas différencier l'équipe 15003 de l'équipe 15004, mais on peut la différencier des autres (voir le Tableau 4.13 pour les résultats). Examinons de plus près les variations au sein de chaque équipe (voir Figure 4.13).

Tableau 4.13 Test de Games-Howell sur l'équipe 15003

Equipe1	B	T-value	p-value
15003	15004	2.8	0.07
15003	15010	30	0
15003	15013	18.5	0
15003	15020	-12.5	0
15003	15050	33.4	0
15003	15063	13.3	0




Figure 4.13 Moyennes des heures réelles de maintenance par année et par équipe (2012 – 2022)

La Figure 4.14 montre la moyenne des heures réelles par équipe (au-dessus de chaque graphique) et par année (en abscisses). Sur cette figure on remarque que les équipes 15063 et 15050 ne sont plus utilisées. On peut les retirer des données d'entraînement du modèle de prédiction, si cela augmente les performances de ce dernier. Les autres équipes ont des variations différentes dans le temps, ce dernier point nous conforte dans l'idée que la variable « Équipe » doit être considérée dans un modèle prédictif des temps de maintenance.

Finalement, on vérifie qu'une équipe n'est pas associée à un seul équipement ou type d'équipement, auquel cas l'information de l'équipe pourrait être redondante.




Figure 4.14 Les trois équipements avec le plus de BTs par équipe

Sur la Figure 4.14, on distingue les équipements (chaque couleur représente une machine) avec le plus de BTs par équipe. Toutes ces équipes travaillent sur plusieurs types d'équipements différents.

On mène la même étude sur les autres variables catégoriques. Les résultats sont synthétisés dans le Tableau 4.14 :

Tableau 4.14 Tests statistiques sur les autres variables catégoriques

Variable	<i>p_value</i> (Levene)	H0 Levene	<i>p_value</i> (ANOVA)	H0 ANOVA	Nombre de clusters	Pertinence
T. D.	0	Rejeté	0	Rejeté	2	Oui
Stat. Eq.	0	Rejeté	0	Rejeté	2	Oui
Type BT	0	Rejeté	0	Rejeté	2	Oui
Priorité BT	0	Rejeté	0	Rejeté	3	Oui
Sté	0	Rejeté	0	Rejeté	2	Oui
Centre Coûts	0	Rejeté	0	Rejeté	3	Oui
Magasin	0	Rejeté	0	Rejeté	2	Oui

Ainsi, toutes ces variables catégoriques sont pertinentes pour la prédiction des temps de maintenance.

Pour les variables numériques, on calcule la corrélation (linéaire) de Pearson avec les heures réelles (voir les résultats dans le Tableau 4.15).

Tableau 4.15 Corrélation des variables numériques avec les heures réelles

Variable	Corrélation
Heures estimées	0.74
Estim. Matières	0.43
Montant estimé	0.30

Seule la variable « Heures estimées » est réellement en corrélation. On ne retiendra donc pas de variable numérique pour la prédiction.

Le Tableau 4.16 résume les variables retenues pour la prédiction.

Tableau 4.16 Variables retenues

Variables Catégoriques	Variables Numériques	Variables Textuelles
Équipe	Heures réelles	Description
T. D.		
Stat. Eq.		
No Unité		
Description Condensée		
Fabr.		
Type BT		
Priorité BT		
Sté		
Centre Coûts		
Magasin		

Ce sont ces variables qui vont servir de variables d'entrée dans notre modèle de prédiction. Toutefois, on n'a que très peu d'informations concernant la nature de la maintenance sur les variables catégoriques et numériques ci-dessus donc la majeure partie du travail consiste à réussir à exploiter la variable « Description » (du Tableau 4.16).

De plus, les équipements miniers sont de gros équipements de fabricants parfois différents. Deux BTs avec la même description sur deux équipements différents peuvent donc ne pas être résolus de la même manière donc peuvent ne pas avoir le même temps de maintenance. Pour faciliter et la prédiction et accélérer l'entraînement des modèles en réduisant le nombre de variable et en veillant à avoir un minimum de données d'entraînement, nous allons nous concentrer sur un ou deux équipements en particulier. Les équipements les plus intéressants d'un point de vue objectif industriel sont les équipements qui ont les plus gros volumes horaires de sous-estimation et qui créent le plus de retard dans les plannings de maintenance. Le Tableau 4.17 représente les 5 équipements avec les plus gros volumes horaires de sous-estimation. Pour la construction de ce tableau, il faut retirer les données qui présentent des erreurs, ici ce sont les BTs avec un temps estimé de maintenance nul ou un temps réel nul.

Tableau 4.17 Ecart moyen et somme des écarts des 5 équipements
qui créent le plus de sous-estimation

Description Condensée	Ecart moyen	Somme des Ecart	Nombre de BTs
CHARGEUSE TORO 1400 8 VERGES	-3.517322	-29408.33	8361
CHARGEUSE CAT R2900	-5.184834	-19883.84	3835
BOULONNEUSE	-4.603251	-19117.30	4153
CAMION TORO 50D	-2.734080	-15614.33	5711
BOULONNEUSE MEM946	-3.172771	-14448.80	4554

Les chargeuses TORO 1400 8 Verges, les chargeuses CAT R2900, les boulonneuses, les camions TORO 50D et les boulonneuses MEM946 sont les équipements avec les plus gros volumes horaires de sous-estimation. L'équilibrage des classes est aussi un critère important dans la préparation des données, une classe présente en trop grand nombre peut polluer l'information contenue dans les autres classes.

Nous représentons donc dans la Figure 4.15 une carte de chaleur des 3 BTs les plus récurrents pour les 5 équipements relevés précédemment.




Figure 4.15 Carte de chaleur des 3 BTs les plus récurrents pour les 5 équipements avec le plus de sous-estimation

On remarque que pour les chargeuses TORO 1400 et les camion TORO 50D, il y a beaucoup de BTs « INSPECTION A/C » ce qui crée un fort déséquilibre de classes alors que les autres équipements présentent moins ce problème. Nous allons donc nous concentrer sur les chargeuses CAT R2900 car elles présentent moins de déséquilibre de classes et c'est un modèle qui va être équipé de capteurs pour un suivi télémétrique en direct d'après les planificateurs donc il sera intéressant de comparer nos résultats à des études futures. Dans ce cas, les variables « Description Condensée », « Fabricant » et « Catég. Equip. » (Catégorie équipement) ne nous sont plus utiles. On vérifie bien sur le Tableau 4.17 qu'il y a au moins quelques milliers de BTs pour avoir un minimum de données d'entraînement.

4.2.2 Nettoyage des données

Parmi les 335 730 BTs dont nous disposons, 25% ne sont pas utilisables pour entraîner notre modèle de prédiction, car la variable t_r n'est pas disponible. Il reste donc 253 185 BTs valides, c'est un nombre suffisant quand on compare aux études mentionnées dans la revue de littérature.

Les données aberrantes sont aussi retirées. Pour cela, on retire les 1% des données qui ont le plus grand écart entre les heures estimées et les heures réelles. On retire aussi les 1% des données qui ont le plus grand rapport temps réel de maintenance sur temps estimé de maintenance.

4.2.3 Intégration des données

Comme dit précédemment, il est aussi possible d'avoir accès à une autre variable textuelle « Annexe » dans une base de données connexe, mais après inspection, celle-ci n'est que peu souvent informative (20 % de ces données contiennent plus de cinq mots) et elle est potentiellement remplie après la maintenance. Nous ne retiendrons donc pas la variable « Annexe ». Les pièces utilisées sont aussi parfois renseignées après ou pendant la maintenance donc elles ne sont pas exploitables pour prédire un temps de maintenance. Il n'y a donc pas d'intégration des données à faire.

