
Département Génie industrielle

Mémoire de fin d'étude en vue de l'obtention du diplôme

D'INGENIEUR d'État

-Filière-

Génie industrielle

-Spécialité -

Management et ingénierie de la maintenance industrielle

Génie industrielle

- Thème -

Utilisation des Techniques d'Ensemble Learning pour le Pronostic et la Maintenance préventive du Séparateur d'Huile Alfa Laval PX90 dans le Groupe Cévital

Réalisé par :

M. CHIKER Kheireddine

M. NEDJMA Ghiles

Encadré par :

M. REZGUI Wail (ENSTA)

M. REZGI Nafissa (ENSTA)

Soutenu le 02-03/07/2023, Devant le jury composé de :

Mme. BELAYADI Djahida : ENST- Présidente

Mme. SALHI Nedjma : ENST - Examinatrice

Dédicace

“

Nous dédions ce travail À nos chers parents, pour leurs sacrifices, leur amour, leur soutien et leurs prières tout au long de nos études, À nos chers freres soeurs Katia, Adem pour leurs encouragements permanents, et leur soutien moral,

Merci d'être toujours là pour nous, Puisse Dieu vous donne santé, bonheur, courage et surtout réussite.

Merci.

”

- Ghiles & Kheireddine -

Remerciements

Remerciements

En premier lieu, nous souhaitons exprimer nos sincères remerciements à Dieu le tout puissant de nous avoir donné la foi qui nous a guidés jusqu'à la réalisation et l'aboutissement de ce travail.

Nous tenons à adresser nos remerciements les plus distingués à toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce projet :

Nous remercions chaleureusement M. REZGUI Wail, notre promoteur, pour nous avoir fait l'honneur d'assurer l'encadrement de notre travail. Nous lui exprimons notre profonde gratitude pour ses conseils avisés, sa disponibilité et le temps précieux qu'il nous a accordé.

Nous tenons à remercier vivement les membres du jury pour avoir accepté de consacrer leur temps à la lecture, l'évaluation et la jugement de ce manuscrit.

Nous exprimons notre reconnaissance à l'ensemble du personnel de la direction technique de CEVITAL, notamment MEZITI Belkacem, pour nous avoir permis d'effectuer notre stage dans les meilleures conditions. Leur accueil, leur soutien et leur expertise ont grandement contribué à la réussite de notre projet.

Nous voulons exprimer notre profonde gratitude à nos parents et nos amis qui nous ont soutenus tout au long de ce projet. Leur amour, leur encouragement constant et leur soutien indéfectible ont été une source d'inspiration et de motivation inestimable.

Nous remercions également tous nos collègues et collaborateurs qui ont partagé leurs connaissances, échangé des idées et apporté leur aide tout au long de notre parcours académique et professionnel.

Nous tenons à exprimer notre reconnaissance à tous ceux qui ont apporté leur contribution, quelle qu'elle soit, à la réalisation de ce travail. Votre soutien a été inestimable et nous vous en sommes profondément reconnaissants.

Résumé

En raison des conditions opérationnelles et environnementales, le processus de production dans les entreprises est très sensible à la détérioration et aux défaillances. Par conséquent, il est important de définir la bonne stratégie de maintenance pour minimiser les temps d'arrêt dus à des pannes inattendues et ainsi minimiser les coûts de maintenance très élevés.

Plus récemment, la maintenance predictive s'appuie sur les développements dans les domaines de la science des données et de l'intelligence artificielle pour surmonter plusieurs limites de la maintenance traditionnelle.

Le but de ce projet est d'exploiter une quantité considérable de données relatives au comportement d'un séparateur centrifuge Alfa Laval PX90 simulé au sein de la raffinerie du groupe CEVITAL. L'objectif est d'entraîner des modèles capables de prédire l'état de fonctionnement de ce système, afin de détecter, prévoir et localiser les pannes avant leur survenue. Ceci permettra d'établir un plan de maintenance préventive pour l'année suivante

Mots clés : Intelligence artificielle , Maintenance predictive, Apprentissage automatique, Classification, Regression, Ensemble learning , analyse de données , mMaintenance préventive

Abstract

Due to operational and environmental conditions, the production process in companies is highly sensitive to deterioration and failures. Therefore, it is important to define the right maintenance strategy to minimize downtime due to unexpected failures and thus reduce high maintenance costs.

More recently, predictive maintenance relies on developments in the fields of data science and artificial intelligence to overcome several limitations of traditional maintenance approaches.

The aim of this project is to leverage a considerable amount of data regarding the behavior of an Alfa Laval PX90 centrifuge separator simulated within the CEVITAL group refinery. The objective is to train models capable of predicting the operating state of this system in order to detect, forecast, and locate failures before they occur. This will enable the establishment of a preventive maintenance plan for the following year.

Keywords : Artificial Intelligence, Predictive Maintenance, Machine Learning, Classification, Regression.

ملخص

بسبب الظروف التشغيلية والبيئية، يكون عملية الإنتاج في الشركات حساسة جدًا للتدهور والأعطال. لذلك، من المهم تحديد الاستراتيجية الصحيحة للصيانة لتقليل وقت التوقف بسبب الأعطال غير المتوقعة وبالتالي تقليل تكاليف الصيانة المرتفعة جدًا

في الآونة الأخيرة، استخدام الصيانة التنبؤية يعتمد على التطورات في مجالات علم البيانات والذكاء الاصطناعي للتغلب على العديد من القيود التقليدية في الصيانة.

هدف هذا المشروع هو استغلال كمية كبيرة من البيانات المتعلقة بسلوك فاصل الطرد المركزي PX90 Laval Alfa المحاكى داخل مصفاة مجموعة CEVITAL. الهدف هو تدريب نماذج قادرة على التنبؤ بحالة تشغيل هذا النظام، من أجل اكتشاف وتوقع وتحديد مواقع الأعطال قبل حدوثها. وسيتمكن ذلك إنشاء خطة صيانة وقائية للعام القادم.

كلمات مفتاحية :

الذكاء الاصطناعي ، الصيانة التنبؤية ، التعلم الآلي ، التصنيف ، الانحدار.

Table des matières

Dédicace	I
Remerciements	II
Résumé	III
Abstract	IV
V	ملخص
Introduction générale	1
1 Étude de séparation	2
1.1 Introduction	2
1.2 Séparation par centrifugation	2
1.3 Etude de cas : Le séparateur d'huile centrifuge Alfa Laval PX90	3
1.3.1 Introduction	3
1.3.2 Buts de la séparation	3
1.3.3 Conception et fonctionnement du séparateur centrifuge Alfa Laval	4
1.3.4 Etude technologique d'un séparateur Alfa Laval PX 90	5
1.4 Conclusion	8
2 Machine learning pour la surveillance et la E-maintenance prédictive	9
2.1 Introduction	9
2.2 L'intelligence artificielle	9
2.3 Industrie 4.0 et l'intelligence artificielle	9
2.4 Machine learning	10
2.5 Le fonctionnement de la machine learning	10
2.6 Les types d'apprentissages	11
2.6.1 L'apprentissage supervisé	11
2.6.2 Apprentissage non supervisé	12
2.6.3 L'apprentissage semi-supervisé	12
2.6.4 L'apprentissage par renforcement	13
2.7 Machine learning et e-maintenance predictive	13
2.8 Les techniques du Machine Learning pour la e-maintenance prédictive	13
2.8.1 Ensemble learning	13
2.9 Comparaison entre les techniques utilisés	19
2.10 Conclusion	19

3	Implémentation des techniques et résultats	20
3.1	Introduction	20
3.2	Aplication de la methode AMDEC Moyen sur le separateur Alfa Laval PX90	21
3.2.1	La réévaluation de la criticité :	23
3.2.2	Analyse des résultats	23
3.3	Approche intégrée de surveillance, analyse de données et prédictions pour la détection d'états d'alerte	24
3.3.1	Collecte et prétraitement de données	24
3.3.2	Exploration et analyse des données	26
3.3.3	Identification des états d'alerte	35
3.3.4	Classification des états d'alerte à l'aide de modèles d'ensemble learning	46
3.3.5	Prédiction de paramètres pertinents	53
3.4	Elaboration d'un plan de maintenance preventive	55
3.5	Conclusion	57
	Conclusion et perspectives	58
	Bibliographie	60
	Annexes	62
A	Présentation de l'entreprise CEVITAL	63
B	maintenance et la e-maintenance industrielle	68
C	AMDEC du separateur centrifuge PX90	72

Table des figures

1.1	Séparation par centrifugation	2
1.2	Le separateur centrifuge Alfa Laval PX90	3
1.3	Séparateur Alfa Laval PX90 [5]	4
1.4	Schéma du séparateur centrifuge.[5]	5
1.5	Schéma de la partie mécanique du séparateur [5]	7
1.6	Moteur triphasé entraînant le séparateur.	8
2.1	Taxonomie des différentes techniques issues de l'apprentissage automatique [4].	11
2.2	Mécanisme d'agrégation pour le calcul de la prédiction finale pour le BAGGING.	14
2.3	Représentation du modèle de forêt aléatoire pour prédire une défaillance.	15
2.4	Mécanisme d'amplification pour le calcul de la prédiction finale.	16
2.5	Gradient Boosting for ensemble learning.	17
2.6	Illustre le processus itératif de l'algorithme de renforcement de gradient [23].	17
2.7	Illustration de l'algorithme XGBoost pour une précision de prédiction améliorée avec amplification et régularisation des gradients [22].	18
3.1	Fonctions de la bibliothèque pandas pour l'exploration initiale du DataFrame	26
3.2	Distribution des variables numériques	27
3.3	Évolution des paramètres en fonction du temps	28
3.4	Heatmap de corrélation des variables numériques	29
3.5	l'évolution des paramètres pour chaque état en 2022	32
3.6	l'évolution des paramètres en fonction de la date pour chaque état de machine en 2022 avec la fonction scatter	34
3.7	Visualisation des relations entre les paramètres pertinents	35
3.8	Analyse de l'évolution et de la relation de courant avec l'état d'alerte de la machine en 2021 et 2022	37
3.9	Analyse de l'évolution et de la relation de vibration avec l'état d'alerte de la machine en 2021 et 2022	38
3.10	Analyse de l'évolution et de la relation de contre pression avec l'état d'alerte de la machine en 2021 et 2022	38
3.11	Analyse de l'évolution et de la relation de vitesse avec l'état d'alerte de la machine en 2021 et 2022	39
3.12	Graphique en 3D avec des sous-graphiques et des points tracés pour la visualisation des relations des données en Pré-alerte	40
3.13	Graphique en 3D avec des sous-graphiques et des points tracés pour la visualisation des relations des données en Alerte	41

3.14	Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en pré-alerte	42
3.15	Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte	42
3.16	Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte	43
3.17	Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte.	44
3.18	Évolution de l'état d'alerte au fil du temps (Occurrences et Pourcentages) .	46
3.19	Prédictions de létat d'alerte avec Random forest model	47
3.20	Matrice de confusion de prédictions de létat d'alerte avec Random forest model	48
3.21	Prédictions de létat d'alerte avec Gradientboosting model	49
3.22	Matrice de confusion de prédictions de létat d'alerte avec Gradient boosting model	49
3.23	Prédictions de létat d'alerte avec XGboosting model	50
3.24	Matrice de confusion de prédictions de létat d'alerte avec XGboosting model	51
3.25	Comparaison des performances des modèles	52
3.26	Prédection de courant	53
3.27	Prédection de vibration	53
3.28	Prédection de contre pression	54
3.29	Graphique comparatif des métriques d'évaluation pour chaque modèle . . .	54
A.1	Situation géographique [7]	64
A.2	L'organigramme du complexe CEVITAL [7].	65
A.3	Différentes étapes du processus de raffinage [7].	67
C.1	Decomposition fonctionnelle du separateur centrifuge Alfa Laval PX90 . . .	74

Liste des tableaux

1.1	tableau descriptif de chaque piece du separateur	5
1.2	tableau descriptif de chaque piece du separateur	6
1.3	Données techniques du séparateur Alfa Laval PX90	6
1.4	nomination des pieces de la partie mecanique [5]	7
2.1	Comparaison entre les RF,XGboost et AdaBoost.[21	19
3.1	Echelle de criticité	21
3.2	Application de l'AMDEC Moyen machine sur la partie étanchéité	21
3.3	Application de l'AMDEC machine sur la partie transmission de mouvement	22
3.4	Application de l'AMDEC machine sur la partie séparation	22
3.5	Classification des éléments selon leur criticité	23
3.6	Tableau des bibliothèques,classes et fonctions utilisées.	25
3.7	Tableau de corrélations	30
3.8	les paramètres les plus pertinents selon le coefficient de corrélation.	30
3.9	Tableau des intervalle de fonctionnement normal	32
3.10	Tableau de corrélations des paramètres pertinentes	35
3.11	Comparaison des États d'Alerte entre les Années 2019 et 2022	45
3.12	Rapport de classification pour le moodel de random forest	48
3.13	Rapport de classification pour le moedel de gradient boosting forest	50
3.14	Comparaison des États d'Alerte entre les Années 2019 et 2022	51
3.15	Résultats de Comparaison des performances des modèles	52
3.16	Tableau de résultats des métriques d'évaluation par modèle et combinaison de variables	55
3.17	Tableau recapitulatif des interventions	56
C.1	Critère de fréquence	74
C.2	Critère de fréquence	75
C.3	Critère de fréquence	75
C.4	Critère de fréquence	75
C.5	Barème de cotation des critères fréquence, gravité et non détection	76
C.6	Echelle de criticité	76
C.7	Application de l'AMDEC machine sur la partie étanchéité	77
C.8	Application de l'AMDEC machine sur la partie transmission de mouvement	77
C.9	Application de l'AMDEC machine sur la partie séparation	78
C.10	Classification des éléments selon leur criticité	79

Liste des abreviations

AI	<i>Intelligence artificielle</i>
ML	<i>Machine Learning</i>
PdM	<i>Maintenance Predictive</i>
RF	<i>Random Forest</i>
DT	<i>Decison tree</i>
AdaBoost	<i>Adaptive Boosting</i>
GBoost	<i>Gradient Boosting</i>
XGBoost	<i>Extreme Gradient Boosting</i>

Introduction générale

La surveillance des processus industriels est complexe, nécessitant des informations internes abondantes. À l'origine, la surveillance visait principalement à protéger les machines en déclenchant des arrêts automatiques ou en générant des alarmes avant que des dégradations graves ne se produisent. Grâce aux avancées technologiques actuelles, les performances se sont améliorées à travers divers dispositifs, contribuant ainsi à l'évolution des systèmes de surveillance. Les communautés de recherche ont développé différentes approches pour détecter les défaillances et diagnostiquer les défauts.

La complexité croissante des systèmes industriels, caractérisés par des exigences accrues en termes de fiabilité, de performances, de sécurité et de disponibilité, a suscité un intérêt croissant pour la supervision. Cette dernière consiste à surveiller et à gérer l'exécution d'une opération ou d'un travail effectué par l'homme ou par une machine, en proposant des actions correctives en cas de besoin. La maintenance prédictive, qui permet aux clients d'optimiser l'utilisation de leurs machines en détectant les anomalies avant qu'elles ne deviennent graves, ainsi qu'aux industries d'anticiper les pannes et d'estimer les coûts de maintenance, est utilisée dans ce contexte.

De nombreux chercheurs se sont penchés sur le problème de la maintenance prédictive, proposant différentes solutions et approches. L'intelligence artificielle, en particulier l'apprentissage automatique, a révolutionné la prévision en général, et la maintenance en particulier. Certains algorithmes d'apprentissage sont capables de prévisions de haute précision à long terme, en inférant des modèles prédictifs à partir de l'exploitation de l'historique des données collectées.

L'objectif de ce mémoire est d'implémenter la méthode AMDEC et des techniques d'apprentissage automatique avancées, plus spécifiquement des méthodes d'ensemble learning, pour la surveillance et la maintenance prédictive des défauts affectant un séparateur centrifuge de type PX90. Les résultats de cette implémentation seront utilisés pour proposer un plan de maintenance prédictive. Ce mémoire est organisé en trois chapitres :

Le premier chapitre porte sur l'étude de l'existant, avec une introduction générale sur la séparation solide-liquide, suivie d'une étude de cas sur le séparateur d'huile centrifuge Alfa Laval PX90 (principes et mode de fonctionnement). Le deuxième chapitre présente les notions générales sur l'intelligence artificielle, le machine learning et la e-maintenance. ET le troisième chapitre décrit l'application de la méthode AMDEC sur le séparateur Alfa Laval PX90 et les algorithmes de machine learning. Ensuite, une comparaison des différentes techniques de machine learning utilisées est réalisée, suivie de la mise en place d'un plan de maintenance préventive. En outre, ce mémoire comprend une introduction générale, une conclusion générale et des références bibliographiques.

Chapitre 1

Étude de séparation

1.1 Introduction

Ce chapitre est consacré à l'étude de cas du séparateur Alfa Laval PX90 l. D'abord une définition générale de la séparation et son but dans l'industrie, que ce soit la séparation par gravité ou bien par centrifugation, ensuite, en se focalisant sur la conception, le fonctionnement, l'objectif, et une étude technologique du séparateur Alfa Laval Px90. Nous finissons ce chapitre par une étude de cas sur le séparateur d'huile centrifuge Alfa Laval PX90 et son mode de fonctionnement. Ceci nous servira à mieux entamer notre projet.

1.2 Séparation par centrifugation

Dans un bol qui tourne à grande vitesse, la gravité est remplacée par la force centrifuge, qui peut être des milliers de fois supérieure. Les processus de séparation et de sédimentation s'effectuent très rapidement et en continu, comme le montre la figure 1.1 .

La force centrifuge présente dans le bol du séparateur accomplit en quelques secondes ce qui prend plusieurs heures lorsque l'on utilise un réservoir soumis à la gravité.

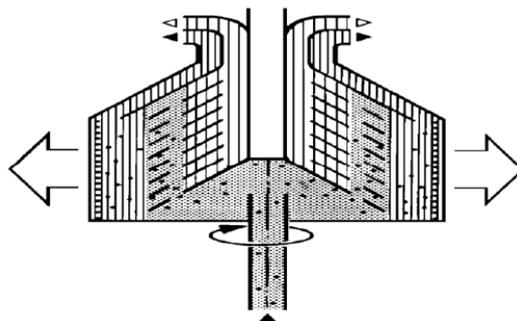


FIG. 1.1 : Séparation par centrifugation

1.3 Etude de cas : Le séparateur d'huile centrifuge Alfa Laval PX90

1.3.1 Introduction

La séparation liquide-solide est une opération largement utilisée dans divers secteurs industriels. Elle est considérée comme une étape essentielle et indispensable de la production en raison de son rôle crucial. Notre étude se concentre spécifiquement sur la séparation d'huile, qui représente un élément clé de cette opération.

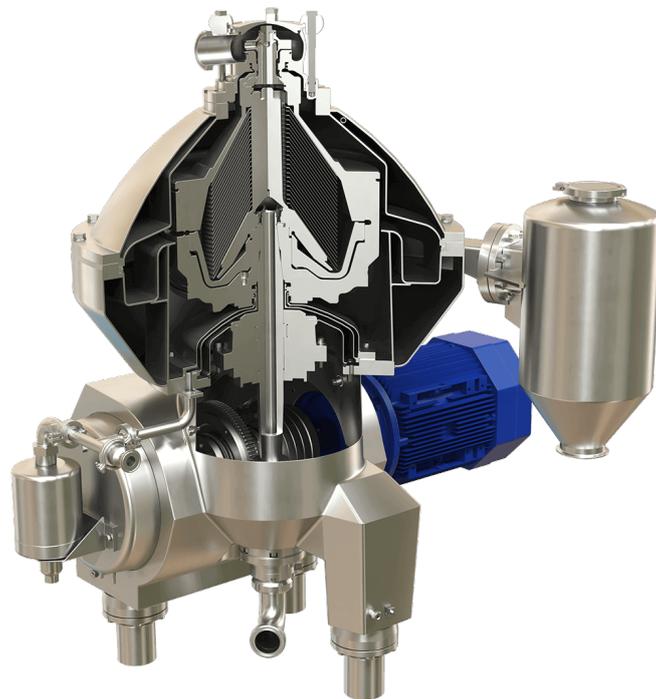


FIG. 1.2 : Le separateur centrifuge Alfa Laval PX90

1.3.2 Buts de la séparation

La séparation peut être réalisée dans le but suivant :

- Extraire les particules solides d'un liquide.
- Séparer deux liquides non solubles entre eux et ayant des densités différentes, tout en extrayant simultanément les particules solides présentes dans ces liquides.
- Séparer et concentrer les particules solides présentes dans un liquide.

1.3.3 Conception et fonctionnement du séparateur centrifuge Alfa Laval

Alfa Laval est une entreprise suédoise spécialisée dans les domaines de l'échange thermique, de la séparation et du transfert de fluides.

Le séparateur Alfa Laval PX 90 se compose de deux parties distinctes, à savoir la partie traitement et la partie commande. Un moteur électrique (9) assure l'entraînement, fixé avec des ergots sur le bâti comme illustré dans la figure 1.3 .

La partie inférieure du séparateur comprend différents éléments : le dispositif de commande horizontal (5), l'arbre moteur avec un accouplement flexible (8), une transmission à vis sans fin (6) et un dispositif de commande vertical (3). L'arbre du bol, relié à l'entrée de liquide (201), est creux.

Une baignoire d'huile est présente dans la partie inférieure pour assurer la lubrification des engrenages.

La partie supérieure du séparateur comprend les composants responsables du traitement, à savoir le bol (2) et le dispositif de sortie équipé du système Centrizoom (1).

Dans le bol du séparateur, le liquide est séparé en deux phases : une phase légère et une phase lourde. Les sédiments les plus lourds sont également séparés du liquide. Le bol, fixé sur la partie supérieure de l'arbre vertical, tourne à grande vitesse.

Il est équipé d'un mécanisme de chasse permettant l'évacuation des sédiments du bol.

Le module d'eau de manœuvre OWMC (4) contrôle l'évacuation des boues du séparateur. Ce module OWMC permet de régler les volumes de chasse.

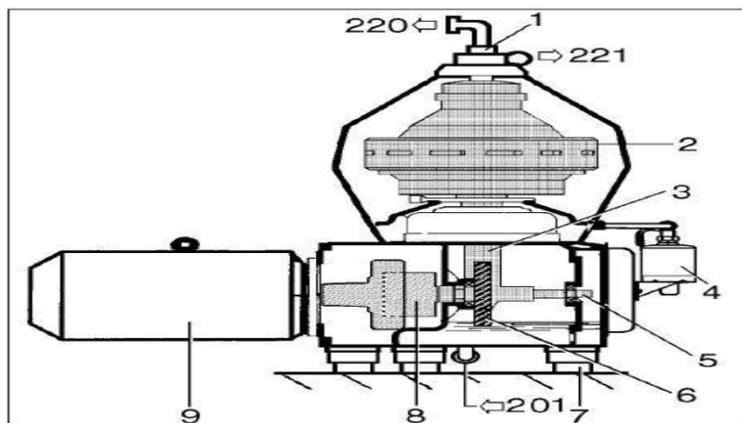


FIG. 1.3 : Séparateur Alfa Laval PX90 [5]

Sur le schéma, les points d'entrée du liquide à séparer et les points de sortie du liquide séparé sont clairement indiqués avec leurs numéros de raccord (201, 220, 221). Le séparateur est également équipé de raccords permettant l'alimentation en liquide de manœuvre, en liquide de rinçage et en liquide de refroidissement/chauffage.

1. Dispositif de sortie avec système Centrizoom	7. Pieds de fondation
2. Bol	8. Accouplement flexible
3. Dispositif d'entraînement vertical et arbre du bol	9. Moteur électrique
4. Module d'eau de manœuvre (OWMC)	201. Entrée de liquide à traiter
5. Dispositif d'entraînement horizontal	220. Sortie de phase légère du liquide
6. Engrenage	221. Sortie de phase lourde séparée

TAB. 1.1 : tableau descriptif de chaque pièce du séparateur

1.3.4 Etude technologique d'un séparateur Alfa Laval PX 90

Présentation du schéma du séparateur centrifuge sur la figure 1.4:

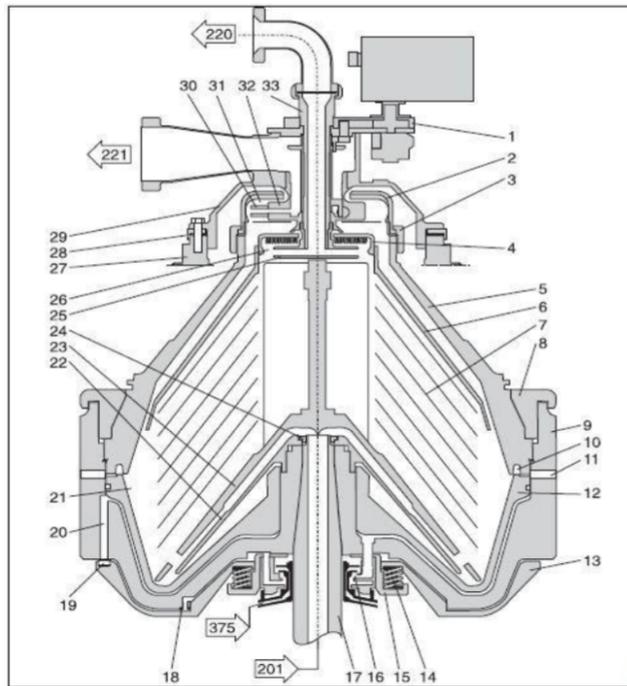


FIG. 1.4 : Schéma du séparateur centrifuge. [5]

Chapitre 1. Étude de séparation

1. Système de réglage (Centrizoom)	20. Canal de vidange
2. Couvercle supérieure de la chambre d'évacuation	21. Chambre à boues
3. Petit anneau de serrage	22. Cône de distribution
4. Couvercle inférieure de la chambre d'évacuation	23. Distributeur
5. Chapeau du bol	24. Ecrou borgne
6. Disque supérieur	25. Turbine centripète pour sortie de phase légère du liquide
7. Jeu de disques	26. Turbine centripète pour phase légère du liquide
8. Grand anneau de serrage	27. Capot du bâti
9. Corps du bol	28. Bague(s) de réglage de la hauteur
10. Anneau d'étanchéité du chapeau du bol	29. Boîtier de sortie
11. Orifice de sortie des boues	30. Tube d'évacuation réglable pour sortie de phase lourde du liquide (Centrizoom)
12. Fond mobile du bol	31. Chambre d'évacuation par turbinage pour phase lourde du liquide
13. Plateau coulissant	32. Support du tube de distribution
14. Ressort	33. Tuyau de sortie
15. Support des ressorts	201. Entrée de liquide non séparé
16. Turbine centripète de manoeuvre	220. Sortie de la phase légère du liquide séparé
17. Arbre du bol (creux)	221. Sortie de phase lourde du liquide séparé
18. Embouchure	375. Entrée de liquide de chasse et d'appoint
19. Clapet	

TAB. 1.2 : tableau descriptif de chaque pièce du séparateur

Données techniques du séparateur Alfa Laval PX90 :

Vitesse maximale autorisée	4800 tr/min +/- 200 tr/min
Fréquence électrique	60,7 Hz
Vitesse de l'arbre moteur	1830 tr/min
Capacité hydraulique	75 m³/h
Température d'alimentation min/max	0 / 100 °C
Puissance du moteur	50 /60 Hz, 37/42 KW
Volume du bol	66 litres
Diamètre interne max. du bol	644 mm
Niveau de vibration max.	7-9 mm/s
Poids du séparateur (sans moteur)	2250 Kg

TAB. 1.3 : Données techniques du séparateur Alfa Laval PX90

a) Principe de fonctionnement du séparateur

Les séparateurs centrifuges sont utilisés pour séparer les mélanges liquides ou éliminer les matières solides des liquides ou des mélanges liquides. À l'intérieur du bol, d'importantes forces centrifuges se forment, permettant une séparation rapide des mélanges

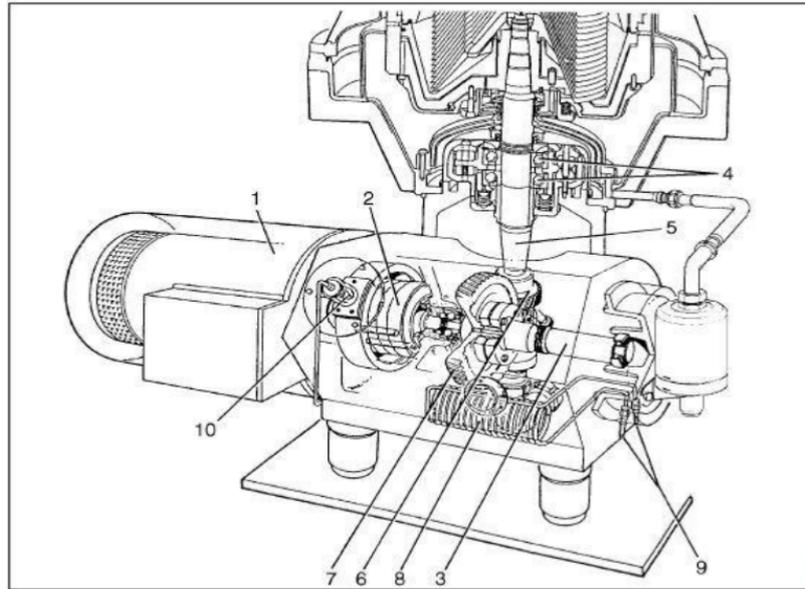


FIG. 1.5 : Schéma de la partie mécanique du séparateur [5]

liquides ou l'élimination des particules solides. Les composants à haute densité se déplacent vers la périphérie du bol, tandis que les composants à faible densité se dirigent vers son centre. Les régimes de rotation très élevés du bol permettent de générer ces forces centrifuges considérables.

b) Partie mécanique

1. Moteur électrique	6. Vis sans fin
2. Accouplement	7. Roue hélicoïdale
3. Arbre de la roue hélicoïdale	8. Serpentine de refroidissement
4. Roulement supérieur	9. Entrée et sortie d'eau de refroidissement
5. Arbre du bol	10. Frein

TAB. 1.4 : nomination des pièces de la partie mécanique [5]

Le bol fonctionne à une vitesse démultipliée par rapport à celle du moteur grâce à l'engrenage.

Afin de déterminer le rapport approprié, il est important de prendre connaissance de ce dernier.

Pour minimiser l'usure des roulements et la transmission des vibrations du bol vers le bâti et le système d'encrage, le roulement supérieur (4) de l'arbre du bol (5) est monté sur un siège équipé d'un amortisseur en caoutchouc. La roue hélicoïdale est immergée dans un bain d'huile lubrifiante.

Les roulements de l'arbre et de la roue hélicoïdale (3) sont lubrifiés par un brouillard d'huile qui se diffuse lors de la rotation de la roue hélicoïdale. Le carter d'engrenage contenant le bain d'huile est refroidi par un serpentin.

c) Partie électrique

La photo présentée dans la Figure 1.6 illustre le moteur triphasé en train de propulser le séparateur. Le moteur triphasé entraîne directement le séparateur, nécessitant ainsi une



FIG. 1.6 : Moteur triphasé entraînant le séparateur.

capacité à supporter de longues périodes de démarrage.

Pour cette raison, le séparateur est équipé d'un moteur à fréquence contrôlée.

Ce type de moteur est similaire à un moteur triphasé standard, mais sa longue période de démarrage est réglée par un convertisseur de fréquence.

c) Bol du séparateur

Le bol du séparateur et le mécanisme de chasse des sédiments sont construits conformément aux éléments suivants : Le corps du bol (9) et le chapeau du bol (5) sont fixés ensemble à l'aide du grand anneau de serrage (8). À l'intérieur du bol, on trouve le cône de distribution (22), le distributeur (23) et le jeu de disques (7). Le jeu de disques est maintenu sous pression par le chapeau. Le fond mobile du bol (12) forme une partie distincte à l'intérieur du bol. La partie supérieure du bol est protégée par le couvercle de la chambre d'évacuation supérieure (2), qui est maintenu en place sur le chapeau du bol grâce au petit anneau de serrage (3). La chambre à boues (21) désigne l'espace situé entre le fond mobile et le chapeau du bol, autour de la périphérie du bol. Cet espace est hermétiquement fermé par le fond mobile du bol, qui repose sur un anneau d'étanchéité (10) dans le chapeau du bol, assurant ainsi une fermeture étanche.

1.4 Conclusion

Dans ce chapitre, nous avons présenté le principe de fonctionnement du séparateur Alfa Laval PX90, et ces différents équipements et le mode de fonctionnement de chacun de ces derniers. Cette étude nous a permis de faire une bonne maintenance prédictive (PdM) des équipements du séparateur.

Chapitre 2

Machine learning pour la surveillance et la E-maintenance prédictive

2.1 Introduction

Au sein des usines automatisées, la prévention des pannes et dysfonctionnements sont primordiales pour éviter des coûts importants liés à l'arrêt de la production [7], [12]. Les techniques d'intelligence artificielle (IA) appliquées à la surveillance des équipements industriels permettent de détecter des phénomènes connus et nouveaux [12]. Dans ce chapitre, nous présenterons les concepts de l'intelligence artificielle et du machine learning, ainsi que leur impact dans l'industrie 4.0. Nous aborderons ensuite les techniques d'apprentissage automatique les plus importantes pour la maintenance prédictive. En conclusion, nous effectuerons une analyse comparative des techniques utilisées, à savoir XGBoost, GBoost et Random Forest.

2.2 L'intelligence artificielle

L'intelligence artificielle (IA) est définie comme la capacité d'une unité fonctionnelle à réaliser des tâches associées à l'intelligence humaine, selon la norme ISO 2382-28.. Ses domaines d'application sont nombreux, notamment dans les transports (gestion du trafic) et l'industrie (maintenance prédictive). L'IA représente une opportunité de transformation majeure, offrant des avantages significatifs pour les entreprises et la société dans son ensemble [10],[11].

2.3 Industrie 4.0 et l'intelligence artificielle

Dans le cadre de l'industrie 4.0, l'intelligence artificielle joue un rôle révolutionnaire. Elle transforme les chaînes d'approvisionnement, optimise la production et assure une maintenance préventive et prévisionnelle efficace[8],[12]. L'intégration de l'IA dans l'indus-

trie 4.0 permet de repousser les limites et d'explorer de nouvelles perspectives d'efficacité et d'innovation.