4.2.4 Construction de nouvelles données et formatage

Comme dit dans le chapitre méthodologie, on s'aide de la librairie *AutoGluon* pour cette sous-étape. C'est la fonction *TabularPredictor* qui nous intéresse le plus car elle permet de construire un modèle de prédiction à partir de données tabulaire (comme dans un tableau *Excel*). D'après la documentation (AutoGluon, 2023), *TabularPredictor* réalise automatiquement la transformation des variables et leur formatage. On explicite dans les paragraphes suivant ce qui va être fait à nos données.

AutoGluon s'aide de la librairie *sklearn* qui regroupe des fonctions de prétraitement des données.

Les variables numériques peuvent théoriquement être traitées comme telles dans la plupart des modèles d'apprentissage automatique. Ici, elles peuvent être normalisées avec *sklearn*, si besoin.

Les variables textuelles sont considérées comme des variables catégoriques avec un très grand nombre de catégories. Les mots vides sont retirés. On extrait ensuite des informations comme le nombre de caractères, le nombre de mots, le nombre de chiffres et le nombre de caractères spéciaux.

Chaque description est transformée en unigrammes, bigrammes et trigrammes. Ce sont des séquences contiguës de mots d’une phrase. Par exemple pour la description « moteur diesel panne », les unigrammes sont « moteur », « diesel » et « panne », les bigrammes sont « moteur diesel » et « diesel panne » et le seul trigramme est « moteur diesel panne ». On transforme ces n-grammes en vecteur numérique pour chaque description. Les vecteurs créés ont autant d’éléments que le nombre de n-grammes uniques et chaque élément du vecteur correspond au nombre d’occurrences du n-gramme dans la description. Avec le même exemple « moteur diesel panne », si le premier élément du vecteur correspondant est pour l’unigramme « moteur », on va retrouver la valeur 1 à cette position. Ensuite, on fait une multiplication élément par élément de ce vecteur avec un autre vecteur qui donne pour chaque n-gramme le logarithme de l’inverse de sa fréquence calculée dans toutes les descriptions $\log\left(\frac{n}{f}\right)$ avec n le nombre de descriptions et f la fréquence du $n - gramme$. C’est la même transformation que la fonction *TfidfTransformer* de *sklearn*. Nous allons aussi extraire d’autres informations des textes : le nombre de mots, le nombre de verbes, le nombre de déterminants et la fraction du texte qui contient des déterminants.

Les variables catégoriques sont converties en variables numériques grâce au « *1-hot encoding* » qui crée une représentation binaire pour chaque catégorie distincte. Ensuite, on la retransforme par plongement, elle devient alors un vecteur de nombres réels à valeurs continues de dimension inférieure. Ce plongement permet de représenter des informations complexes dans un espace vectoriel de dimension réduite, où des relations et des similarités entre les données peuvent être capturées de manière plus efficace.

Enfin, tout cela est concaténé dans un seul vecteur pour chaque entrée de la base de données. Encore une fois, toutes ces opérations sont automatisées par *AutoGluon*.

4.2.5 Séparation des données

Les données de 2012 à 2021 sont utilisées pour l’entraînement. Ensuite, nous considérons les données de l’année 2022 (un peu moins de 10% des données) comme données d’évaluation. Même si cela peut entraîner des biais d’historique, c’est ce qui a été fait sur la majorité des articles revus (Edelman et al., 2017; Jiao et al., 2020; Martinez et al., 2021). Nous ne faisons pas de validation croisée pour le moment pour accélérer le temps d’entraînement des modèles.

Nous avons ainsi relevé tous les éléments importants de la base de données et nous avons identifié quelles variables semblent pertinentes pour un modèle de prédiction. Nous passons maintenant à l'étape de modélisation.

4.3 Modélisation

4.3.1 Génération d'une conception de test

Nous rappelons que nous souhaitons prédire des heures de maintenances par un modèle sans recours à l'estimation des planificateurs. Ces maintenances peuvent prendre jusqu'à quelques dizaines d'heures. Notre problème s'apparente donc à un problème de régression. Dans un premier temps, on essaiera de construire un modèle capable de prédire le temps de maintenance avec les informations avec les variables retenues dans le Tableau 4.16.

Toutefois, on peut réaliser une simplification dans la tâche de prédiction. L'objectif final est de remplacer le travail d'estimation et de l'améliorer mais un second scénario intéressant pour réduire le volume d'heures sous-estimées serait de prédire l'écart des opérations récurrentes. Pour cela, on peut considérer que le temps estimé par l'humain est une variable d'entrée de notre modèle prédictif. On peut aussi espérer que cette variable peut pallier les problèmes de qualité des descriptions ou des autres variables. On peut la voir comme une variable calculée par le planificateur à partir des autres variables, elle contient donc de l'information moins détériorée par les contraintes de la base de données même si elle peut être biaisée par le jugement humain. L'idée, du point de vue de la construction du modèle de prédiction, est de considérer l'estimation des planificateurs comme variable d'entrée. Dans ce cas, au lieu de considérer les heures réelles de maintenance comme variable à prédire, on introduit la variable, plus parlante, $\Delta t \in \mathbb{R} [h]$ qui mesure l'écart entre le temps réel de maintenance et le temps estimé de maintenance pour vérifier la pertinence des variables de la base de données dans ce nouveau cadre :

$$\Delta t \stackrel{\text{def}}{=} t_e - t_r \quad (4.1)$$

La Figure 4.16 présente la moyenne des Δt par année ($\mu_{\Delta t}$) :




Figure 4.16 Moyenne des Écarts en heures par année (2012 – 2022)

On peut constater une sous-estimation ($\Delta t < 0$) globale des temps de maintenance sur toutes les périodes, et qui s'aggrave de 2012 à 2017. Il y a néanmoins une amélioration de l'estimation à partir de 2021. Ainsi, nous menons une nouvelle étape de préparation des données, mais avec l'écart entre le temps de maintenance réel et celui estimé (voir ANNEXE A).

Ainsi, on regroupe les variables retenues pour la prédiction dans le Tableau 4.18 :

Tableau 4.18 Variables retenues pour la prédiction de l'écart

Catégoriques	Numériques	Textuelles
Équipe	Heures estimées (t_e)	Description
T. D.	Heures réelles (t_r)	
No Unité		
Type BT		
Priorité BT		
Sté		
Centre Coûts		
Magasin		

Pour le nettoyage des données, nous excluons en plus les données avec un temps estimé de maintenance nul.

Enfin, une autre approche semble être envisageable si l'objectif consiste seulement à corriger l'estimation des planificateurs. On peut catégoriser les BTs en trois (3) classes : sous-estimés, bien estimés et surestimés. On se retrouve donc avec un problème de classification.

Dans la suite, on définit un BT « bien estimé » si on a un écart en dessous d'une heure :

$$|t_e - t_r| \leq 1h \quad (4.2)$$

Ou, d'une manière adimensionnelle, si l'écart relatif ne dépasse pas 10% pour les maintenances les plus longues.

$$\frac{|t_e - t_r|}{t_r} < 0.1 \quad (4.3)$$

Où t_r est le temps réel et t_e le temps estimé.

Pour ce troisième scénario, l'étape de préparation des données est la même que pour le scénario précédent.

4.3.2 Sélection des techniques de modélisation

La variable textuelle « Description » comporte environ trois mots par entrée, ce qui semble peu pour utiliser des modèles de traitement de langage (réseaux récurrents, *transformers*). À titre de comparaison, dans l'étude de Jiao et al. (2020), les auteurs donnent un exemple de prédiction de leur modèle avec une entrée à huit mots (sans mots vides).