2.4 Machine learning

Le machine learning est une branche de l'intelligence artificielle qui permet aux ordinateurs d'apprendre à partir des données et d'améliorer leurs performances sans être explicitement programmés. Les algorithmes de machine learning analysent les données, identifient des modèles et des relations, et utilisent ces informations pour prendre des décisions ou faire des prédictions. En somme, c'est une approche qui permet aux machines d'apprendre de manière autonome et d'effectuer des tâches spécifiques en se basant sur l'expérience acquise à partir des données.[8],[10],[11].

2.5 Le fonctionnement de la machine learning

En général, un Data Scientist est responsable de la gestion et de la supervision de ce processus.

- Etape 01:

La première étape implique la sélection et la préparation d'un ensemble de données d'entraînement. Ces données seront utilisées pour nourrir le modèle d'apprentissage afin qu'il puisse résoudre le problème spécifique pour lequel il est conçu.

Les données peuvent être étiquetées pour indiquer au modèle les caractéristiques qu'il doit reconnaître, ou elles peuvent ne pas être étiquetées, ce qui demande au modèle de découvrir et d'extraire par lui-même des caractéristiques récurrentes.

Dans les deux cas, il est essentiel de préparer, organiser et nettoyer soigneusement les données. Sinon, l'apprentissage du modèle de Machine Learning peut être biaisé, ce qui aura un impact direct sur ses prévisions futures [8], [11].

- Etape 02 :

La deuxième étape consiste à choisir un algorithme à appliquer sur l'ensemble de données d'entraînement. Le choix de l'algorithme dépend du type et de la quantité de données d'entraînement ainsi que du type de problème à résoudre [10].

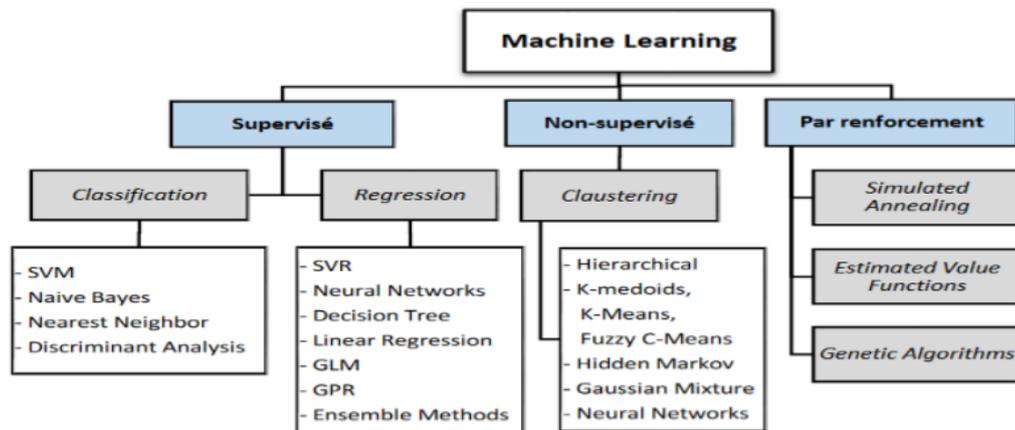
- Etape 03: La troisième étape consiste à entraîner l'algorithme. Il s'agit d'un processus itératif où les variables sont parcourues par l'algorithme et les résultats sont comparés à ceux attendus. Les poids et les biais peuvent alors être ajustés pour améliorer la précision des résultats. On répète ce processus jusqu'à ce que l'algorithme produise le résultat correct la plupart du temps. Une fois l'algorithme correctement entraîné, il devient le modèle de Machine Learning.

- Etape 04:

La quatrième et dernière étape concerne l'utilisation et l'amélioration du modèle. On utilise le modèle sur de nouvelles données, spécifiques au problème à résoudre [8], [9], [11].

2.6 Les types d'apprentissages

Différentes méthodes d'apprentissage automatique existent, que ce soit pour la régression, la classification ou le clustering comme illustré dans la figure 2.1 :



l:

FIG. 2.1 : Taxonomie des différentes techniques issues de l'apprentissage automatique [4].

2.6.1 L'apprentissage supervisé

Il s'agit d'une méthode d'apprentissage supervisée qui utilise un ensemble de classes d'apprentissage connues pour ajuster un modèle statistique, qui sera utilisé ultérieurement pour le déploiement.

Contrairement aux méthodes non supervisées, où les classes ne sont pas connues (non étiquetées), l'objectif est de déterminer à quel groupe l'individu a le plus de chances d'appartenir [18].

Le processus se déroule en deux phases. Dans la première phase (appelée phase d'apprentissage hors ligne), un expert étiquette des exemples pour déterminer un modèle à partir des données étiquetées. Dans la seconde phase (appelée phase de test en ligne), l'étiquette d'une nouvelle donnée est prédite en utilisant le modèle préalablement appris [9],[10],[18] .

a) Classification

Les algorithmes de classification sont utilisés lorsque la variable à prédire (Y) est discrète (qualitative). Les modèles de classification peuvent prédire des valeurs continues, telles que les probabilités d'appartenance à chaque classe de sortie. Pour convertir une

probabilité prédite en une valeur de classe, on sélectionne l'étiquette de la classe présentant la probabilité la plus élevée [18].

b) Régression

Les algorithmes de régression sont utilisés lorsque la variable à prédire (Y) est continue (quantitative), comme dans le cas de la prédiction du prix d'une voiture. Un problème de régression consiste à prédire une quantité. Les variables d'entrée peuvent être à valeurs réelles ou discrètes [9],[11],[19].

2.6.2 Apprentissage non supervisé

L'objectif de l'apprentissage non supervisé est de caractériser la distribution des données et les relations entre les variables, sans faire de distinction entre les variables observées et les variables à prédire. Dans cette tâche, la machine est chargée de catégoriser les données par elle-même.

Pour ce faire, le système croise les informations qui lui sont fournies afin de regrouper dans une même classe les éléments présentant des similitudes. Ensuite, il revient à l'opérateur ou au chercheur d'analyser ces regroupements pour en déduire différentes hypothèses. L'algorithme doit découvrir de manière autonome la structure des données.[9].[18].

L'apprentissage non supervisé vise à regrouper (classifier) les individus qui se ressemblent le plus et qui ont des caractéristiques similaires. Ce regroupement peut servir à différents objectifs, tels que séparer des individus appartenant à des sous-populations distinctes, décrire les données en réduisant le nombre d'individus, simplifier et exposer les résultats [8],[11].

2.6.3 L'apprentissage semi-supervisé

L'apprentissage semi-supervisé est une classe de techniques d'apprentissage automatique qui utilise à la fois des données étiquetées et des données non-étiquetées. Il se situe entre l'apprentissage supervisé, qui ne se base que sur des données étiquetées, et l'apprentissage non-supervisé, qui ne nécessite que des données non-étiquetées. L'objectif de l'apprentissage semi-supervisé est de mettre en évidence la distribution sous-jacente des exemples dans leur espace de description [8],[11].

Cette approche est utilisée lorsque des données (ou des étiquettes) manquent. Le modèle doit utiliser des exemples non-étiquetés pour fournir des informations utiles. Il est souvent associé au concept d'apprentissage transductif. L'apprentissage semi-supervisé est réalisé sur les données de la base d'apprentissage dans le but de faire des prédictions uniquement sur les observations de la base de test [17].

L'objectif n'est donc pas de déterminer la fonction qui minimise l'erreur de généralisation en général, mais plutôt celle qui minimise l'erreur moyenne sur la base de test. L'apprentissage semi-supervisé est particulièrement utile dans les problèmes où il y a relativement peu de données étiquetées et une grande quantité de données non-étiquetées.

Cette situation se produit souvent lorsque l'étiquetage des données est coûteux, comme dans le cas de la classification des pages web [8],[10],17]

2.6.4 L'apprentissage par renforcement

L'apprentissage par renforcement se distingue considérablement des types d'apprentissage précédemment abordés. Il consiste à apprendre, par le biais d'expériences successives, la meilleure manière d'agir afin de trouver la solution optimale. Dans ce type d'apprentissage, les données d'entraînement sont directement issues de l'environnement. Selon ses performances, l'agent est récompensé ou pénalisé pour l'encourager à continuer dans une direction ou à changer d'approche. Cette technique est largement utilisée pour permettre aux systèmes d'intelligence artificielle de dépasser les capacités humaines dans des jeux et autres domaines [8],[17].

L'apprentissage par renforcement trouve des applications dans l'enseignement d'un robot à marcher ou d'un programme à jouer [10].

2.7 Machine learning et e-maintenance predictive

Le machine learning joue un rôle clé dans la e-maintenance prédictive en permettant l'analyse et la prédiction des défaillances des équipements. En utilisant des algorithmes d'apprentissage supervisé, il est possible de développer des modèles capables d'apprendre à partir des données historiques et de détecter les signes avant-coureurs de pannes ou de dégradations. Ces modèles peuvent être utilisés pour prédire les défaillances potentielles, permettant ainsi une planification proactive de la maintenance. Le machine learning facilite également l'identification de schémas et de relations complexes entre les variables, ce qui contribue à une meilleure compréhension des facteurs qui influencent les performances des équipements. En combinant les données en temps réel avec les modèles d'apprentissage automatique, la e-maintenance prédictive permet d'optimiser la disponibilité et les performances des équipements, tout en réduisant les coûts et les interruptions imprévues [8],[9],[14].

2.8 Les techniques du Machine Learning pour la e-maintenance prédictive

2.8.1 Ensemble learning

Une autre approche populaire pour la maintenance prédictive. Ces techniques consistent à combiner plusieurs modèles de machine learning pour améliorer les performances de prédiction. Random Forest, XGBoosting et Gradient Boosting sont des exemples courants de techniques d'ensemble learning [20].

a) Bagging

La technique d'ensemble Bagging est l'acronyme de "bootstrap aggregating". Elle est l'une des premières méthodes d'ensemble proposées. Pour cette méthode, des sous-échantillons d'un ensemble de données sont créés et sont appelés "échantillonnage bootstrap".

Pour simplifier, des sous-ensembles aléatoires d'un ensemble de données sont créés en utilisant le remplacement, ce qui signifie que le même point de données peut être présent dans plusieurs sous-ensembles [20],[21]. Ces sous-ensembles sont maintenant traités comme des ensembles de données indépendants, sur lesquels plusieurs modèles d'apprentissage automatique seront adaptés. Au moment du test, les prédictions de tous ces modèles formés sur différents sous-ensembles des mêmes données sont prises en compte [21].

Un mécanisme d'agrégation est utilisé pour calculer la prédiction finale, comme la moyenne, la moyenne pondérée, etc., dont il sera question plus loin, comme illustré dans la figure 2.2 .

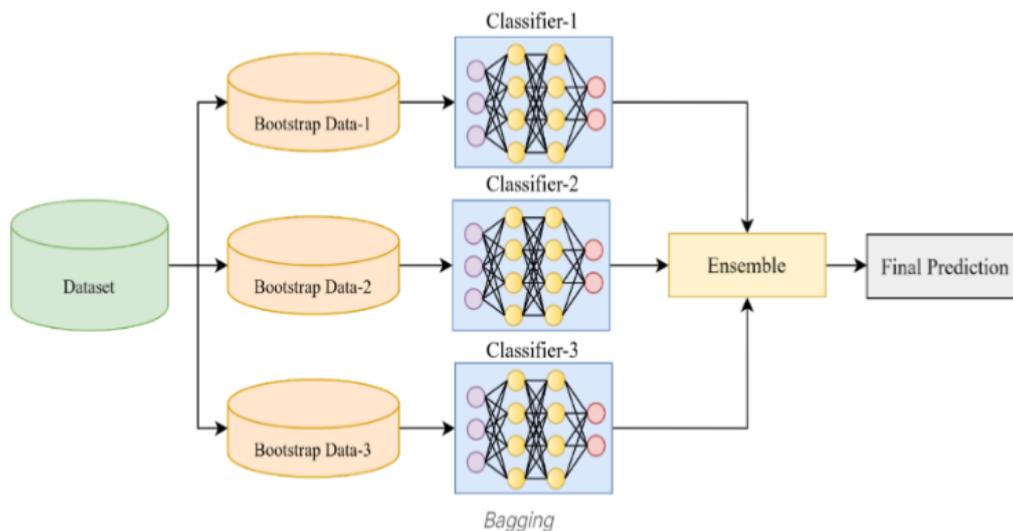


FIG. 2.2 : Mécanisme d'agrégation pour le calcul de la prédiction finale pour le BAGGING.

a) Random Forest

L'algorithme de Random Forest est une technique d'ensemble learning développée par Breiman [20]. Il est l'un des meilleurs algorithmes de classification supervisée en termes de précision. Il est utilisé dans le domaine industriel pour prédire la défaillance imminente d'une machine en temps réel , cependant, la vitesse d'apprentissage est généralement rapide et, en même temps, la fonctionnalité de généralisation est assez bonne. Le principe de cet algorithme est de créer une forêt de décision en sélectionnant de manière aléatoire les arbres qui la composent. Plus la forêt contient un grand nombre d'arbres, plus le résultat est précis. L'algorithme Random Forest utilise les nœuds caractéristiques pour trouver le nœud racine et diviser les nœuds de manière aléatoire. Il comprend également plusieurs classificateurs DT et contient de nombreux nœuds. La prédiction de la défaillance

imminente est basée sur les prédictions des arbres de la forêt aléatoire. Le modèle d'apprentissage automatique de Random forest repose sur des prédictions arborescentes, qui permettent ensuite de fournir des prédictions de Random forest [21]. La figure 2.3 présente une représentation du modèle RF.

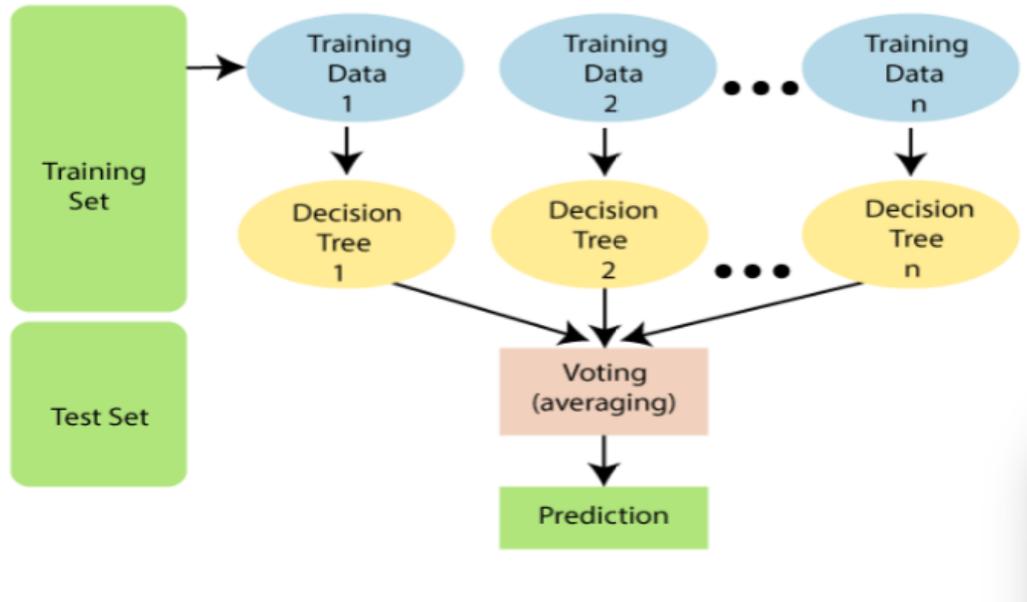


FIG. 2.3 : Représentation du modèle de forêt aléatoire pour prédire une défaillance.

b) Boosting

L'ensemble boosting est une méthode différente de l'ensemble bagging, où les données sont traitées séquentiellement [22]. Le premier classifieur utilise toutes les données, et les cas mal classés sont transférés au deuxième classifieur, qui se concentre sur les problèmes. Cette procédure est répétée avec les autres classifieurs, et alors tous les classifieurs sont utilisés pour la prédiction finale [22].

Un mécanisme de Boosting est utilisé pour calculer la prédiction finale, comme la moyenne, la moyenne pondérée, etc., dont il sera question plus loin, comme illustré dans la figure 2.4.