Dans la revue de littérature, nous avons identifié que les modèles les plus performants sont des variantes des arbres de décision (renforcement du gradient, arbres bagués), les réseaux de neurones, les forêts aléatoires. Ces réseaux peuvent s'adapter à des problèmes de régression et de classification.

4.3.3 Création des modèles

Pour construire tous ces modèles, Erickson et al. (2020) proposent une bibliothèque d'apprentissage automatique, *AutoGluon*, conçue pour automatiser le processus d'entraînement et de déploiement de modèles d'apprentissage automatique. La fonction *TabularPredictor* de la bibliothèque permet l'ajustement de modèles d'apprentissage automatique avec un effort minimal de la part de l'utilisateur. *TabularPredictor* peut automatiquement tester plusieurs modèles avec plusieurs hyperparamètres. Les réseaux de neurones, les algorithmes basés sur les arbres de décisions, les forêts aléatoires, vus dans les études de la revue de littérature peuvent être entraînés par cette fonction. Ces algorithmes sont aussi optimisés selon les dernières avancées en apprentissage machine. Nous allons donc exploiter cette fonction pour faciliter la construction des modèles. Il suffit de donner un temps imparti pour entraîner plusieurs modèles sur des données et de les comparer. On peut utiliser tous les modèles entraînés, mais c'est le plus performant qui est utilisé par défaut quand on veut faire une analyse approfondie de ses résultats.

Par défaut, *TabularPredictor* réalise des ensembles d'algorithmes pour obtenir de meilleurs résultats à partir des résultats de chaque algorithme de l'ensemble, nous retirons cette fonctionnalité pour vérifier quel est le meilleur algorithme et pour pouvoir expliciter notre approche. Nous contrainsons aussi la fonction *TabularPredictor* à seulement entraîner les algorithmes définis dans la sous-étape précédente.

4.3.4 Évaluation du modèle

Pour déterminer quel temps d'entraînement est nécessaire, nous mènerons des tests sur 5 heures, 2 heures et 1 heure. Le Tableau 4.19 résume les résultats de la fonction *TabularPredictor* pour les différents temps d'entraînement sur la prédiction des temps de maintenance (scénario 1) des chargeuses CAT R2900.

Tableau 4.19 Résultats de prédiction pour la prédiction du temps de maintenance avec des temps d'entraînement différents

Temps d'entraînement	<i>REQM</i> (heures) du meilleur algorithme
5 heures	9.30
2 heures	9.30
1 heures	9.31

On a défini, pour la suite, le temps imparti de la fonction *TabularPredictor* à une heure, car les résultats ne diffèrent pas avec un entraînement de 5 heures. On vérifie bien que tous les algorithmes définis ont été entraînés avec les trois temps d'entraînement différents.

Pour déterminer quel algorithme était le plus performant, on lance un entraînement sur un sous-ensemble de nos données pour faciliter l'entraînement de tous les algorithmes. On classe les modèles selon la racine de l'erreur quadratique moyenne (*REQM*) pour la prédiction de temps de maintenance car on veut pénaliser les grosses erreurs qui peuvent gâcher tout un planning de maintenance, et selon la précision pour la stratégie de classification.

On obtient alors les résultats suivants (Tableau 4.20, Tableau 4.22 et Tableau 4.21) pour la prédiction du temps de maintenance des chargeuses CAT R2900 :

Tableau 4.20 Résultats des algorithmes pour la prédiction du temps de maintenance

Algorithme	<i>REQM</i> (heures)
<i>Gradient Boosting Decision Tree</i>	9.28
Arbres bagués (<i>Bagged Tree</i>)	9.32
Réseaux de neurones	9.44
Forêts aléatoires	9.72

Tableau 4.21 Résultats des algorithmes pour la prédiction de l'écart entre estimation et temps réel

Algorithme	REQM (heures)
<i>Gradient Boosting Decision Tree</i>	8.36
Arbres bagués (<i>Bagged Tree</i>)	8.50
Réseaux de neurones	8.59
Forêts aléatoires	8.51

Tableau 4.22 Résultats des algorithmes pour la stratégie de classification

Algorithme	Précision
<i>Gradient Boosting Decision Tree</i>	0.60
Arbres bagués (<i>Bagged Tree</i>)	0.60
Réseaux de neurones	0.60
Forêts aléatoires	0.60

On ne remarque pas de différence significative entre les variantes d'arbres de décision, les réseaux de neurones et les forêts aléatoires. Nous pourrions contraindre la fonction *TabularPredictor* à entrainer seulement un algorithme pour de futures construction de modèle mais pour le moment, nous avons tous les résultats nécessaires à l'évaluation et à l'analyse des scénarios.

4.4 Validation

4.4.1 Premier scénario – Prédiction du temps réel

D'abord pour la prédiction avec le premier scénario sur les chargeuses CAT R2900. On a une $REQM$ entre le temps prédit et le temps réel égale à $REQM_{pred} = 9,2 h$ et un coefficient de détermination $r^2 = 0,47$. Si on compare à l'estimation des planificateurs $REQM_{estim} = 9,6 h$, on pourrait ainsi penser que le modèle peut remplacer le travail d'estimation des planificateurs. Analysons de plus près son comportement. On illustre sur la Figure 4.17 un extrait des temps prédit pour l'opération « changement d'huile moteur ».




Figure 4.17 Heures de maintenances prédites pour l'opération "changement d'huile moteur"

À part pour une valeur (#54425), on remarque que les prédictions sont autour de 4 h de maintenance, et qu'en général, il y a là surestimation du temps de maintenance fourni par le modèle. En réalité, la durée moyenne pour ce genre d'opération est autour de 2 h. Le modèle n'a pas réussi à extraire cette information.

On réexamine ensuite 10 maintenances aléatoires dans les données de test. La Figure 4.18 rend compte des prédictions du modèle.




Figure 4.18 Prédiction des temps de maintenance pour 10 opérations

Là aussi, on a une surestimation dans la plupart des cas. Sur les 8 premières opérations, on a l'impression que le modèle prédit un temps moyen de 7 h et qu'il essaye d'ajuster suivant les autres paramètres d'entrée. Globalement, si on continue d'explorer le comportement du modèle, on peut penser qu'il distingue deux groupes : pour les maintenances avec des mots qui reviennent fréquemment on prédit autour de 4 h de maintenance et pour les autres autour de 7 h.

Sur la Figure 4.19, on représente les résidus en fonction des heures prédites, le diagramme quantile-quantile, les heures prédites en fonction des heures réelles et l'histogramme des résidus.




Figure 4.19 Analyse des résidus

Les résidus en fonction des heures prédites sont en éventail, cela signifie que la variance des résidus n'est pas constante. On voit sur le diagramme quantile-quantile que les points dévient de la ligne rouge surtout aux extrémités de la figure. Cela met en évidence la non-normalité des résidus à causes de valeurs aberrantes. Les heures prédites en fonction des heures réelles ne mettent pas de paterne en évidence, les points semblent distribués aléatoirement. L'histogramme révèle quand même une distribution normale centrée autour de -5h des résidus qui révèle un biais du modèle de prédiction, cela peut être une tentative du modèle de corriger artificiellement l'erreur d'estimation.

Finalement, si on compare les prédictions du modèle avec les estimations des planificateurs (dans le cas où elles sont dans les données), un tiers des BTs sont mieux estimés par le modèle alors que deux tiers des BTs sont mieux estimés par les planificateurs. Le modèle construit ne répond donc

pas à nos attentes. On va alors chercher à résoudre un problème plus simple où le modèle doit corriger l'estimation des planificateurs.