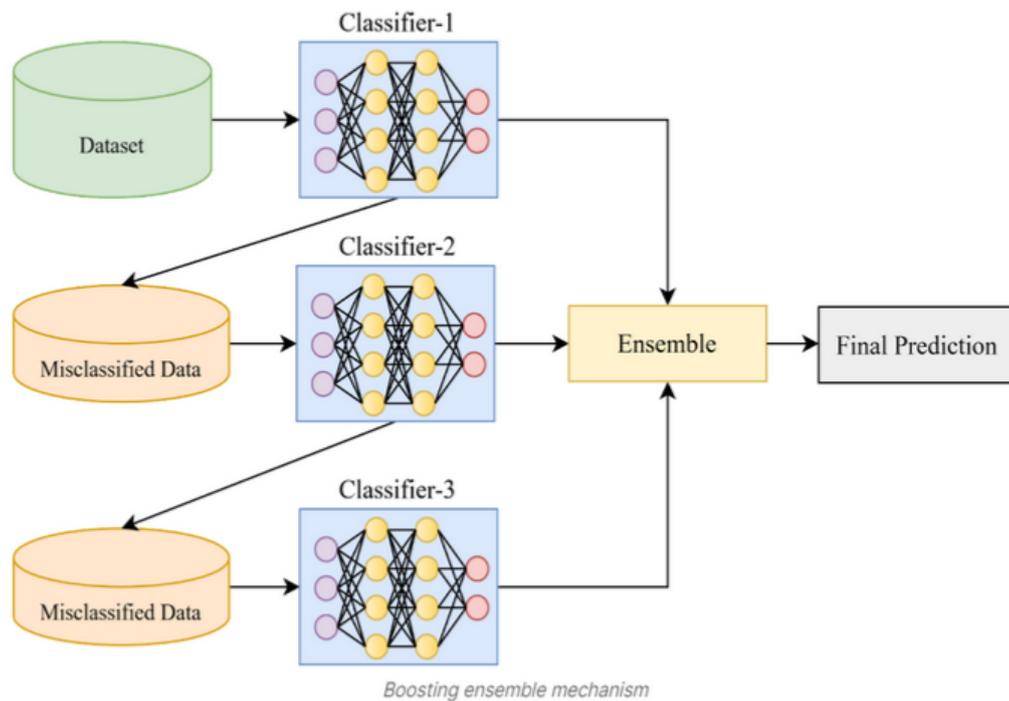


FIG. 2.4 : Mécanisme d'amplification pour le calcul de la prédiction finale.

a) Gradient Boosting (GBoost)

Une autre technique d'ensemble learning qui utilise une combinaison de modèles de faible complexité pour améliorer les performances de prédiction. Cette technique utilise une approche de boosting itératif pour construire un modèle fort à partir de plusieurs modèles faibles. Les modèles faibles sont construits en minimisant l'erreur de prédiction entre le modèle actuel et la vérité terrain [22]. La figure 2.5 présente Gradient Boosting (GB), une autre technique d'ensemble learning utilisant une combinaison de modèles de faible complexité pour améliorer les performances de prédiction. Cette approche utilise un processus de boosting itératif pour construire un modèle fort à partir de plusieurs modèles faibles. Les modèles faibles sont créés en minimisant l'erreur de prédiction entre le modèle actuel et la vérité terrain [23].

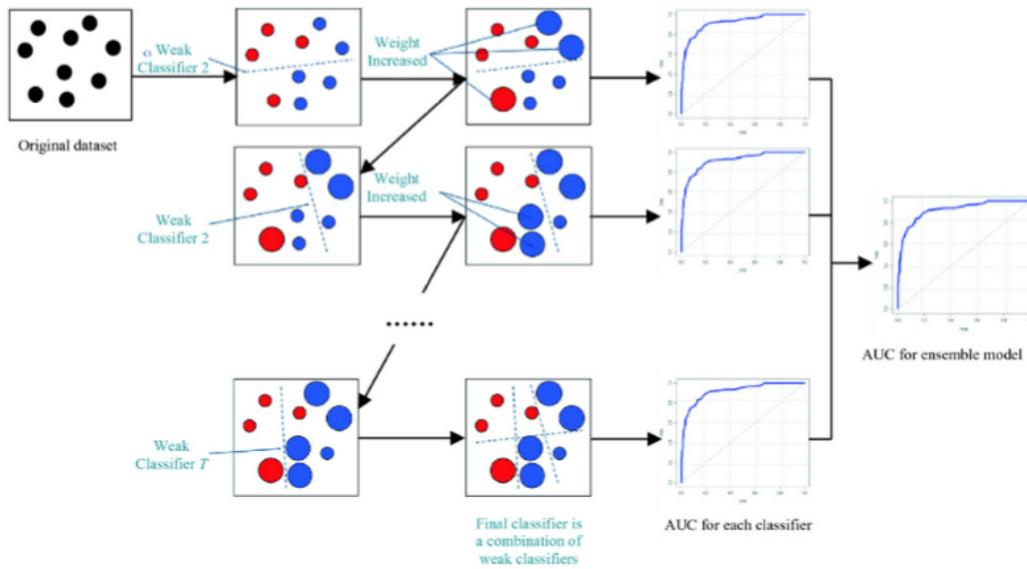


FIG. 2.5 : Gradient Boosting for ensemble learning.

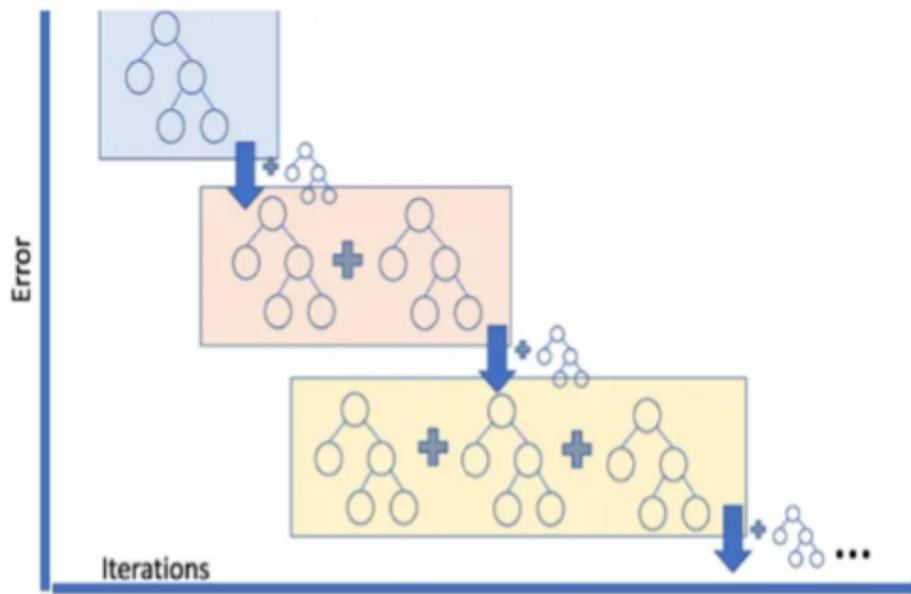


FIG. 2.6 : Illustre le processus itératif de l'algorithme de renforcement de gradient [23].

L'algorithme de gradient boosting est un processus itératif qui combine plusieurs modèles plus simples pour former un modèle prédictif plus puissant. La figure 2.6 montre comment cet algorithme fonctionne[21],[22],[23].

b) Extreme Gradient Boosting (XGBoost)

C'est une technique d'ensemble learning développée par Chen, T. et Guestrin, C. [22]. Il s'agit d'un système évolutif de renforcement des arbres qui est largement utilisé par les scientifiques des données et qui fournit des résultats de pointe sur de nombreux

problèmes. Comme la figure 2.7 le montre, cette technique utilise une combinaison de gradient boosting et de régularisation pour améliorer la précision de la prédiction [22],[23].



FIG. 2.7 : Illustration de l'algorithme XGBoost pour une précision de prédiction améliorée avec amplification et régularisation des gradients [22].

XGBoosting utilise des arbres de décision peu profonds pour modéliser les relations entre les caractéristiques et la variable ciblée, et utilise une fonction de coût régularisée pour éviter le surapprentissage La figure 2.7 présente l'algorithme XGBoost.

2.9 Comparaison entre les techniques utilisés

Pour évaluer les performances des différentes techniques de machine learning, nous avons réalisé le tableau 2.1 détaillé.

Ce dernier présente les principales caractéristiques et avantages et limitations de Random Forest, Adaptive Boosting (AdaBoost) et Extreme Gradient Boosting (XGBoost).

Techniques	Principe	Critère		REF
		Avantages	Limitations	
Random forest	Plusieurs arbres de décision seront utilisés pour faire des prédictions. Chaque arbre est formé sur un sous-ensemble aléatoire du données et fonctionnalités, évitant ainsi surapprentissage et amélioration précision des prédictions.	-Réduit le risque de surajustement en combinant plusieurs arbres de décision. -Efficace pour les grandes tailles de données. -Robuste aux valeurs manquantes et aux valeurs aberrantes.	-Moins interprétable que les arbres de décision individuels. -Peut être coûteux en calcul.	[8],[10],[18]
Gradient boosting	Construit des modèles prédictifs en améliorant de manière itérative un modèle de base en ajoutant des modèles plus complexes.	Efficace pour les grandes tailles de données. Peut être utilisé pour la classification et la régression. Peut gérer les données manquantes.	Risque de sur-ajustement. Sensibilité aux valeurs aberrantes. Nécessite plus de temps de calcul que les arbres de décision.	[22],[10]
XGboosting	-Basé sur des arbres de décision, mais utilise une méthode d'optimisation plus avancée appelée Gradient Boosting. Cette méthode combine plusieurs arbres de décision faibles pour construire un modèle plus performant.	Fonctionne bien sur de grands ensembles de données, rapide à former, évite le surapprentissage, peut être utilisé avec une grande variété de fonctions de perte...	-Peut nécessiter une configuration et un réglage minutieux des hyperparamètres. -Peut nécessiter une préparation de données plus complexe, peut être moins interprétable que DT.	[21],[10]

TAB. 2.1 : Comparaison entre les RF,XGboost et AdaBoost.[21],[22],[23]

2.10 Conclusion

Dans ce chapitre nous avons illustré l'utilisation des techniques d'ensemble learning, en particulier Random Forest, XGBoosting et Gradient Boosting, pour la maintenance prédictive offre plusieurs avantages, notamment la réduction des coûts de maintenance et des temps d'arrêt imprévus. Cependant, il convient de noter que ces techniques peuvent nécessiter une grande quantité de données d'entraînement et de temps de calcul pour obtenir des résultats précis. Il est donc important de bien comprendre les avantages et les limites de chaque technique avant de les utiliser dans des applications de maintenance prédictive [22],[23].

Chapitre 3

Implémentation des techniques et résultats

3.1 Introduction

Dans ce chapitre, nous avons sélectionné le séparateur d'huile Alfa Laval PX90 comme étude de cas afin de mettre en œuvre une stratégie de maintenance prédictive. L'objectif était d'améliorer la fiabilité, l'efficacité et la disponibilité, tout en réduisant les temps d'arrêt imprévus et en anticipant les signes précurseurs de défaillance. En accomplissant ces objectifs, les coûts de maintenance ainsi que les pertes de production seront minimisés. Tout d'abord, nous avons utilisé la méthode AMDEC moyen pour évaluer les risques liés aux défaillances et déterminer les mesures préventives appropriées. Cette démarche comprenait l'identification des modes de défaillance potentiels, l'évaluation des effets de ces défaillances, la détermination de leur criticité et la proposition de mesures préventives.

Ensuite, nous avons employé des techniques d'apprentissage automatique avancées, plus spécifiquement des méthodes d'ensemble learning, dans le but de classifier en temps réel les états d'alerte actuels de la machine et de prédire les paramètres pertinents pour localiser les défauts. Pour y parvenir, nous avons procédé à une collecte et un prétraitement des données historiques collectées à partir de capteurs. Nous avons ensuite effectué une analyse et une visualisation des données en mettant l'accent sur les paramètres les plus pertinents que nous avons identifiés, en les associant à l'identification des états d'alerte correspondants.

Par la suite, nous avons entraîné des modèles de classification et de régression en utilisant les données préparées. En évaluant les résultats obtenus, nous serons en mesure de déterminer le meilleur modèle de classification à utiliser pour détecter et prévoir les pannes avant qu'elles ne surviennent. De plus, nous disposons également du meilleur modèle de régression pour localiser spécifiquement les pannes.

Enfin, en se basant sur les informations fournies par notre système de détection et de prédiction, nous avons proposé un plan de maintenance préventive pour éviter les pannes détectées. Cette approche globale nous permet d'optimiser nos stratégies de détection, de prévention et de localisation des pannes.

3.2 Application de la methode AMDEC Moyen sur le separateur Alfa Laval PX90

L'analyse AMDEC Moyen a identifié les défaillances les plus critiques et les risques associés. Ces résultats sont basés sur une évaluation approfondie des modes de défaillance, de leur gravité, de leur fréquence d'occurrence et de leur capacité de détection. Le tableau 3.1 définit le niveau de criticité et l'action à engager.

Niveau de criticité	Actions à engager
1 < C < 12 Criticité négligeable	-Aucune modification de conception. -Maintenance corrective.
12 < C < 24 Criticité moyenne	-Amélioration des performances de l'élément. -Maintenance préventive systématique.
24 < C < 48 Criticité élevée	-Révision de la conception du sous-ensemble et du choix des éléments. -Surveillance particulière. -Maintenance préventive conditionnelle/prévisionnelle.
48 < C < 64 Criticité interdite	-Remise en cause complète de la conception.

TAB. 3.1 : Echelle de criticité

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de la défaillance	Détection	F	G	D	C	Action
Joint bleu	Etanchéité	Rupture	-Fatigue -Durée de vie	Garniture usée	Contrôle	2	2	3	1 2	-Vérification de la lubrification -Changement de joint
Joint téflon	Etanchéité	-Déplacement de joint -Rupture	-Fatigue -Durée de vie -Charge	-Bruit -Pièce usée -Fuite	Contrôle	3	3	3	2 7	Changement de joint
Bague de réglage de la hauteur	Etanchéité	-Usure -déformation -Cassure	-Fatigue -Durée de vie	-Réglage perdu	Contrôle	1	3	2	6	Changement de Bague
Garniture mécanique	Etanchéité	-Usure Fissure	Fatigue -Frottement -Charge -Manque d'eau de refroidissement -Rupture des joints	Bruit -Vibration élevé -Changement de vitesse -Faible rendement	-Contrôle -Bruit anormal	4	4	3	4 8	Changement de la Garniture mécanique -Contrôle du système de refroidissement Et le système de lubrification
Joint torique	Etanchéité	-Usure -La hauteur du joint n'est pas exacte -Rupture	-Fatigue -Pas de lubrification	-Bruit -Fissure de la garniture -Fuite	Contrôle	3	4	3	3 6	-graissage -Changement de joint

TAB. 3.2 : Application de l'AMDEC Moyen machine sur la partie étanchéité

Chapitre 3. Implémentation des techniques et résultats

dans le tableau 3.2, l'étanchéité comprend trois éléments critiques, dont deux d'entre eux (la garniture mécanique et le joint torique) nécessitent l'intervention du constructeur. Le joint Téflon présente une criticité élevée avec C=27.

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de défaillance	Détection	F	G	D	C	Action
Roue dentée	Transmission	-Usure -Fissure	-Fatigue de matériau -Manque de lubrification	Arrêt de Séparateur	-Bruit anormal	2	3	3	12	Changement des roues -Vérifier la lubrification -Eliminer les jeux
Arbre vertical	Transmission	-Usure -Déformation -Rupture	-Manque de lubrification -Charge -Fatigue	Vibration élevé	Contrôle	1	4	3	12	-Vérifier la lubrification -Réglage de l'arbre -Changement de l'arbre
Arbre horizontal	Transmission	-Usure -Déformation	-Manque de lubrification -Jeux -Vibration	-Vibration élevé -Mauvais fonctionnement	-Contrôle -Bruit	3	4	3	36	-Réglage de l'arbre -Changement de l'arbre -Vérifier la lubrification
Réducteur de vitesse	-Freinage de convoyeur	Mauvais freinage du convoyeur	-Détérioration des engrenages -Manque de lubrifiant	-Mauvais rapport de vitesse -Vibration	Contrôle	2	3	2	12	-Changement de réducteur

TAB. 3.3 : Application de l'AMDEC machine sur la partie transmission de mouvement

Dans le tableau 3.3, nous avons observé que plusieurs éléments affichent une criticité moyenne de C 12, à l'exception de l'arbre horizontal qui présente une criticité particulièrement élevée avec C=36. Dans cette situation, l'intervention du constructeur est nécessaire selon les besoins du service de maintenance.

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de défaillance	Détection	F	G	D	C	Action
Bol	Séparation	-Usure -Fuite -Fissure	-Mauvais nettoyage -Déformation des joints	-Perte de production -Vibration élevé -Bruit -Vitesse de séparateur diminue ou augmente	-Bruit anormal	2	3	3	18	-Bon nettoyage des pièces du bol -Changement du bol
Assiette	Séparation	-Usure -Déformation	-Mauvais nettoyage des assiettes -Mauvais montage -La charge	-Mauvaise séparation -Mauvaise évaluation	Visuel	4	2	2	16	-Nettoyage des assiettes -Changement des assiettes
Centrizoom	Séparation	-Usure -Déformation -Fissure	-Fatigue du matériau -Mauvais réglage -La charge -Vitesse élevée -Pression élevée	-Mauvaise séparation -Mauvaise évacuation	Contrôle	2	2	3	12	-Vérification de la commande -Changement de centrizom -Nettoyage de centrizoom
Electrovanne	- Régularisation de débit -Séparation	- L'électrovanne reste fermée - L'électrovanne reste ouverte	Usure de la pièce interne	Il n'y a pas de régulation de débit	Contrôle	2	3	2	12	Changer l'électrovanne

TAB. 3.4 : Application de l'AMDEC machine sur la partie séparation

Dans le tableau 3.4, nous observons la présence de plusieurs éléments avec une criticité

moyenne, avec des valeurs de $12 < C < 24$. La remise en marche de ces éléments relève uniquement de la responsabilité du service de maintenance.

3.2.1 La réévaluation de la criticité :

La réévaluation de la criticité consiste à regrouper les éléments selon leur criticité, en les classant par ordre décroissant dans le tableau 3.5. Il est essentiel de prioriser ces éléments pour engager des actions appropriées en conséquence.