4.4.2 Deuxième scénario – Prédiction de l'erreur d'estimation

Pour le deuxième scénario, si on utilise les estimations des planificateurs et qu'on essaye de prédire l'erreur d'estimation sur les chargeuses navettes CAT R2900, on obtient $REQM_{pred} = 8,4 h$ et $REQM_{estim} = 9,5 h$. On constate encore une légère amélioration avec un $r^2 = 0,68$. À titre de comparaison, si on enlève l'estimation des planificateurs comme information, on a $REQM_{pred} = 9,5 h$. Considérant que la moyenne des temps de maintenance est d'environ 5 h, même si l'estimation est meilleure, ce résultat n'est pas satisfaisant.

Sur la Figure 4.20, on représente les résidus en fonction des heures prédites, le diagramme quantile-quantile, les heures prédites en fonction des heures réelles et l'histogramme des résidus.




Figure 4.20 Analyse des résidus

On peut faire les mêmes conclusions qu'avec le modèle précédent, on a une hétéroscédasticité, des valeurs aberrantes et un coefficient de détermination faible.

Sur la Figure 4.21, on peut constater les temps prédits, estimés et réels pour 10 maintenances.




Figure 4.21 Prédiction et estimation des temps de maintenance pour 10 opérations

Pour les BTs « VERIFICATION APRES MAINTENANCE » et « CENTRE TRES LOUSSE », on voit que les heures prédites et les heures estimées se rapprochent alors que les heures réelles sont très loin des prédictions et des estimations. Le modèle semble beaucoup se reposer sur l'estimation des planificateurs pour faire sa prédiction. On peut vérifier cela grâce à une méthode de permutation aléatoire au sein des valeurs d'un variable (Parr et al., 2018), après la permutation il s'agit de réévaluer le modèle et on peut en déduire l'importance de la variable permutée sur les résultats du modèle via la différence entre la nouvelle métrique d'évaluation et cette de base (ici $importance = REQ_{M_{sans\ permutation}} - REQ_{M_{avec\ permutation}}$). Le Tableau 4.23 résume les résultats de ces permutations.

Tableau 4.23 Importance des variables via permutations

Variable	Importance
Heures Estimées	5.50
Description	0.74
Équipe	0.25
Parent	0.10
Priorité BT	0.08
Autres variables	< 0.03

On constate bien que la variables « Heures Estimées » est beaucoup plus importante que les autres pour les prédictions.

Dans un dernier temps, on se restreint aux chargeuses navettes. Dans le Tableau 4.24, on regroupe les résultats de prédiction du temps de maintenance des chargeuses navettes pour tous les types de maintenance.

Tableau 4.24 Résultats de régression - chargeuses navettes

Variables Catégoriques	Variable Texte	REQM (h) (Préd.)	REQM (h) (Estim.)	Delta
Oui	Oui	8.17	9.34	+1.17
Oui	Non	8.54	9.56	+1.02
Non	Oui	8.47	9.6	+1.13
Non	Non	8.69	9.53	+0.84

Les deux premières colonnes représentent l'utilisation de ce type de variables pour la prédiction. On teste ainsi l'influence de chaque type de variables, à part bien sûr l'influence de la seule variable numérique « Heures estimées » qui est essentielle dans ce scénario.

La colonne « **REQM (h) (Préd.)** » donne la racine carrée de l'erreur quadratique moyenne entre le temps prédit et le temps réel.

La colonne « **REQM (h) (Estim.)** » donne la racine carrée de l'erreur quadratique moyenne entre le temps estimé par les planificateurs et le temps réel.

Avec ces résultats on remarque que le modèle n'améliore que très peu l'estimation de l'humain. Sachant que les maintenances durent en moyenne 6 h, ces prédictions ne sont pas satisfaisantes. De plus, les variables catégoriques et textuelles ne jouent pas un grand rôle dans la prédiction, car la REQM ne change pas beaucoup quand on les enlève des paramètres d'entrée. Cela montre que c'est l'estimation que font les planificateurs (seule variable numérique) qui détient la plus grande source d'information sur la durée de la maintenance. D'après le Tableau 4.23, seules deux variables sont vraiment significatives et parmi elles il y a l'estimation des planificateurs. On peut conclure que les données ne contiennent pas assez d'information pour répondre à l'objectif de prédiction des temps de maintenance. Si on se réfère à Soofastaei (2021), on peut identifier un problème d'utilisabilité ou un problème d'exhaustivité selon Anastasova et Yanev (2021). C'est donc la qualité des données qui nous freine dans notre objectif de prédiction.

Par ailleurs, nous n'avons pas tenté de prédiction avec des informations complémentaires issues du logiciel de GMAO telles que les pièces utilisées car cela ne constituait pas une situation de prédiction réaliste comme ces informations ne sont pas disponibles pendant la planification du BT.

4.4.3 Troisième scénario – Classification des BTs

Pour le troisième scénario, nous avons entraîné le modèle sur les chargeuses CAT R2900.

Le Tableau 4.25 présente des calculs des métriques de classification :

$$Précision = \frac{Vrais\ positifs}{Vrais\ positifs + Faux\ positifs} \quad (4.4)$$

La *Précision* est la capacité du modèle à ne pas classer à tort les négatifs comme positifs.

$$Rappel = \frac{Vrais\ positifs}{Vrais\ positifs + Faux\ négatifs} \quad (4.5)$$

Le *Rappel* est la capacité du modèle à prédire tous les réels positifs.

$$F_1 - score = 2 \frac{précision \times rappel}{précision + rappel} \quad (4.6)$$

Le $F_1 - score \in [0,1]$ est la moyenne harmonique de la précision et du rappel, particulièrement utile quand les classes sont déséquilibrées.

$$Exactitude = \frac{\text{Prédictions correctes}}{\text{Support total}} \quad (4.7)$$

C'est la mesure globale de la performance du modèle indépendamment de la classe.

Tableau 4.25 Rapport de classification

	Précision	Rappel	F1-score	Support
Bien estimé	0.69	0.76	0.72	1777
Sous-estimé	0.52	0.33	0.41	1360
Surestimé	0.42	0.61	0.50	631
Exactitude	0.58			3768
Moyenne	0.54	0.57	0.54	3768
Moy. équilibrée	0.58	0.58	0.57	3768

La moyenne équilibrée représente la moyenne pondérée par le support de chaque classe.

Si nous examinons de plus près chaque classe, on constate de meilleurs scores pour la classe « bien estimés », mais de moins bons résultats dans les autres classes. Ces résultats ne permettent pas de proposer un bon modèle d'aide à la décision.

Examinons les résultats sur les BTs de la chargeuse CAT R2900 qui a été la mieux prédite en termes de précision. Le Tableau 4.26 présente les résultats de classification sous forme d'une matrice de confusion.

Tableau 4.26 Matrice de confusion

	Prédiction			
Réel	Total 961	Bien estimé 501	Sous-estimé 222	Surestimé 238
	Bien estimé 453	345	60	48
	Sous-estimé 347	140	116	91
	Surestimé 161	16	46	99

On lit la deuxième colonne de la sorte : « Le modèle a prédit que 501 BTs étaient bien estimés. Parmi ces 501 BTs, 345 sont en effet bien estimés, 140 sont en réalité sous-estimés et 16 surestimés ». On constate qu'aucune classe n'est bien prédite. On a du mal à prédire les sous-estimations. On peut remarquer aussi que parmi les « bien estimés » prédits très peu sont en réalité des « surestimés ». Le modèle reproduit le comportement des planificateurs.

4.4.4 Analyse des résultats

Nous avons défini trois scénarios de prédiction dans le chapitre de méthodologie. Nous avons déterminé que dans chacun des trois scénarios, les modèles de prédiction construits ne sont pas assez performants pour faciliter le travail du planificateur. En effet, nous avons soit des résultats moins bons que les estimations des planificateurs, soit des résultats qui n'améliorent pas les estimations, soit des résultats insatisfaisants. On trouve des REQM supérieures à la moyenne des temps de maintenances dans tous les scénarios de régression, ces modèles sont donc inexploitable.

Ainsi, il peut y avoir plusieurs causes aux manques de performance. Première possibilité, les algorithmes entraînés ne permettent pas de répondre à l'objectif posé. Deuxième possibilité, le travail de traitement des variables est insuffisant. Dernière possibilité, les données ne permettent pas de répondre à l'objectif.

Premièrement, les algorithmes choisis sont, d'après notre revue de littérature, l'état de l'art dans beaucoup de domaines de prédiction dans l'industrie. Si d'autres algorithmes sont meilleurs pour la prédiction de temps de maintenance, ils seraient soit nouveaux par rapport au domaine de prédiction, soit utilisés dans le domaine mais pour d'autres tâches.

Deuxièmement, la méthode CRISP-DM est classique dans le domaine de l'apprentissage machine appliqué à un cas industriel. C'est-à-dire que les étapes d'exploration des données, de sélection des variables, de transformation des variables et d'extraction des variables ont bien été respectées. L'entraînement des modèles a été aussi fait sans fuite de données et avec une validation classique.

Enfin, lors des étapes d'exploration des données et de sélection des variables nous avons pu relever des manquements au niveau de la qualité des données. C'est cette dernière possibilité qui paraît la plus probable. La base de données actuelle ne permet pas de prédire les temps de maintenance.

Nous présenterons ainsi des recommandations pour résoudre les problèmes de qualité des données dans la conclusion de notre travail.

CHAPITRE 5 CONCLUSION

5.1 Conclusion

Notre travail visait à développer un modèle de prédiction des temps de maintenance à partir des bons de travail pour soulager le travail des planificateurs. Dans ces bons de travail, on peut trouver des informations sur l'équipement concerné et sur la maintenance dont la description de celle-ci, ainsi que l'estimation par les planificateurs de sa durée. Notre revue de littérature a montré que peu de travaux sur ce sujet ont été réalisés dans le domaine minier et industriel, mais plusieurs articles ont été publiés dans le domaine de la chirurgie. Plusieurs modèles ont été utilisés comme des variantes d'arbres de décision et les forêts aléatoire dans le cas où il n'y a pas d'information textuelles à traiter. Si le texte était une variable importante pour la description de la maintenance, des modèles plus complexes comme les réseaux de neurones récurrents et les *transformers* pouvaient être construits. Notre travail est ainsi l'un des premiers travaux scientifiques de prédiction de temps de maintenance dans le domaine minier. Dans notre cas, nous avons une description textuelle de la maintenance ou du problème rencontré. Cependant, sa concision ne permettait que de se placer dans le cadre des premiers modèles évoqués. Une analyse préliminaire des données a permis de dégager les variables corrélées au temps de maintenance. Ensuite, nous avons utilisé la librairie *Autogluon* pour entraîner facilement plusieurs modèles en parallèle, parmi ceux-ci on retrouve bien entendu les arbres de décision et les forêts aléatoires. Plusieurs stratégies ont été adoptées : (1) on prédit le temps de maintenance sans l'aide de l'estimation par les planificateurs, (2) on utilise l'estimation des planificateurs, (3) on classe si la maintenance est bien estimée ou mal estimée. Notre travail a révélé que les modèles les plus performants sont les arbres bagués (*Bagged Tree*), les réseaux de neurones et les arbres par renforcement du gradient (*Gradient Boosting Decision Tree*). Les résultats obtenus ont montré que dans les trois scénarios, la prédiction n'est pas assez performante pour qu'elle soit utilisée. Nous avons aussi montré que la qualité des données nuit à la prédiction. Nous proposons donc dans les paragraphes suivants des solutions qui permettent de regrouper plus d'informations dans les bons de travail, de mieux mesurer le temps de maintenance et de mieux catégoriser les maintenances.

5.2 Discussions

Les résultats des modèles n'étant pas satisfaisants dans un cadre classique, nous n'avons pas cherché à tester les performances du modèle dans de nouvelles situations comme l'ajout d'un nouvel équipement ou l'ajout d'un nouveau type de maintenance.

Nous avons déterminé quels modèles étaient les plus performants dans notre cas d'étude mais on ne peut pas être certains que dans de meilleures conditions de qualité des données, ceux-là restent les plus performants. En effet, le Tableau 4.20 et le Tableau 4.22 révèlent que plusieurs modèles ont des métriques très proches, un modèle peut donc l'emporter sur l'autre sur d'autres bases de données. De plus, nous avons mentionné l'utilisation des réseaux récurrents (Jiao et al., 2020) et des bi-encodeurs (Zhong et al., 2023) dans la littérature, ces modèles pourraient être plus performants que ceux entraînés dans notre travail dans le cas où les variables textuelles contiennent assez d'information.

Au vu des variables qui constituent notre base de données seule une seule semble réellement caractériser la nature de la maintenance. Nous avons vu que c'est un texte qui est rempli par le mécanicien ou le planificateur qui porte souvent sur la description du problème rencontré. Cela pose plusieurs problèmes de perte d'information. Déjà, s'il s'agit de la description du problème rencontré, nous ne pouvons pas avoir l'information exacte de la nature de la maintenance qui va suivre car une même défaillance peut parfois être corrigée de plusieurs manières. Il se pose aussi la question de la variabilité due au facteur humain. Une même panne peut être comprise différemment suivant l'expérience de l'auteur du BT, résultant en plusieurs descriptions possibles pour finalement une même maintenance, cela ne pose pas tant de problème dans le cas où nous avons énormément de données mais dans le cas contraire cela nuit aux performances du modèle de prédiction comme il aurait plus de maintenance à « apprendre ». Tous n'ont pas la même implication dans le bon remplissage des BTs, l'amélioration de la planification des maintenances n'a actuellement aucune réelle incidence sur le travail du mécanicien. Sans réelle implication de toutes les personnes impliquées dans la création de la base de données, il peut être difficile d'avoir des données qualitatives (Eskandarzadeh et al., 2023). Enfin, il faut ajouter à cela la marge d'erreur venant de l'homme, allant de simples erreurs de typographie à une mauvaise identification du problème sur l'équipement.

Il n'y a aussi presque aucune information sur le mécanicien qui va effectuer la maintenance, à part son équipe. D'après les planificateurs et nos analyses (une même maintenance peut prendre plusieurs temps différents), l'expérience du mécanicien joue beaucoup sur le temps de maintenance nécessaire.

Nous avons donc regroupé plusieurs recommandations dans la section suivante.

5.3 Recommandations

On en revient aux analyses précédentes et aux dimensions de qualité des données de Anastasova et Yanev (2021) pour former des recommandations qui pourraient améliorer la prédiction de temps de maintenance.

Premièrement pour améliorer l'exhaustivité, il faudrait pouvoir réunir le plus d'information dans les BTs. A savoir, les informations sur le mécanicien, celui qui crée le BT et remplit la description et les caractéristiques de l'équipement. Il suffit de connaître au moment où on désire faire la prédiction (quand les planificateurs créent le plan de maintenance de la prochaine semaine) qui fera la maintenance, mais pour cela, l'affectation des mécaniciens doit se faire pendant la phase de planification afin de savoir qui travaillera la semaine qui suit. Entre autres, elle peut aussi se faire en même temps que la planification automatique par un algorithme de programmation par contraintes. Il n'est pas obligatoire d'avoir le nom de l'opérateur concerné, un code employé suffit si des soucis d'anonymat sont en jeu. Plus précisément, l'accès aux variables suivantes permettrait d'avoir une meilleure prédiction : l'âge de la machine, le niveau d'expérience du mécanicien (années dans la mine et dans une autre mine) ; l'identifiant des personnes concernées ; le nombre de maintenances sur la machine ; le nombre de kilomètres roulés ; le temps d'opération total. Entre autres, Jiao et al. (2020) disposent de descriptions plus détaillées pour la prédiction d'opérations en chirurgie et obtiennent de bons résultats en exploitant ces textes.