Element	Criticité	Action
-Garniture mécanique -Joint torique -Arbre horizontal	48 36 36	Remise complète de la conception
-Joint téflon	27	Surveillance particulière Maintenance préventive conditionnelle
-Bol -Assiettes -joint bleu -Roue dentée -Arbre vertical -Réducteur de vitesse -Électrovanne	18 16 12 12 12 12 12	Amélioration des performances d'éléments. Maintenance préventive systématique
-Bague de réglage de la hauteur	6	Aucune modification Maintenance corrective

TAB. 3.5 : Classification des éléments selon leur criticité

–Pour l'intervention du constructeur de la machine, on a choisi la valeur 36 comme seuil de criticité.

3.2.2 Analyse des résultats

Pour améliorer la disponibilité du séparateur Alfa Laval, il est essentiel de mettre en œuvre des actions de maintenance sur les équipements ayant une criticité supérieure à 12. Les actions recommandées incluent une surveillance périodique et une maintenance systématique ou conditionnelle.

Grâce à notre analyse approfondie, nous avons identifié les risques de dysfonctionnement du système de grenailage, en mettant en évidence les points critiques et en proposant des actions de maintenance pour réduire leur criticité.

Nous avons constaté que la majorité des problèmes rencontrés dans ce système sont liés à l'usure. Afin d'éviter de tels problèmes, il est recommandé de réaliser un contrôle systématique de l'usure. Pour prévenir la propagation de l'usure et les défaillances susceptibles de perturber le fonctionnement normal du système, l'entreprise doit effectuer régulièrement les tâches suivantes :

- Réparations et nettoyage
- Respect des instructions de maintenance systématique telles que le remplacement des pièces défectueuses selon l’agenda périodique recommandé par le constructeur,
- Tenue d’un historique des pannes, réexamen périodique de l’AMDEC,
- Formation du personnel de maintenance à l’AMDEC,
- Maintien d’un stock de sécurité de pièces de rechange essentielles.

Pour une analyse plus approfondie des défaillances et des risques, veuillez vous référer à l’**annexe C** où nous avons détaillé notre application de la méthode AMDEC.

3.3 Approche intégrée de surveillance, analyse de données et prédictions pour la détection d’états d’alerte

La Figure 3.1 illustre la démarche adoptée dans cette partie du Chapitre 3

3.3.1 Collecte et prétraitement de données

Acquisition de données

Les données ont été acquises à l’aide de capteurs connectés au séparateur d’huile, permettant de recueillir des informations essentielles pour assurer son bon fonctionnement. La collecte de données s’est étendue sur une période de 8 ans, Les données sont enregistrées en temps réel, assurant une capture instantanée des informations. Cependant, afin de faciliter leur traitement et leur analyse, une transformation est effectuée toutes les 15 minutes. Cette périodicité permet d’organiser les données de manière plus efficace, simplifiant ainsi les opérations ultérieures de traitement et d’analyse. Cette approche garantit une gestion optimale des données en vue d’optimiser les processus de maintenance prédictive du séparateur d’huile Alpha Laval PX90 chez Cévitral. Les variables clés mesurées comprennent le courant, la vibration, la vitesse et la contre-pression (avant de démarrer la production d’huile séparée, il est impératif d’appliquer une contre-pression sur l’huile complète afin d’éviter tout effet de vide indésirable). Ces paramètres jouent un rôle crucial dans la performance et la fiabilité du séparateur d’huile Parmi les variables collectées, le centrage (centre-zoom) revêt une importance particulière. Il est exprimé en pourcentage et permet de localiser précisément la phase pâteuse de l’huile, qui est séparée en une phase légère et une phase pâteuse distincte. La mesure de centrage est essentielle pour détecter la présence de pâte dans l’huile et prendre les mesures appropriées. Un autre paramètre d’intérêt est l’état de la machine, représenté par des valeurs telles que "Démarrage", "Stand-By", "En-production", "Envoie-production" et "Arrêt". Ces informations fournissent une vue complète de l’état opérationnel de la machine à différents moments, ce qui est essentiel pour évaluer son fonctionnement et prévoir d’éventuelles défaillances.

Importation des données et prétraitement

Les données sont importées à partir de fichiers locaux tels que des fichiers CSV ou Excel vers des logiciels open source tels qu'Anaconda Jupiter Notebook, qui sont utilisés pour l'analyse de données. Pour cela, différentes bibliothèques sont utilisées comme le tableau 3.6 montre :

Bibliothèque	Classe/Fonction	Explication
Pandas	read_csv()	-Lecture d'un fichier CSV et création d'un Data Frame à partir des données.
	DataFrame	- Structure de données tabulaire permettant de stocker et manipuler les données
Numpy	array()	-Création d'un tableau multidimensionnel pour le stockage et la manipulation des Données
Matplotlib	pyplot()	-Module de visualisation de données permettant de créer des graphiques et des Visualisations
Seaborn	heatmap()	-Création d'une carte thermique (heatmap) pour visualiser les corrélations entre les Variables
Scikit-learn	RandomForest Classifier/Regressor	-Classe pour la construction d'un modèle de classification/régression utilisant la méthode de la forêt Aléatoire
	GradientBoosting Classifier/Regressor	-Classe pour la construction d'un modèle de classification /régression en utilisant l'algorithme de boosting par gradient
	train_test_split()	-Fonction pour séparer les données en un ensemble d'entraînement et un ensemble de test.
	accuracy_score()	-Fonction pour calculer le score d'exactitude (accuracy) d'un modèle de classification
	datetime	-Classe pour la manipulation des valeurs de date et d'heure
Scikit-learn	confusion_matrix()	- Fonction pour calculer une matrice de confusion, qu'évalue les performances d'un modèle de classification en comparant les prédictions avec les valeurs réelles
	XGBClassifier/regressor	-Classe pour la construction d'un modèle de Classification / Regression utilisant l'algorithme de boosting
Sklearn.preprocessing	LabelEncoder	-Classe pour convertir des variables Catégorielles en variables numériques
Sklearn.metrics	classification_report()	-Fonction pour générer un rapport détaillé des performances d'un modèle de classification, y Compris la précision, le rappel, le score F1, etc.
	mean_absolute_error() mean_squared_error()	-Fonction pour calculer l'erreur absolue / quadratique moyenne entre les prédictions et les valeurs réelles dans un modèle de régression
	r2_score()	-Fonction pour calculer le coefficient de détermination (R ²) d'un modèle de régression

TAB. 3.6 : Tableau des bibliothèques, classes et fonctions utilisées.

Lors de l'importation des données, nous utilisons la fonction `read_csv()` pour charger les données dans des structures de données pandas, telles que les DataFrames, afin de les manipuler ultérieurement. La fonction `pd.to_datetime` est utilisée pour convertir les valeurs de date et d'heure dans le format approprié. Après l'importation, nous pouvons vérifier les en-têtes de colonne en affichant les 10 premières lignes du DataFrame à l'aide de la fonction `head()`. La figure 3.1 présente certaines fonctions de la bibliothèque pandas pour les tableaux qui fournissent des informations sur le DataFrame, telles que `head()`, `info()`, `isnull().sum()` et `describe()`.

Les résultats des fonctions `info()` et `isnull().sum()` indiquent ce qui suit :

1. Le DataFrame comprend 250 000 entrées réparties sur 7 colonnes.
2. Les colonnes contiennent des données de différents types, tels que des dates, des nombres décimaux, des nombres entiers et des chaînes de caractères.
3. Aucune valeur manquante n'est présente dans le DataFrame.
4. la fonction `describe()` nous aide d'obtenir des statistiques descriptives sur les données, telles que la moyenne, l'écart type, les valeurs minimales et maximales, etc.

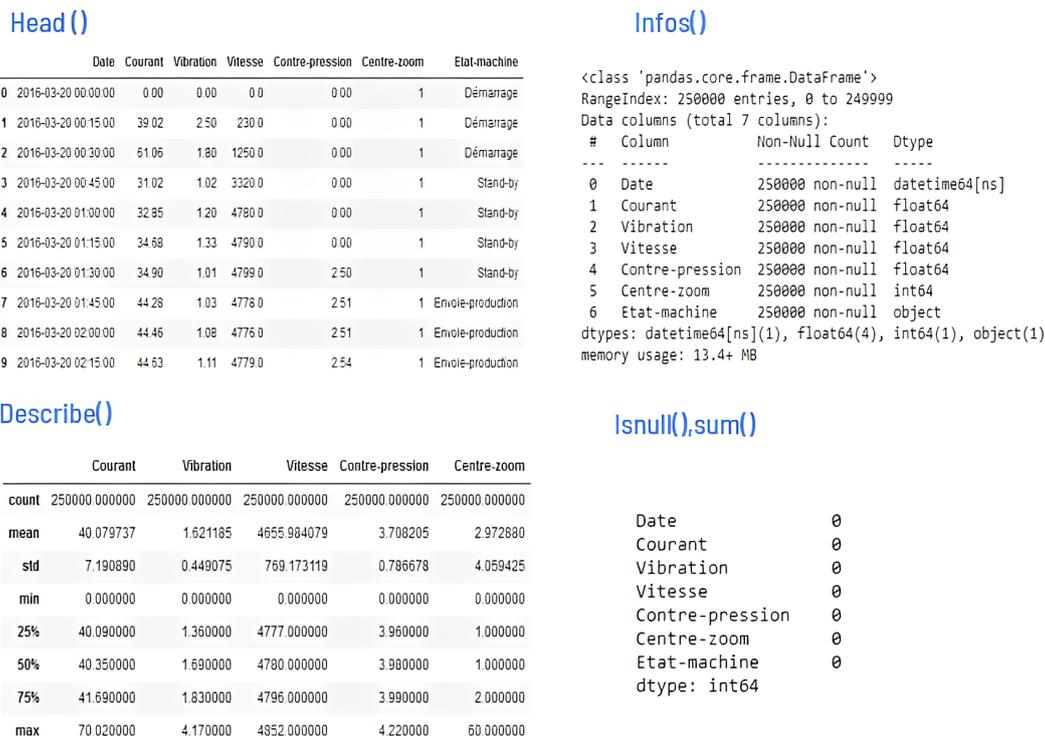


FIG. 3.1 : Fonctions de la bibliothèque pandas pour l'exploration initiale du DataFrame

3.3.2 Exploration et analyse des données

Dans cette étape, nous avons exploré les données en utilisant des techniques d'analyse et de visualisation avancées. Nous avons généré des graphiques et des tableaux récapitulatifs pour visualiser les distributions et les tendances des différentes variables. L'objectif

était d'identifier les relations significatives entre les variables et d'extraire des informations précieuses pour la détection des états d'alerte.

Analyse dynamique des paramètres

Visualisation des distributions des variables numériques avec des histogrammes

Dans cette partie, une copie temporaire du DataFrame `data` est créée à l'aide de la méthode `copy()`. Ensuite, la variable catégorielle "Etat-machine" est convertie en variable numérique dans la copie temporaire en utilisant la méthode `map()` pour mapper les valeurs catégorielles aux valeurs numériques correspondantes. Ensuite, la colonne "Date" est supprimée de la copie temporaire à l'aide de la méthode `drop()`. Enfin, les distributions des variables numériques sont visualisées à l'aide d'histogrammes en utilisant la méthode `hist()` sur la copie temporaire du DataFrame et en spécifiant des paramètres tels que `alpha`, `bins`, et `color`. La fonction `tight_layout()` est utilisée pour améliorer la disposition des sous-graphiques, puis la fonction `show()` est utilisée pour afficher la figure 3.2

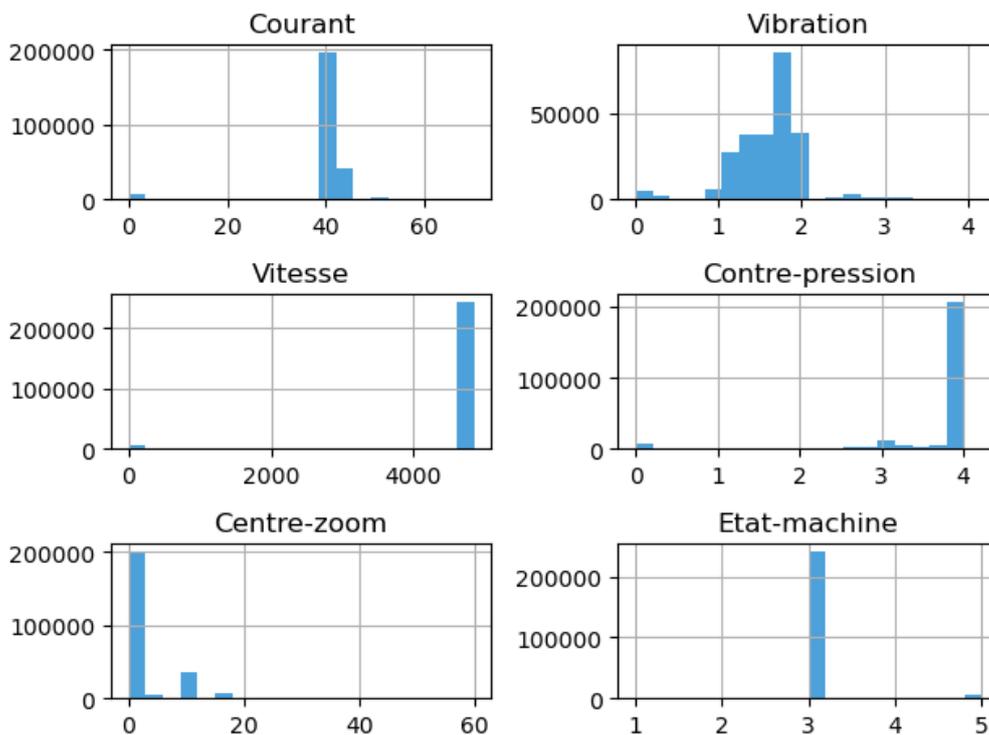


FIG. 3.2 : Distribution des variables numériques

Visualisation de l'évolution des paramètres Dans cette partie, la figure 3.3 contenant 3 lignes et 2 colonnes est créée à l'aide de la fonction `subplots()`. Ensuite, une liste de paramètres est définie. Une boucle est utilisée pour parcourir les paramètres et les afficher dans les sous-graphiques correspondants. Pour chaque paramètre, un graphe de l'évolution du paramètre en fonction de la date est tracé à l'aide de la méthode `plot()`. Les étiquettes des axes et les titres des sous-graphiques sont définis à l'aide des méthodes `set_xlabel()`, `set_ylabel()` et `set_title()`. Enfin, la fonction `tight-layout()` est utilisée pour améliorer la disposition des sous-graphiques, et la fonction `show()` est utilisée pour afficher la figure 3.3

La Figure 3.3 présente l'évolution des paramètres au cours du temps, de 2016 à 2023. Une

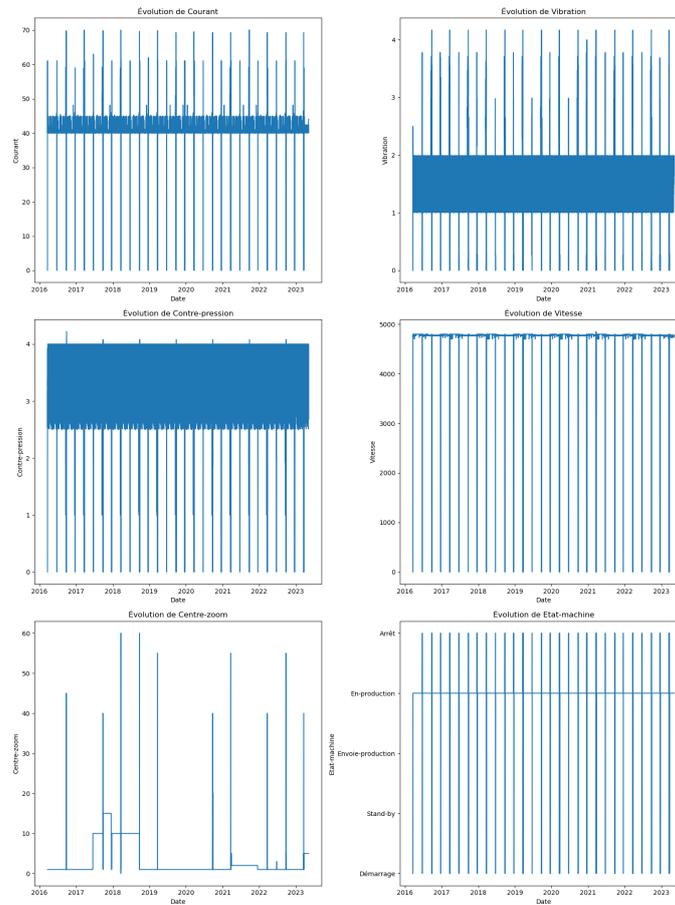


FIG. 3.3 : Évolution des paramètres en fonction du temps

analyse approfondie des données révèle plusieurs observations significatives. Tout d'abord, il est constaté que la machine était en fonctionnement de manière générale tout au long de ces années. Concernant les différents paramètres, il est observé que leurs valeurs tendent à se rapprocher de zéro environ tous les 3 mois. Cette observation suggère que l'arrêt de la machine est généralement programmé tous les 3 mois. Par ailleurs, il est remarqué que l'arrêt de la machine est déclenché lorsque les valeurs de courant et de vibration dépassent des seuils supérieurs, tandis que la valeur de contre-pression atteint des seuils inférieurs. Ces seuils indiquent des niveaux critiques qui nécessitent une intervention ou une maintenance préventive. En outre, il est possible d'extraire les valeurs moyennes de chaque paramètre pour obtenir une mesure de référence. Ces moyennes fournissent une indication de la tendance générale des paramètres au fil du temps et peuvent être utilisées pour évaluer les variations et les écarts par rapport à la normale.

Visualiser les relations entre les variables numériques avec une matrice de corrélation Pour visualiser les relations entre les variables numériques avec une matrice de corrélation nous avons suivi ces étapes :

1. Sélectionner les colonnes nécessaires ("Vibration", "Courant", "Contre-pression", "Centre-zoom", "Vitesse").

2. Créer une matrice de corrélation à l'aide de la fonction `corr()`.
3. Afficher la heatmap de corrélation avec la fonction `heatmap()`, annotée avec les valeurs de corrélation.
4. Définir le titre de la heatmap avec la fonction `title()`.
5. Afficher la heatmap avec la fonction `show()` est utilisée pour afficher la figure 3.4

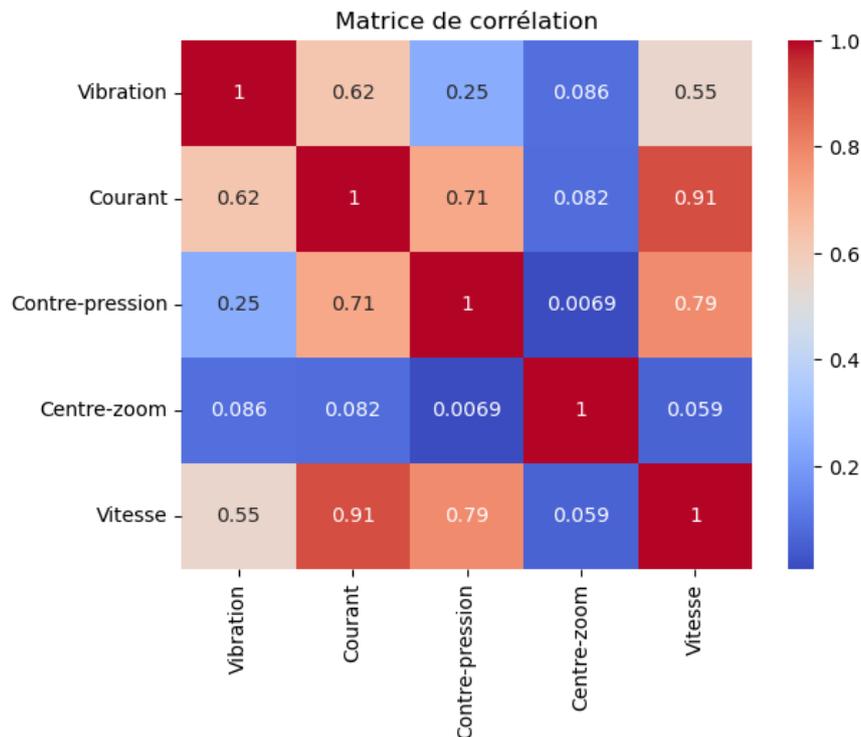


FIG. 3.4 : Heatmap de corrélation des variables numériques

Pour une visualisation claire, nous avons créé un tableau des coefficients de corrélation en utilisant un DataFrame appelé "table-data". Ce DataFrame a été créé à partir de la matrice de corrélation, en utilisant les paires de variables comme index et la colonne "Corrélation" pour afficher les valeurs. Nous avons également ajouté une colonne "Corrélation-abs" contenant les valeurs absolues des coefficients de corrélation. Ensuite, nous avons trié le DataFrame par ordre décroissant des valeurs absolues de corrélation en utilisant la méthode "sort-values()". Enfin, nous avons affiché le tableau 3.2 des coefficients de corrélation en utilisant la fonction "print()".

Tableau des corrélations :

	Variable 1	Variable 2	Corrélation	Corrélation_abs
9	Courant	Vitesse	0.908117	0.908117
21	Vitesse	Courant	0.908117	0.908117
14	Contre-pression	Vitesse	0.786608	0.786608
22	Vitesse	Contre-pression	0.786608	0.786608
7	Courant	Contre-pression	0.714809	0.714809
11	Contre-pression	Courant	0.714809	0.714809
1	Vibration	Courant	0.620929	0.620929
5	Courant	Vibration	0.620929	0.620929
20	Vitesse	Vibration	0.552380	0.552380
4	Vibration	Vitesse	0.552380	0.552380
10	Contre-pression	Vibration	0.246718	0.246718
2	Vibration	Contre-pression	0.246718	0.246718
3	Vibration	Centre-zoom	0.085870	0.085870
15	Centre-zoom	Vibration	0.085870	0.085870
8	Courant	Centre-zoom	0.081970	0.081970
16	Centre-zoom	Courant	0.081970	0.081970
23	Vitesse	Centre-zoom	0.058927	0.058927
19	Centre-zoom	Vitesse	0.058927	0.058927
17	Centre-zoom	Contre-pression	0.006921	0.006921
13	Contre-pression	Centre-zoom	0.006921	0.006921

TAB. 3.7 : Tableau de corrélations .

le tableau 3.7 représente les corrélations entre différentes paires de variables La colonne "Corrélation" indique la mesure de corrélation entre les deux variables, tandis que la colonne "Corrélation Abs" représente la valeur absolue de la corrélation. Les valeurs proches de 1 indiquent une corrélation positive forte, tandis que les valeurs proches de 0 indiquent une corrélation faible. Certaines paires de variables présentent des corrélations élevées, telles que "Courant" et "Vitesse", "Contre-pression" et "Vitesse", ainsi que "Courant" et "Contre-pression".

Les paramètres les plus pertinents sont sélectionnés en groupant les lignes du DataFrame `table_data` par la colonne "Variable 1" et en choisissant la première ligne de chaque groupe avec la méthode `head(1)`. Les résultats sont ensuite triés par ordre décroissant des valeurs absolues de corrélation. Le tableau 3.4 des paramètres les plus pertinents est affiché à l'aide de la fonction `print()`

Paramètres les plus pertinents :

	Variable 1	Variable 2	Corrélation
9	Courant	Vitesse	0.908117
21	Vitesse	Courant	0.908117
14	Contre-pression	Vitesse	0.786608
1	Vibration	Courant	0.620929
15	Centre-zoom	Vibration	0.085870

TAB. 3.8 : les paramètres les plus pertinents selon le coefficient de corrélation.

le tableau 3.8 présente les paires de variables les plus pertinentes en termes de corrélation. Les variables "Courant" et "Vitesse" présentent la plus forte corrélation avec une valeur de 0.908061, suivies de "Contre-pression" et "Vitesse" avec une corrélation de

0.786608. La corrélation entre "Vibration" et "Courant" est également significative avec une valeur de 0.619878. En revanche, la corrélation entre "Centre-zoom" et "Vibration" est plus faible avec une valeur de 0.085542.

l'évolution des paramètres pour chaque état en 2022 Pour le tracé de l'évolution des paramètres en fonction de la date pour chaque état en 2022 :

1. Les données sont filtrées pour l'année 2022. Une figure avec des sous-graphiques est créée à l'aide de la fonction `subplots()`.
2. Les données sont parcourues pour chaque paramètre et chaque état de la machine.
3. Le graphe de l'évolution du paramètre en fonction de la date est tracé à l'aide de la méthode `plot()`.
4. Les sous-graphiques sont ajustés et affichés avec la fonction `tight-layout()` et `show()` est utilisée pour afficher la figure 3.5

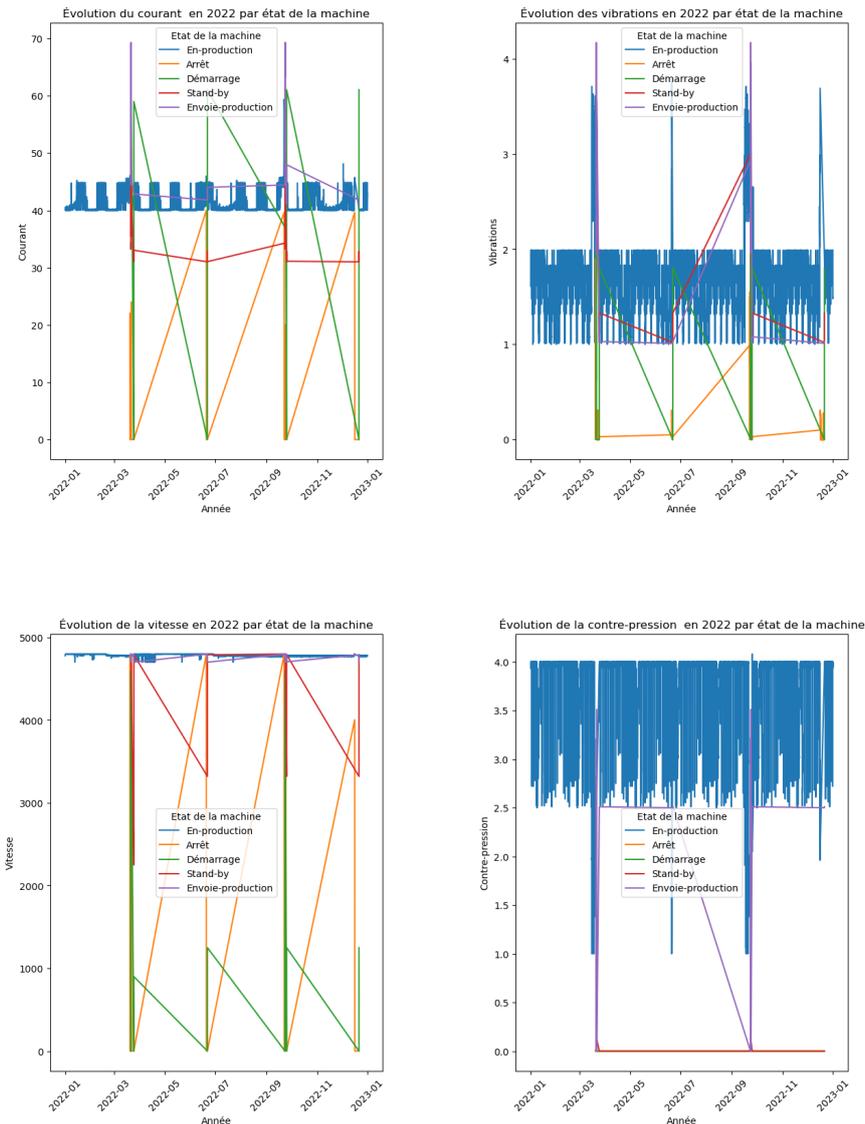


FIG. 3.5 : l'évolution des paramètres pour chaque état en 2022

Tout d'abord, afin de mieux visualiser les états critiques et les intervalles de fonctionnement normal de la machine, un tableau présentant les intervalles des paramètres dans des conditions normales peut être utile. Cela permettra d'identifier plus facilement les écarts par rapport à ces valeurs de référence et de détecter les états critiques de la machine.

Intervalle de fonctionnement normal

	Courant	Vibration	Contre-Pression	Vitesse
Démarrage	0 - 69	0 - 3.7	0 - 0.2	0 - 4810
Stand-by	28 - 35	1 - 1.8	0 - 0.2	4700 - 4800
Envoie-production	34 - 45.5	1 - 2	2.5 - 4.5	4700 - 4800
En-production	40 - 45.5	1 - 2	2.5 - 4.5	4700 - 4800
Arrêt	0 - 0.3	0 - 0	0 - 0.2	4800 - 0

TAB. 3.9 : Tableau des intervalle de fonctionnement normal

D'après l'analyse des résultats de la figure 3.6, qui représente l'évolution des paramètres d'une machine en fonction de la date pour chaque état en 2022, les observations suivantes peuvent être faites :

1. La machine est généralement en production tous les jours, ce qui suggère un fonctionnement normal pendant la majeure partie de l'année.
2. Des périodes d'arrêt sont programmées tous les trois mois, ce qui peut correspondre à des opérations de maintenance régulières ou à d'autres activités planifiées visant à assurer le bon fonctionnement de la machine. Ces arrêts semblent être déclenchés lorsque les paramètres atteignent des valeurs critiques en dehors de l'intervalle normal. Cette approche indique qu'il existe des seuils de fonctionnement définis pour les paramètres, et lorsque ces seuils sont dépassés, il est nécessaire d'arrêter la machine pour éviter des problèmes plus graves.
3. Après chaque arrêt de la machine, un redémarrage est effectué et la production reprend. Cela suggère que la machine est conçue pour être redémarrée après chaque période d'arrêt planifiée, et la production reprend normalement.
4. Une observation importante concerne les mois de mars 2022 et septembre 2022, où la durée d'arrêt est plus longue par rapport aux autres périodes. De plus, les valeurs des paramètres pendant ces périodes sont supérieures à celles des autres états. Cela peut indiquer un dysfonctionnement de la machine pendant ces mois, ce qui entraîne une indisponibilité prolongée et des valeurs anormales des paramètres. Il est essentiel de prêter une attention particulière à ces périodes afin de résoudre les problèmes de fonctionnement de la machine.

Pour une visualisation plus claire et discrète des données, nous pouvons utiliser la fonction "scatterplot" au lieu de "lineplot", comme illustré dans la figure 3.6 . Cela nous permettra d'observer les valeurs des paramètres de manière distincte et de mieux comprendre les variations entre les différents états de la machine.

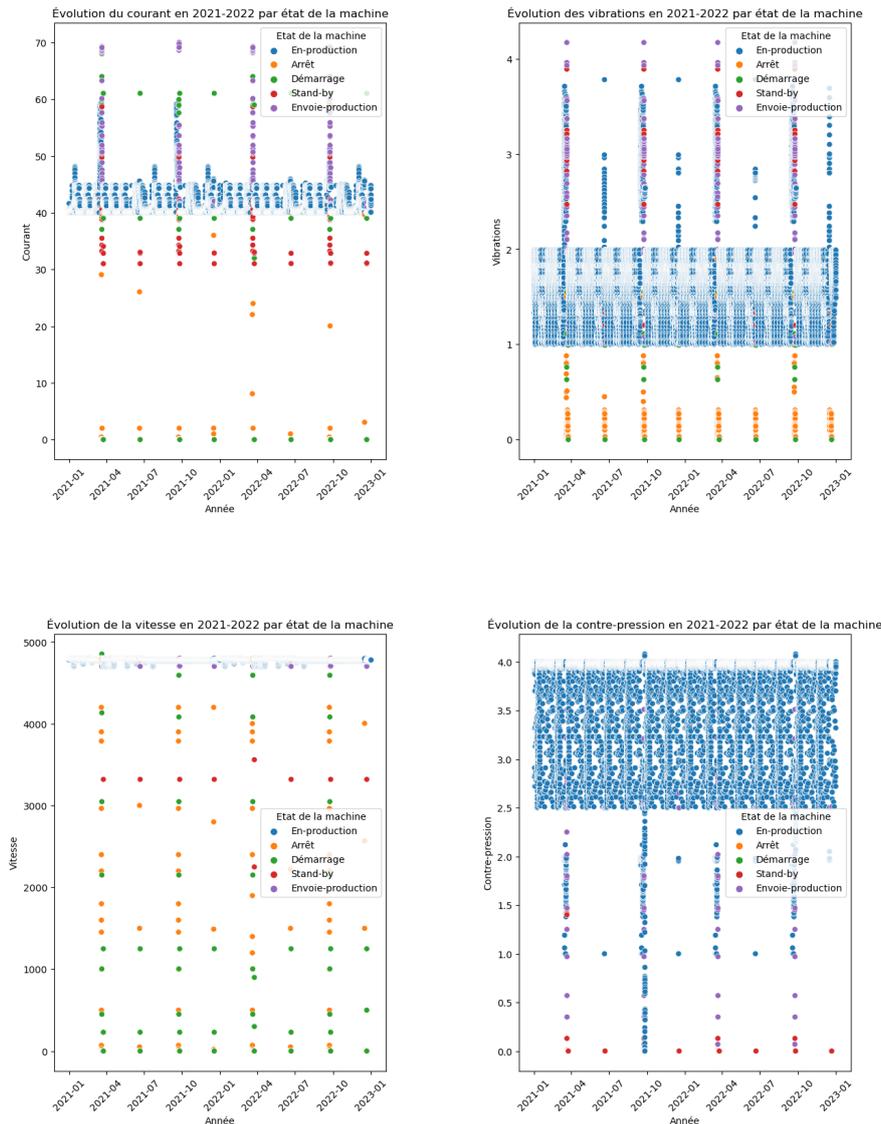


FIG. 3.6 : l'évolution des paramètres en fonction de la date pour chaque état de machine en 2022 avec la fonction scatter

Visualisation des relations entre les paramètres pertinents Pour visualiser les relations entre les paramètres pertinentes, nous avons suivi ces étapes :