Pour les problèmes de cohérence, on peut jouer sur deux approches visant à standardiser les descriptions. La première idée serait de mettre à disposition de la documentation avec les noms des éléments de chaque équipement et les problèmes qui peuvent être associés pour les utilisateurs qui remplissent les bons de travail. Qu'elle soit en papier ou directement dans le logiciel de GMAO (une solution à plus long terme), cela permet de se mettre d'accord sur l'appellation d'un élément

ainsi que sur son orthographe. L'avantage de la deuxième option est que l'utilisateur n'a même pas besoin de taper une description, ce qui évite les fautes de frappe, toutefois elle est plus difficile à mettre en œuvre. La deuxième idée serait de contraindre les mots utilisés dans la description du BT avec des listes déroulantes ou, plus laborieux, contraindre à l'aide d'une sorte de correcteur orthographique qui reconnaît les synonymes lors du remplissage de la description.

Pour les problèmes de validité et d'exactitude, plusieurs idées peuvent être mises en place. Créer des fiches de travail plus adaptées pour les quarts de travail où le mécanicien a plusieurs BTs lui permettrait de mieux gérer son temps et de mieux pointer les heures qu'il passe sur chaque BT. Concevoir un système de pointage de temps à chaque fois que le mécanicien se rend à l'atelier pour changer d'outil permettrait de retrouver l'information du temps de maintenance sans intervention du mécanicien. Un exemple de solution serait d'utiliser des puces utilisant la radio-identification (RFID) sur les outils et les pièces de rechange pour enregistrer automatiquement les sorties et les entrées dans les ateliers. On pourrait ainsi synchroniser ces temps avec les temps de maintenance après coup, cela a aussi des avantages pour suivre les stocks de pièce et pour retrouver les outils manquants. Une solution temporaire, pourrait être de rajouter une variable dans la base de données qui indiquerait si les heures réelles correspondent bien à un seul BT. Le superviseur peut avoir cette information quand il transfère les informations de la carte de travail d'un opérateur dans le système de GMAO et qu'il ferme les BTs. La solution à plus long terme serait d'informatiser complètement les bons de travaux. Par exemple avec des tablettes qui remplacent les cartes de travail, les mécaniciens pourraient alors directement consulter le bon de travail en cours, rajouter des informations sur ce bon dans le système en temps réel, fermer les BTs eux-mêmes (on peut forcer cela en « fermant » le BT dès qu'il en « ouvre » un autre) et avoir une explication plus imagée du problème dans le cas où il y a des photos ou des schémas accrochés au BT. Sur la Figure 5.1, on a représenté le processus semi-automatisé d'ouverture et de fermeture des BTs avec l'utilisation de tablette numériques.




Figure 5.1 Processus d'ouverture et de fermeture de BTs semi-autonome

Le contre-maître donne au mécanicien une tablette au départ de son quart de travail. La tablette est chargée avec le profil du mécanicien, c'est-à-dire les maintenances qu'il est censé réaliser. Quand le mécanicien découvre le premier BT sur sa tablette, on commence à compter le temps qu'il met pour finir sa tâche. Quand il a fini et qu'il prend connaissance du BT suivant, on ferme le BT précédent et on enregistre le temps qu'il a mis. Le tout jusqu'à la fin de son quart de travail, auquel cas le BT actuellement ouvert est mis en pause jusqu'à son ouverture par le prochain mécanicien.

Pour mettre en place ce genre de changement, il faut du temps pour décider quel plan d'amélioration va être suivi, pour former les employés de la mine, pour mettre en place les nouveaux systèmes et pour récolter des données sur une période minimale.

RÉFÉRENCES

- Achouch, M., Dimitrova, M., Ziane, K., Sattarpanah Karganroudi, S., Dhouib, R., Ibrahim, H., & Adda, M. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. *Applied Sciences*, 12(16). <https://doi.org/10.3390/app12168081>
- Anastasova, Y., & Yanev, N. (2021). Models and data quality in information systems applicable in the mining industry. *E3S Web Conf.*, 280. <https://doi.org/10.1051/e3sconf/202128008012>
- Angeles, E., & Kumral, M. (2020). Optimal Inspection and Preventive Maintenance Scheduling of Mining Equipment. *Journal of Failure Analysis and Prevention*, 20(4), 1408-1416. <https://doi.org/10.1007/s11668-020-00949-z>
- Arif, A., & Wang, Z. (2018). *Distribution Network Outage Data Analysis and Repair Time Prediction Using Deep Learning*. 2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS). <https://doi.org/10.1109/pmaps.2018.8440354>
- Augustin, A. (2023). *Modèle d'optimisation de l'ordonnancement des travaux correctifs et de maintenance dans un contexte minier souterrain* [Mémoire de maîtrise, Polytechnique Montréal]. PolyPublie. <https://publications.polymtl.ca/54779/>
- AutoGluon. (01 Janvier 2023). *AutoGluon Tabular - Feature Engineering*. AutoGluon. <https://auto.gluon.ai/0.8.2/tutorials/tabular/tabular-feature-engineering.html>
- Azhari, F., Sennersten, C. C., Lindley, C. A., & Sellers, E. (2023). Deep learning implementations in mining applications: a compact critical review. *Artificial Intelligence Review*, 56(12), 14367-14402. <https://doi.org/10.1007/s10462-023-10500-9>
- Balaraju, J., Govinda Raj, M., & Murthy, C. H. S. N. (2018). Estimation of reliability-based maintenance time intervals of Load-Haul-Dumper in an underground coal mine. *Journal of Mining and Environment*, 9(3), 761-770. <https://doi.org/10.22044/jme.2018.6813.1508>
- Bellehumeur, V., & Marquis, R. (2018). *Transformation numérique et compétences du 21^e siècle pour la prospérité du Québec : exemple de l'industrie minière*. Institut national des mines (Québec). <http://collections.banq.qc.ca/ark:/52327/3500114>
- Brzywczy, E. (2021). An Overview of Data Mining and Process Mining Applications in Underground Mining. *Inżynieria Mineralna*, 1(1). <https://doi.org/10.29227/im-2019-01-52>
- Cambridge University Press & Assessment. (2024). *Cambridge Thesaurus*. <https://dictionary.cambridge.org/thesaurus/>
- César de Sá, N., Baratchi, M., Buitenhuis, V., Cornelissen, P., & van Bodegom, P. M. (2022). AutoML for estimating grass height from ETM+/OLI data from field measurements at a nature reserve. *GIScience & Remote Sensing*, 59(1), 2164-2183. <https://doi.org/10.1080/15481603.2022.2152304>
- Christiansen, B. (2018). *Exploring biggest maintenance challenges in the mining industry*. Limble CMMS. <https://www.mining.com/web/exploring-biggest-maintenance-challenges-mining-industry/>