1. Sélection des colonnes nécessaires : Les colonnes pertinentes ('Vibration', 'Contre-pression', 'Courant', 'Vitesse') sont extraites du DataFrame 'data' et stockées dans un nouveau DataFrame appelé 'df_filtered'.
2. Calcul de la matrice de corrélation : La méthode 'corr()' est utilisée sur le DataFrame 'df_filtered' pour calculer la matrice de corrélation entre les variables.
3. Création de la figure 3.7 et des sous-graphiques : Une figure avec une disposition en 2x2 est créée à l'aide de la fonction 'subplots()'. Les axes des sous-graphiques sont assignés aux variables 'ax0', 'ax1', 'ax2' et 'ax3'.
4. Scatterplot avec lignes de régression : Pour chaque sous-graphique, un scatterplot est tracé avec une ligne de régression pour une paire spécifique de variables. Les

étiquettes des axes et les titres des sous-graphiques sont définis. La figure III.6 est affichée avec la fonction 'show()'

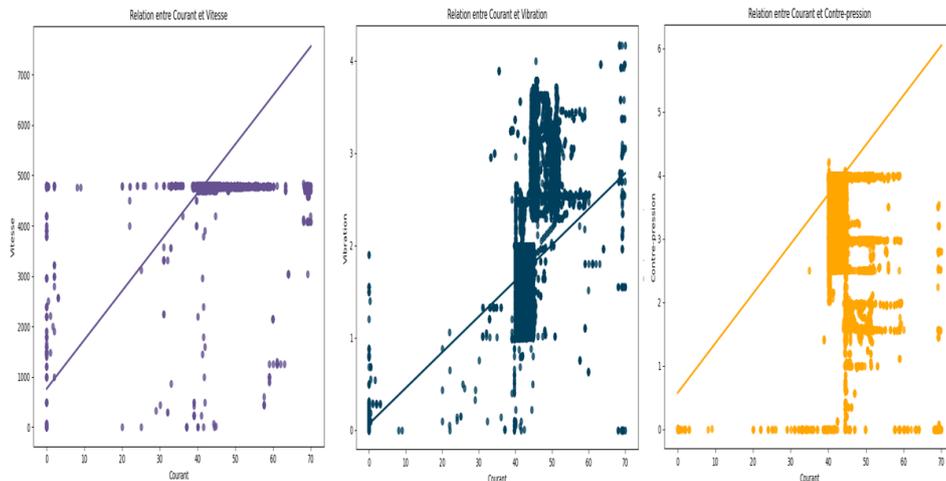


FIG. 3.7 : Visualisation des relations entre les paramètres pertinents

Comme montré dans la figure 3.6 et dans le tableau 3.4 des coefficients de corrélation avec la fonction print() Les paires de variables ayant les corrélations les plus élevées sont :

1. "Courant" et "Vitesse" avec une corrélation de 0.908061
2. "Contre-pression" et "Vitesse" avec une corrélation de 0.786608
3. "Courant" et "Contre-pression" avec une corrélation de 0.714659
4. "Vibration" et "Courant" avec une corrélation de 0.619878

Variable 1	Variable 2	Corrélation
Courant	Vitesse	0.9080610609844675
Vitesse	Courant	0.9080610609844675
Contre-pression	Vitesse	0.7866076160295447
Vitesse	Contre-pression	0.7866076160295447
Contre-pression	Courant	0.7146587396577495
Courant	Contre-pression	0.7146587396577495
Vibration	Courant	0.6198781113955673
Courant	Vibration	0.6198781113955673
Vibration	Vitesse	0.5512823473012085
Vitesse	Vibration	0.5512823473012085
Vibration	Contre-pression	0.24651989185685202
Contre-pression	Vibration	0.24651989185685202

TAB. 3.10 : Tableau de corrélations des paramètres pertinentes

3.3.3 Identification des états d'alerte

Dans cette section, nous utilisons des intervalles prédéfinis tels qu'ils sont établis dans le tableau 3.4 pour classer les différents états de fonctionnement de la machine. Par exemple, si le courant mesuré dépasse 69 ou si la vibration dépasse 3.7, nous considérons

cela comme une situation d’alerte. De même, pour l’état ‘Stand-by’, si le courant est inférieur à 28 ou supérieur à 35, ou si la vibration est inférieure à 1 ou supérieure à 1.8, cela est considéré comme une pré-alerte. Sinon, l’état est considéré comme normal.

Pour illustrer cela, supposons que nous ayons les données suivantes pour une machine : État-machine : Démarrage, Courant : 70, Vibration : 3.5, Contre-pression : 0.1. Selon les intervalles d’alerte définis, le courant de 70 dépasse la plage acceptable de 0 à 69, mais la vibration de 3.5 est dans les limites acceptables de 0 à 3.7. Par conséquent, cet enregistrement serait classé comme une alerte.

donc nous classons les différents états de fonctionnement de la machine en alerte, pré-alerte ou normal, en fonction des valeurs mesurées des paramètres. Cela permet de distinguer les situations qui nécessitent une attention particulière et de prendre des mesures appropriées pour maintenir le bon fonctionnement de la machine. Une fois les états d’alerte identifiés pour chaque ligne du DataFrame, le DataFrame mis à jour est enregistré dans un fichier CSV à l’aide de la fonction ‘to_csv’. Ce processus permet de marquer chaque observation dans le DataFrame avec l’état d’alerte correspondant, ce qui facilite l’analyse ultérieure des données et la prise de décisions en fonction de l’état de la machine.

Analyse de l’évolution des paramètres et de la relation avec l’état d’alerte de la machine en 2021 et 2022

Nous nous concentrons sur l’évolution des paramètres en fonction de l’état d’alerte de la machine pour les années 2021 et 2022, ainsi que sur la visualisation de la relation entre ces paramètres mesurés et l’état d’alerte.

Dans l’implémentation de ce code, nous commençons par effectuer une copie du DataFrame et convertir la colonne “Date” en type datetime en utilisant la fonction `pd.to_datetime()`. Ensuite, nous filtrons les données pour la période spécifiée (2021 et 2022) en utilisant la condition `df[‘year’].between(2021, 2022)`, ce qui nous permet de sélectionner uniquement les enregistrements correspondant à ces années.

Nous créons une figure avec une disposition en 2x2 pour les sous-graphiques en utilisant la fonction `plt.subplots()`. Pour chaque paramètre (courant, vibrations, vitesse et contre-pression), nous utilisons la fonction `sns.lineplot()` pour tracer l’évolution en fonction de l’état d’alerte de la machine. Cette approche nous permet d’analyser visuellement l’évolution de ces paramètres au fil du temps et de déterminer si des tendances ou des modèles significatifs se manifestent en fonction de l’état d’alerte.

De plus, nous utilisons des graphiques de type boîte à moustaches (boxplot) pour visualiser les relations entre l’état d’alerte et les paramètres mesurés tels que les vibrations, le courant, la contre-pression et la vitesse. Par exemple, dans le premier sous-graphique, nous affichons la répartition des valeurs de vibrations pour chaque état d’alerte, ce qui nous permet d’observer les différences potentielles dans les valeurs de vibrations en fonction de l’état d’alerte. Cette approche nous permet de mieux comprendre comment ces paramètres varient en fonction de l’état d’alerte de la machine.

En ajustant l’espacement entre les sous-graphiques à l’aide de la fonction `plt.subplots_adjust(hspace=0.4, wspace=0.4)`, nous améliorons la lisibilité de la figure. Enfin, nous utilisons la fonction `plt.show()` pour afficher la figure contenant à la fois les sous-graphiques

illustrant l'évolution des paramètres et les graphiques en boîte à moustaches montrant la relation entre l'état d'alerte et les paramètres mesurés.

Cette approche d'analyse et de visualisation nous permet de détecter les paramètres les plus pertinents. Elle nous permet également de détecter des tendances, des modèles ou des différences significatives dans les valeurs des paramètres en fonction de l'état d'alerte, ce qui peut être utile pour identifier des problèmes potentiels dans le fonctionnement de la machine et prendre des mesures appropriées en conséquence.

Courant :

Le courant présente une variance significativement plus élevée pour l'état d'alerte par rapport à l'état normal. Cela suggère que les variations de courant peuvent être un indicateur important d'un état d'alerte de la machine.

La figure 3.8 montre l'analyse de l'évolution et de la relation de courant avec l'état d'alerte de la machine en 2021 et 2022:

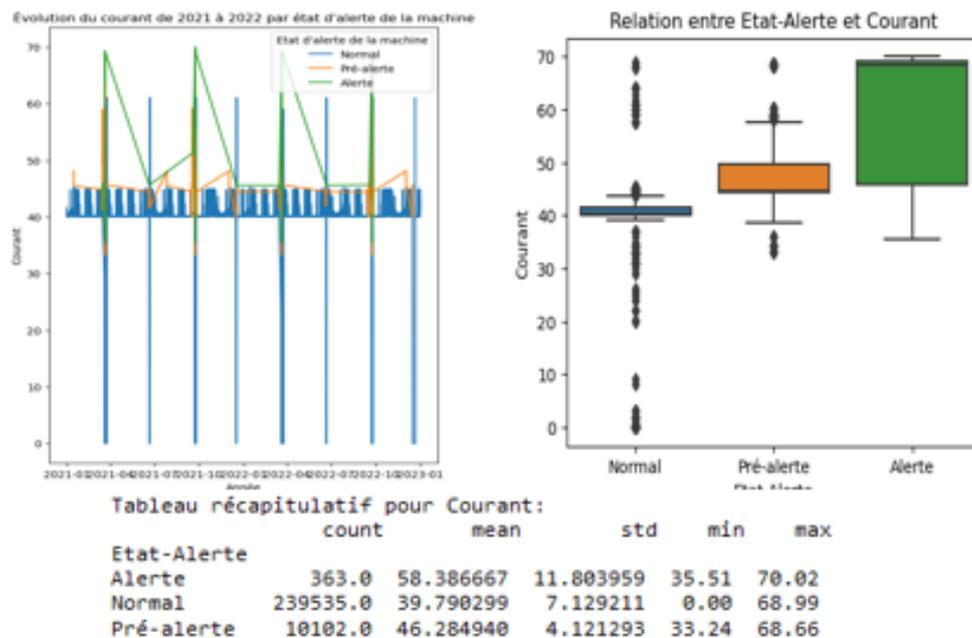


FIG. 3.8 : Analyse de l'évolution et de la relation de courant avec l'état d'alerte de la machine en 2021 et 2022

Vibration :

Les vibrations présentent une variance plus élevée pour l'état d'alerte par rapport à l'état normal. Cela indique une plus grande variabilité des valeurs de vibrations lorsque la machine est en état d'alerte. Par conséquent, les vibrations peuvent être considérées comme un paramètre pertinent pour détecter les états d'alerte. La figure 3.9 représente l'analyse de l'évolution et de la relation de vibration avec l'état d'alerte de la machine en 2021 et 2022.

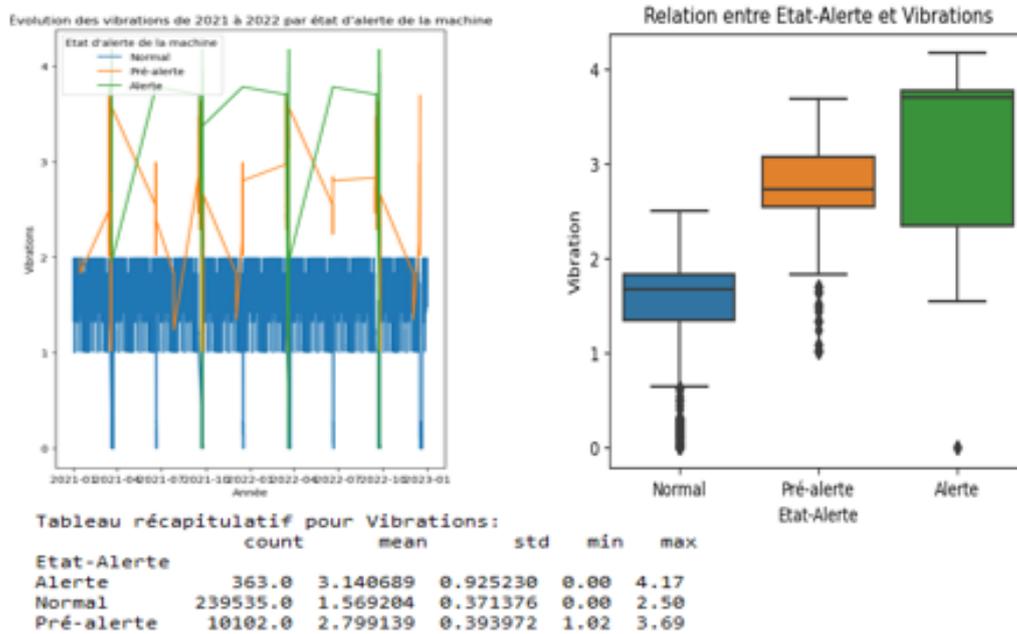


FIG. 3.9 : Analyse de l'évolution et de la relation de vibration avec l'état d'alerte de la machine en 2021 et 2022

Contre-pression :

La contre-pression présente également une variance plus élevée pour l'état d'alerte par rapport à l'état normal. Cela suggère que les variations de contre-pression peuvent être significatives lorsque la machine est en état d'alerte.

La figure 3.10 montre l'analyse de l'évolution et de la relation de contre pression avec l'état d'alerte de la machine en 2021 et 2022:

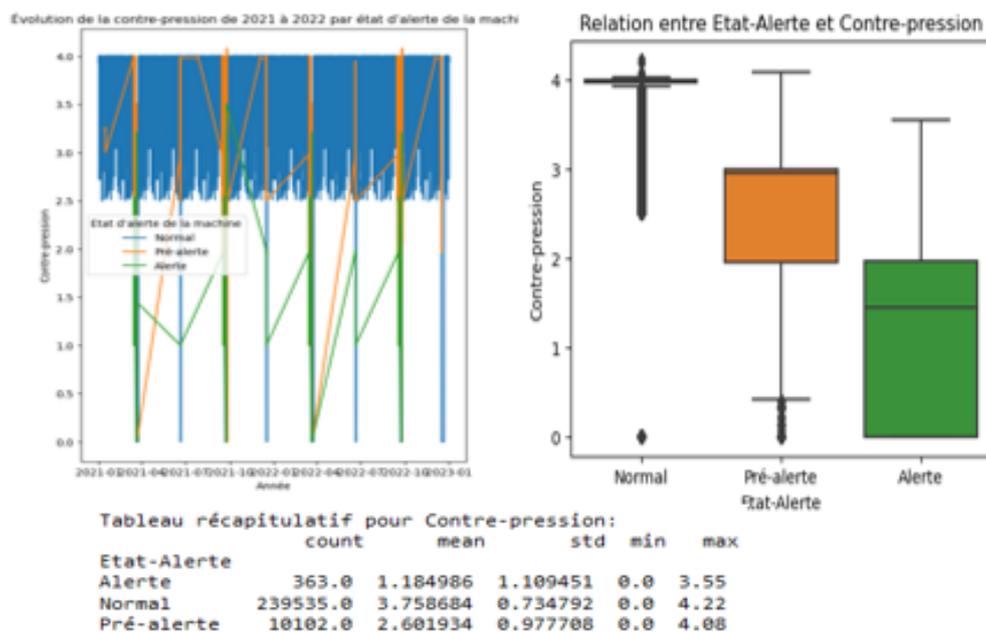


FIG. 3.10 : Analyse de l'évolution et de la relation de contre pression avec l'état d'alerte de la machine en 2021 et 2022

Vitesse :

La vitesse moyenne est presque la même pour tous les états d'alerte, ce qui suggère que la vitesse n'est pas un facteur déterminant pour différencier les états d'alerte. Cependant, la variance de la vitesse est plus élevée pour l'état normal, ce qui indique une plus grande dispersion des valeurs. Cela suggère que les variations de vitesse peuvent être courantes dans l'état normal de fonctionnement de la machine.

La figure 3.8 montre l'analyse de l'évolution et de la relation de la vitesse avec l'état d'alerte de la machine en 2021 et 2022:

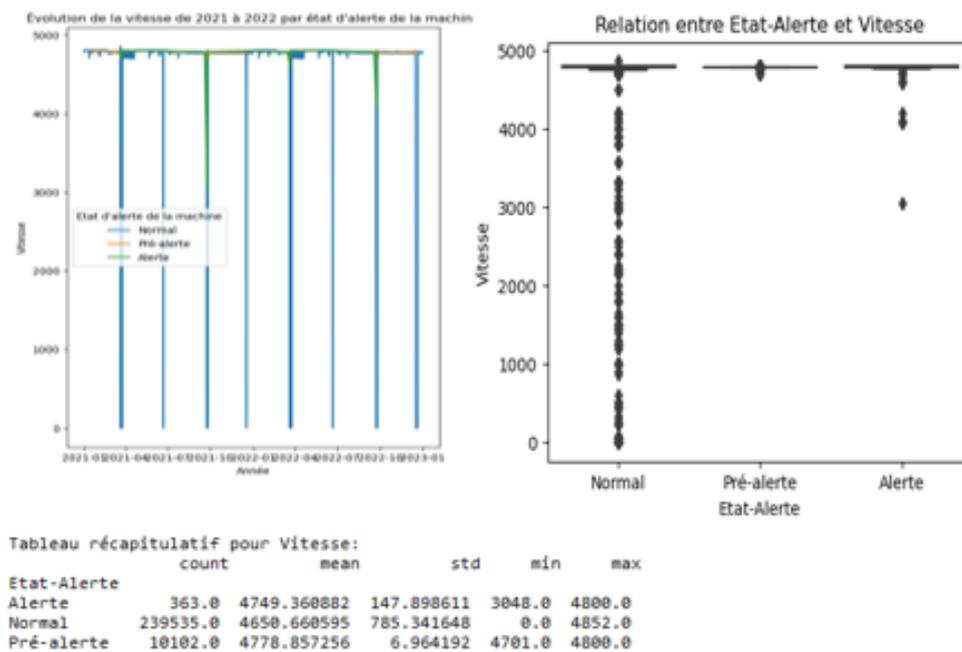


FIG. 3.11 : Analyse de l'évolution et de la relation de vitesse avec l'état d'alerte de la machine en 2021 et 2022

En résumé, l'analyse des variances des paramètres montre que les vibrations, le courant et la contre-pression sont des variables pertinentes pour différencier les états d'alerte de la machine. Ces paramètres présentent des variances plus élevées pour l'état d'alerte, ce qui suggère une plus grande variabilité des valeurs et une sensibilité accrue à des fluctuations. La vitesse, en revanche, présente une variance similaire pour tous les états d'alerte, indiquant qu'elle n'est pas un facteur déterminant pour différencier les états d'alerte.