- Clarivate. (2024). *Web of Science Core Collection*. <https://clarivate.com/products/scientific-and-academic-research/research-discovery-and-workflow-solutions/webofscience-platform/web-of-science-core-collection/>
- Deloitte. (2020). *À l'affût des tendances de 2020 - Les 10 principaux enjeux des sociétés minières pour l'année à venir*. Deloitte. <https://www2.deloitte.com/ca/fr/pages/energy-and-resources/articles/tracking-the-trends-2020.html>
- Edelman, E. R., Van Kuijk, S. M. J., Hamaekers, A. E. W., De Korte, M. J. M., Van Merode, G. G., & Buhre, W. F. F. A. (2017). Improving the Prediction of Total Surgical Procedure Time Using Linear Regression Modeling. *Frontiers in Medicine*, 4, 5. <https://doi.org/10.3389/fmed.2017.00085>
- Erickson, N., Mueller, J., Shirkov, A., Zhang, H., Larroy, P., Li, M., & Smola, A. (2020). AutoGluon-Tabular: Robust and Accurate AutoML for Structured Data. <https://doi.org/10.48550/arXiv.2003.06505>
- Eskandarzadeh, S., Fahimnia, B., & Hoberg, K. (2023). Adherence to standard operating procedures for improving data quality: An empirical analysis in the postal service industry. *Transportation Research Part E: Logistics and Transportation Review*, 176. <https://doi.org/10.1016/j.tre.2023.103178>
- Forti, A., Azzolin, V., Andrews, M., Cerminara, G., Dev, N., Jessop, C., Marinelli, N., Mudholkar, T., Pierini, M., Pol, A., Vlimant, J.-R., Betev, L., Litmaath, M., Smirnova, O., & Hristov, P. (2019). Improving data quality monitoring via a partnership of technologies and resources between the CMS experiment at CERN and industry. *EPJ Web of Conferences*, 214. <https://doi.org/10.1051/epjconf/201921401007>
- Fu, Q., & Easton, J. M. (11-14 Dec. 2017 2017). *Understanding data quality: Ensuring data quality by design in the rail industry*. 2017 IEEE International Conference on Big Data (Big Data) (p. 3792-3799). <https://doi.org/10.1109/BigData.2017.8258380>
- Gackowiec, P., Podobińska-Staniec, M., Brzychczy, E., Kühnbach, C., & Özver, T. (2020). Review of Key Performance Indicators for Process Monitoring in the Mining Industry. *Energies*, 13(19), 5169. <https://doi.org/10.3390/en13195169>
- Goknil, A., Nguyen, P., Sen, S., Politaki, D., Niavis, H., Pedersen, K. J., Suyuthi, A., Anand, A., & Ziegenbein, A. (2023). A Systematic Review of Data Quality in CPS and IoT for Industry 4.0. *ACM Comput. Surv.*, 55(14s). <https://doi.org/10.1145/3593043>
- IBM. (17 août 2021). *IBM SPSS Modeler documentation*. IBM. <https://www.ibm.com/docs/fr/spss-modeler/saas?topic=guide-introduction-crisp-dm>
- Institut national des mines (Québec). (2018). *Mine 4.0 : pour plus d'agilité dans les entreprises minières*. Institut national des mines (Québec). https://inmq.gouv.qc.ca/publication/71/mine_agilite_operations_minieres
- Ismail, S. N., Ramli, A., & Aziz, H. A. (2021). Influencing factors on safety culture in mining industry: A systematic literature review approach. *Resources Policy*, 74, 102250. <https://doi.org/10.1016/j.resourpol.2021.102250>
- Jiao, Y., Sharma, A., Ben Abdallah, A., Maddox, T. M., & Kannampallil, T. (2020). Probabilistic forecasting of surgical case duration using machine learning: model development and

- validation. *Journal of the American Medical Informatics Association*, 27(12), 1885-1893. <https://doi.org/10.1093/jamia/ocaa140>
- Juddoo, S., George, C., Duquenoy, P., & Windridge, D. (2018). Data Governance in the Health Industry: Investigating Data Quality Dimensions within a Big Data Context. *Applied System Innovation*, 1(4), 43. <https://doi.org/10.3390/asi1040043>
- Jung, D., & Choi, Y. (2021). Systematic Review of Machine Learning Applications in Mining: Exploration, Exploitation, and Reclamation. *Minerals*, 11(2), 148. <https://doi.org/10.3390/min11020148>
- Leoni, L., De Carlo, F., Paltrinieri, N., Sgarbossa, F., & Bahootoroody, A. (2021). On risk-based maintenance: A comprehensive review of three approaches to track the impact of consequence modelling for predicting maintenance actions. *Journal of Loss Prevention in the Process Industries*, 72, 104555. <https://doi.org/10.1016/j.jlp.2021.104555>
- Liang, R., Huang, C., Zhang, C., Li, B., Saydam, S., & Canbulat, I. (2023). Exploring the Fusion Potentials of Data Visualization and Data Analytics in the Process of Mining Digitalization. *IEEE Access*, 11, 40608-40628. <https://doi.org/10.1109/access.2023.3267813>
- Martinez, O., Martinez, C., Parra, C. A., Rugeles, S., & Suarez, D. R. (2021). Machine learning for surgical time prediction. *Comput Methods Programs Biomed*, 208, 106220. <https://doi.org/10.1016/j.cmpb.2021.106220>
- Moore, D. S., McCabe, G. P., & Craig, B. A. (2021). *Introduction to the practice of statistics* (10^e éd.). Macmillan Learning.
- Noriega, R., & Pourrahimian, Y. (2022). A systematic review of artificial intelligence and data-driven approaches in strategic open-pit mine planning. *Resources Policy*, 77, 102727. <https://doi.org/10.1016/j.resourpol.2022.102727>
- Odeyar, P., Apel, D. B., Hall, R., Zon, B., & Skrzypkowski, K. (2022). A Review of Reliability and Fault Analysis Methods for Heavy Equipment and Their Components Used in Mining. *Energies*, 15(17), 6263. <https://doi.org/10.3390/en15176263>
- Paladino, L. M., Hughes, A., Perera, A., Topsakal, O., & Akinci, T. C. (2023). Evaluating the Performance of Automated Machine Learning (AutoML) Tools for Heart Disease Diagnosis and Prediction. *Ai*, 4(4), 1036-1058. <https://doi.org/10.3390/ai4040053>
- Pan, Y., & Dagneu, M. (2022). A new approach to estimating oxygen off-gas fraction and dynamic alpha factor in aeration systems using hybrid machine learning and mechanistic models. *Journal of Water Process Engineering*, 48, 102924. <https://doi.org/10.1016/j.jwpe.2022.102924>
- Parr, T., Turgutlu, K., Csiszar, C., & Howard, J. (26 mars 2018). *Beware Default Random Forest Importances*. <https://explained.ai/rf-importance/>
- PwC Canada. (2023). *Un nouveau virage numérique pour les minières*. PwC Canada. <https://www.pwc.com/ca/fr/industries/mining/new-digital-agenda-for-mining-companies.html>
- Qi, C.-c. (2020). Big data management in the mining industry. *International Journal of Minerals, Metallurgy and Materials*, 27(2), 131-139. <https://doi.org/10.1007/s12613-019-1937-z>

- Robatto Simard, S. (2023). *Conception et évaluation d'un outil d'aide à la décision pour la maintenance préventive et prédictive d'équipements miniers mobiles souterrains* [Mémoire de maîtrise, Polytechnique Montréal]. <https://publications.polymtl.ca/53427/>
- Robatto Simard, S., Gamache, M., & Doyon-Poulin, P. (2023). Current Practices for Preventive Maintenance and Expectations for Predictive Maintenance in East-Canadian Mines. *Mining*, 3(1), 26-53. <https://doi.org/10.3390/mining3010002>
- Said, U., & Taghipour, S. (2016). *Modeling failure and maintenance effects of a system subject to multiple preventive maintenance types*. Annual Symposium on Reliability and Maintainability (RAMS), Tucson, AZ, USA. <https://doi.org/10.1109/rams.2016.7448007>
- Sánchez, F., & Hartlieb, P. (2020). Innovation in the Mining Industry: Technological Trends and a Case Study of the Challenges of Disruptive Innovation. *Mining, Metallurgy & Exploration*, 37(5), 1385-1399. <https://doi.org/10.1007/s42461-020-00262-1>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526-534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Shardt, Y. A. W., Yang, X., Brooks, K., & Torgashov, A. (2020). Data Quality Assessment for System Identification in the Age of Big Data and Industry 4.0. *IFAC-PapersOnLine*, 53(2), 104-113. <https://doi.org/10.1016/j.ifacol.2020.12.103>
- Shukla, K., Nefti-Meziani, S., & Davis, S. (2022). A heuristic approach on predictive maintenance techniques: Limitations and scope. *Advances in Mechanical Engineering*, 14(6). <https://doi.org/10.1177/16878132221101009>
- Soofastaei, A. (2021). *Data analytics applied to the mining industry* (1^e éd.). CRC Press. <https://www.taylorfrancis.com/books/9780429433368>
- Taaffe, K., Pearce, B., & Ritchie, G. (2021). Using kernel density estimation to model surgical procedure duration. *International Transactions in Operational Research*, 28(1), 401-418. <https://doi.org/10.1111/itor.12561>
- Tan, K. W., Nguyen, F. N. H. L., Ang, B. Y., Gan, J., & Lam, S. W. (2019). *Data-Driven Surgical Duration Prediction Model for Surgery Scheduling: A Case-Study for a Practice-Feasible Model in a Public Hospital*. 15th IEEE International Conference on Automation Science and Engineering (IEEE CASE), Univ British Columbia, Vancouver, CANADA (p. 275-280). <https://doi.org/10.1109/coase.2019.8843299>
- Tubis, A., Werbińska-Wojciechowska, S., Sliwinski, P., & Zimroz, R. (2022). Fuzzy Risk-Based Maintenance Strategy with Safety Considerations for the Mining Industry. *Sensors*, 22(2), 441. <https://doi.org/10.3390/s22020441>
- Velasquez, N., Anani, A., Munoz-Gama, J., & Pascual, R. (2023). Towards the Application of Process Mining in the Mining Industry—An LHD Maintenance Process Optimization Case Study. *Sustainability*, 15(10), 7974. <https://doi.org/10.3390/su15107974>
- Wang, J. H., Xue, Q., Zhang, C. W. J., Wong, K. K. L., & Liu, Z. H. (2024). Explainable coronary artery disease prediction model based on AutoGluon from AutoML framework. *Frontiers in Cardiovascular Medicine*, 11. <https://doi.org/10.3389/fcvm.2024.1360548>

- Witvoet, K., Saad, S., Vidal, C., Ahmed, R., & Emadi, A. (21-23 June 2023 2023). *Electric Vehicle's Range and State of Charge Estimations using AutoML*. 2023 IEEE Transportation Electrification Conference & Expo (ITEC) (p. 1-6). <https://doi.org/10.1109/ITEC55900.2023.10186953>
- Wu, A., Huang, C.-C., Weaver, M. J., & Urman, R. D. (2016). Use of Historical Surgical Times to Predict Duration of Primary Total Knee Arthroplasty. *The Journal of Arthroplasty*, 31(12), 2768-2772. <https://doi.org/10.1016/j.arth.2016.05.038>
- Wu, A., Rinewalt, D. E., Lekowski, R. W., & Urman, R. D. (2017). Use of Historical Surgical Times to Predict Duration of Primary Aortic Valve Replacement. *Journal of Cardiothoracic and Vascular Anesthesia*, 31(3), 810-815. <https://doi.org/10.1053/j.jvca.2016.11.023>
- Zhong, W., Yao, P. Y., Boppana, S. H., Pacheco, F. V., Alexander, B. S., Simpson, S., & Gabriel, R. A. (2023). Improving case duration accuracy of orthopedic surgery using bidirectional encoder representations from Transformers (BERT) on Radiology Reports. *Journal of Clinical Monitoring and Computing*, 38, 221-228. <https://doi.org/10.1007/s10877-023-01070-w>
- Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., & Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150, 106889. <https://doi.org/10.1016/j.cie.2020.106889>

ANNEXE A ANALYSES COMPLEMENTAIRES

Variables catégoriques

On teste d'abord l'homogénéité des variances des écarts avec le test de *Levene* pour savoir quel test ANOVA on devra mettre en œuvre. On trouve $p \approx 0 < 0.05$ par conséquent, l'hypothèse d'égalité des variances est donc rejetée. Il y a au moins deux équipes qui n'ont pas la même variance. On peut voir cela sur la Figure A..




Figure A.1 Variances des écarts par équipe (avec intervalle de confiance à 95%)

La Figure A.1 montre la variance des heures réelles par équipe. La barre noire correspond à l'intervalle de confiance sur la variance à 95%. Les variances des groupes ne sont pas égales, on utilise encore une fois l'ANOVA à corrections de Welch. Puisque la valeur de $p \approx 0 < 0.05$, il existe donc au moins deux équipes avec des écarts moyens différents. On peut aussi le vérifier sur la Figure A.2.

On constate quatre sous-ensembles : (15003, 15004, 15063) ; (15010, 15013) ; (15020) ; (15050). On peut aussi réaliser le test de Games-Howell deux à deux pour déterminer quelles équipes sont significativement différentes. Par exemple, entre l'équipe 15003 et les autres, on obtient les résultats présentés au Tableau A.1.




Figure A.2 Moyennes des écarts par équipe (avec intervalle de confiance à 95%)

Tableau A.1 Test de Games-Howell sur l'équipe 15003

Equipe1	B	T-value	p-value
15003	15004	2.44	0.18
15003	15010	-3.13	0.03
15003	15013	-0.73	1.00
15003	15020	13.82	0.00
15003	15050	-11.33	0.00
15003	15063	-0.61	1.00

On retrouve presque le résultat précédent. On ne peut donc pas différencier l'équipe 15003 des équipes 15004, 15013 et 15063, mais on peut la différencier de 15010, 15020 et 15050. Examinons de plus près les variations au sein de chaque équipe (voir Figure A.3).




Figure A.3 Écart moyen en heures par année et par équipe (2012 – 2022)

Sans les équipes 15063 et 15050, on constate bien qu'il reste au moins deux (2) sous-ensembles. Toutefois, la conclusion de l'ANOVA demeure la même. Les autres équipes ont des variations différentes dans le temps. Ce dernier point nous conforte dans l'idée que la variable « Équipe » doit être considérée dans un modèle prédictif des temps de maintenance.

On mène la même étude sur les autres variables catégoriques. Les résultats sont synthétisés dans le Tableau A.2.

Tableau A.2 Tests statistiques sur les autres variables catégoriques

Variable	<i>p_value</i> (Levene)	H0 Levene	<i>p_value</i> (ANOVA)	H0 ANOVA	Nombre de clusters	Pertinence
T. D.	0	Rejeté	0	Rejeté	2	Oui
Stat. Eq.	0	Rejeté	0.08	Accepté	1	Non
Type BT	0	Rejeté	0	Rejeté	3	Oui
Priorité BT	0	Rejeté	0	Rejeté	3	Oui
Sté	0	Rejeté	0	Rejeté	2	Oui
Centre Coûts	0	Rejeté	0	Rejeté	3	Oui
Magasin	0	Rejeté	0	Rejeté	2	Oui

Ainsi, seule la variable « Stat. Eq. » n'est pas pertinente par rapport à la prédiction des temps de maintenance.

Variables numériques

Cette fois, la variable t_e est une information essentielle dans la prédiction du temps de maintenance. Elle est retenue d'office. Le Tableau A.3 présente les résultats du calcul de la corrélation (linéaire) de Pearson avec l'écart.

Tableau A.3 Corrélation des variables numériques

Variable	Corrélation
Estim. Matières	0.15
Montant estimé	0.08

Sur les deux variables numériques, aucune n'est corrélée linéairement à l'écart. On ne retiendra donc pas ces variables dans la prédiction.