Identification de la relation entre les paramètres les plus pertinents pour détecter les états d'alerte

Nous nous concentrons sur l'identification de la relation entre les paramètres mesurés (vibrations, courant, contre-pression et vitesse) et l'état d'alerte de la machine.

Visualisation des relations en utilisant des sous-graphiques en 3D avec des points tracés pour les données en pré-alerte et en alerte :

Une explication étape par étape de l'implémentation du code :

1. Filtrer les données : Le code commence par le filtrage des données pour ne conserver que les observations en "Pré-alerte" et en "Alerte" à l'aide de la condition `data["Etat-Alerte"] == "Pré-alerte"` et `data["Etat-Alerte"] == "Alerte"`. Les données filtrées sont ensuite assignées aux variables `data_prealerte` et `data_alerte`, respectivement.
2. Créer la figure et ajouter les sous-graphiques en 3D : une nouvelle figure est créée en utilisant `fig = plt.figure(figsize=(18, 12))`. puis on va ajouter les sous-graphiques en 3D , Le code ajoute six sous-graphiques en 3D à la figure à l'aide de la fonction `fig.add_subplot()`. Chaque sous-graphique est spécifié par trois chiffres : le nombre de lignes, le nombre de colonnes et l'index du sous-graphique. Par exemple, `ax1 = fig.add_subplot(231, projection='3d')` crée un sous-graphique dans la première position (en haut à gauche) d'une disposition en 2x3 (2 lignes, 3 colonnes) de sous-graphiques.
3. Tracer les points : pour chaque sous-graphique, le code utilise la méthode `scatter()` pour tracer les points en 3D. Les données utilisées pour chaque axe (x, y, z) sont extraites des variables `data_prealerte` et `data_alerte`.
4. Afficher les graphiques en 3D : enfin, la fonction `plt.show()` est utilisée pour afficher les graphiques en 3D comme montre la figure 3.12 et figure 3.13

Relation entre Vibration, Courant et Contre-pression (Pré-alerte)

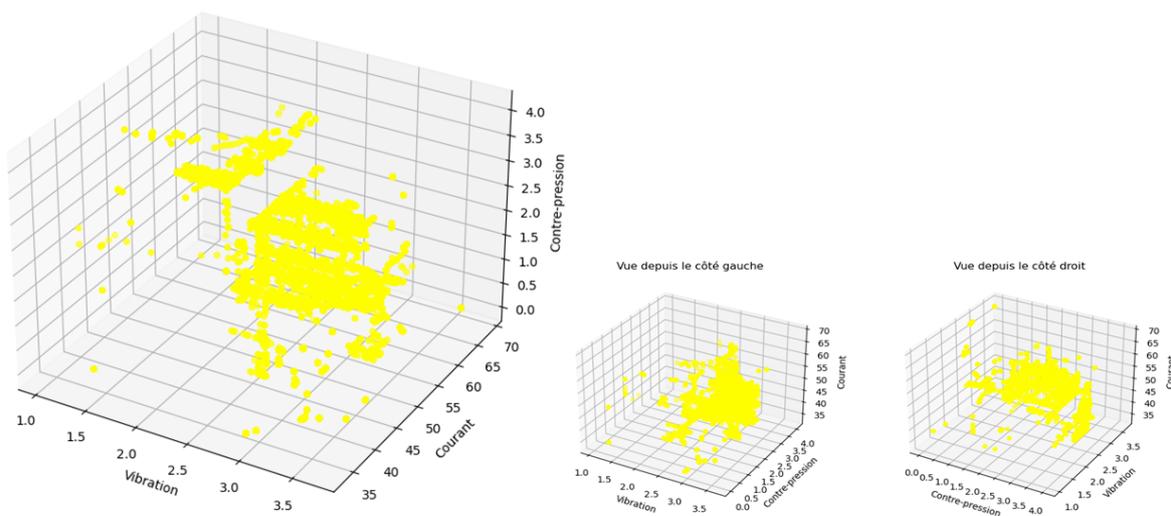


FIG. 3.12 : Graphique en 3D avec des sous-graphiques et des points tracés pour la visualisation des relations des données en Pré-alerte

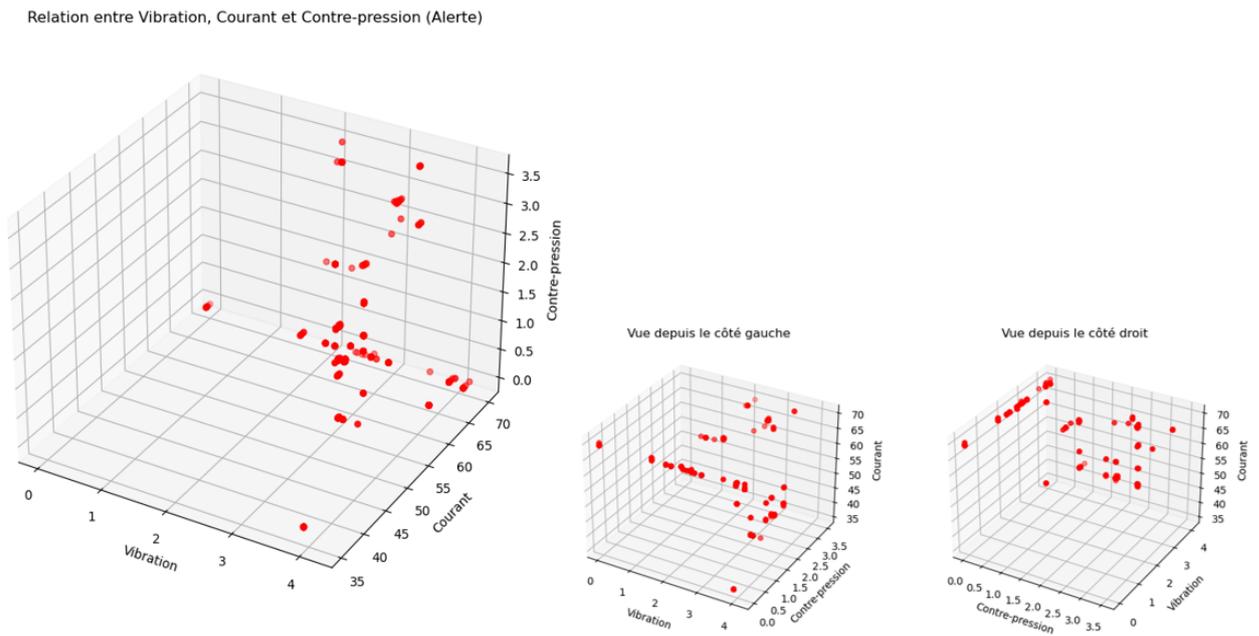


FIG. 3.13 : Graphique en 3D avec des sous-graphiques et des points tracés pour la visualisation des relations des données en Alerte

Visualisation des relations à l'aide de diagrammes en nuage de points avec une barre de couleur : Ce code utilise la fonction `plt.scatter()` pour créer des diagrammes en nuage de points. La fonction `plt.scatter()` prend les valeurs de Vibration et de Courant comme données d'entrée et utilise la couleur des points pour représenter les valeurs de Contre-pression. La fonction `plt.colorbar()` ajoute une barre de couleur à côté du graphique pour indiquer les valeurs de Contre-pression. Enfin, la fonction `plt.show()` est utilisée pour afficher les graphiques à l'écran comme montre la figure 3.12 (préalerte) et la figure 3.13 (Alerte).

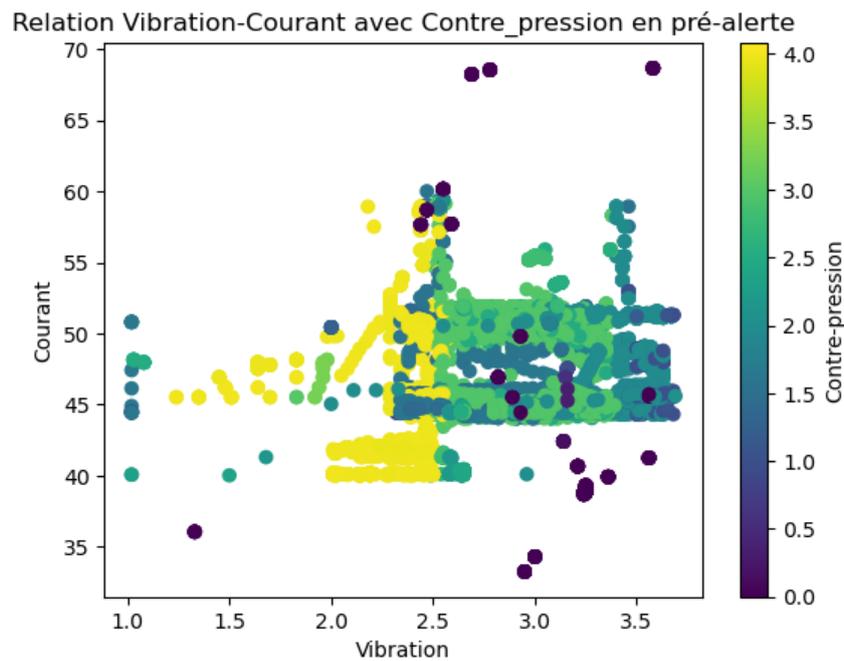


FIG. 3.14 : Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en pré-alerte

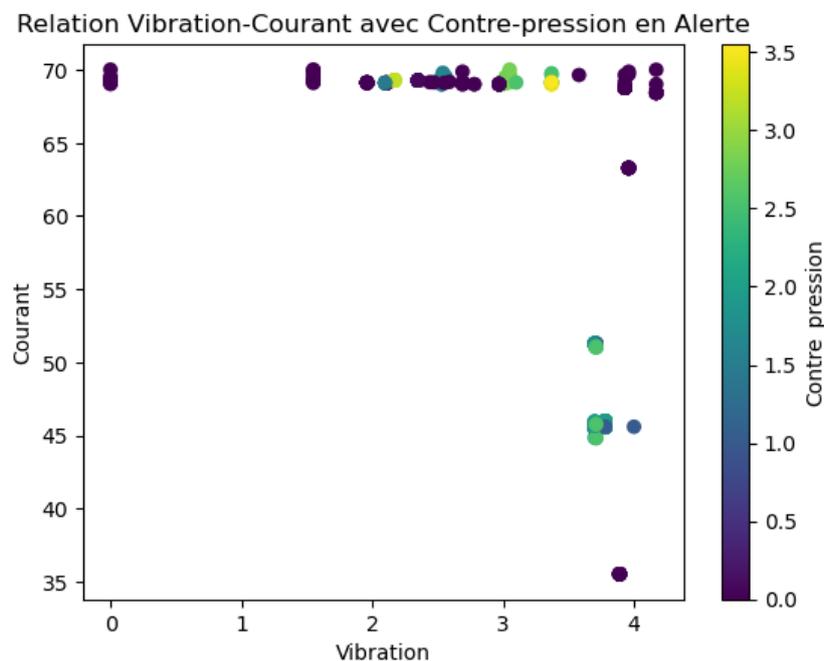


FIG. 3.15 : Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte

Les graphiques en 3D, tels que la Figure 3.12 et la Figure 3.13 ainsi les diagrammes de nuages dans les figures 3.12 et 3.13 mettent en évidence une corrélation claire entre les états de pré-alerte et d’alerte, avec une répartition des points qui se regroupent lorsque les valeurs de vibrations et de courant sont élevées, tandis que la contre-pression est plus basse. Cela suggère que lorsque les vibrations et le courant dépassent un seuil spécifique,

associés à une contre-pression réduite, la machine tend à se trouver dans un état d'alerte.

4- Évolution et comparaison des états d'alerte au fil du temps

Tout d'abord nous nous concentrons sur l'analyse de l'évolution des états d'alertes au cours de temps , Pour commencer, nous extrayons les données nécessaires pour notre analyse, à savoir les dates et les états d'alerte correspondants. Ensuite, nous définissons les couleurs associées à chaque état d'alerte (normal, pré-alerte, alerte) à l'aide du dictionnaire de couleurs. Nous créons un graphique de dispersion en utilisant la fonction `plt.scatter()`, où les dates sont représentées sur l'axe des x et les états d'alerte sur l'axe des y. Les points sont colorés en fonction de l'état d'alerte correspondant en utilisant la liste des couleurs définie précédemment. Enfin, nous utilisons la fonction `plt.show()` pour afficher le graphique comme montre la figure 3.16 .

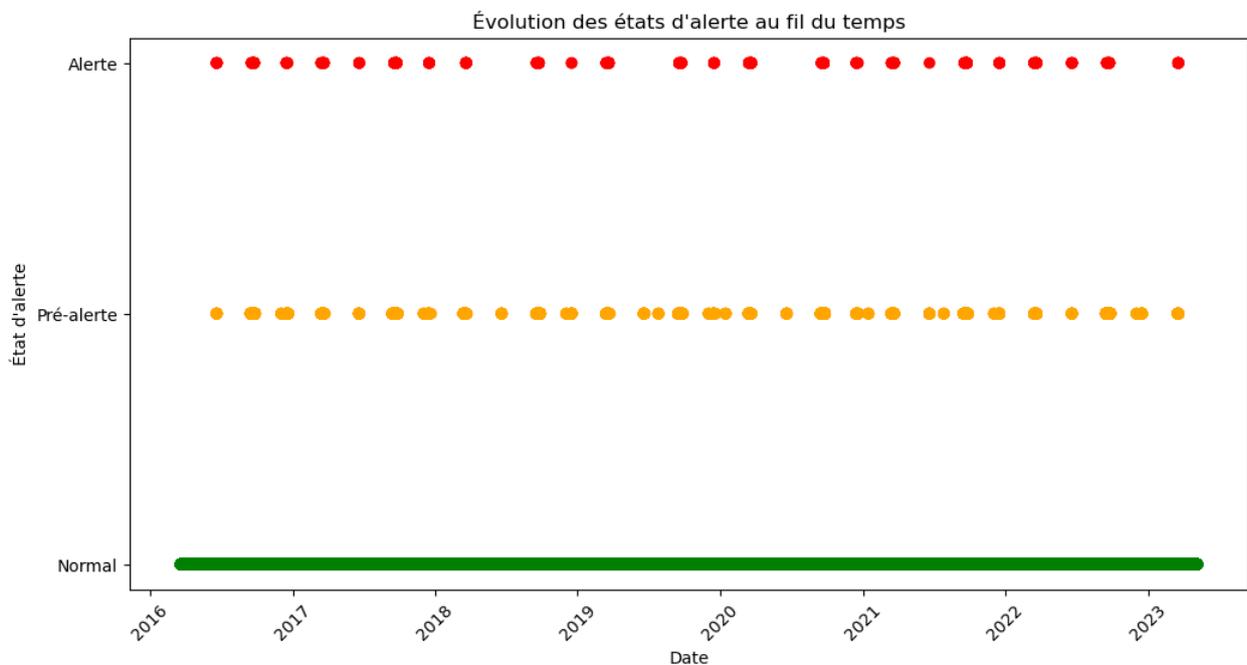


FIG. 3.16 : Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte

D'après la distribution du nuage de points dans ce graphe, on peut observer que l'état "Normal" présente une proportion plus élevée de points par rapport aux autres états d'alerte. Ensuite, l'état de "Pré-alerte" se situe au deuxième niveau en terme de distribution, tandis que l'état "Alerte" affiche un pourcentage plus bas, indiquant une diminution de sa fréquence. Afin de déterminer les pourcentages exacts de chaque état d'alerte, nous effectuons une comparaison entre les années 2019 et 2022 en utilisant des diagrammes circulaires. Pour cela, nous commençons par filtrer les données en fonction des dates correspondantes à chaque année spécifique. Ensuite, nous calculons les pourcentages de chaque état d'alerte dans chaque année filtrée. Pour chaque année, nous utilisons la fonction `pie` pour tracer un diagramme circulaire qui représente la répartition de l'état d'alerte. Les pourcentages, les étiquettes, les couleurs et les décalages de secteur sont

spécifiés pour chaque diagramme, permettant ainsi une visualisation claire et précise de la répartition des différents états d'alerte. Enfin, nous utilisons la fonction `plt.show()` pour afficher les diagrammes circulaires qui permettent de comparer les états d'alerte entre les années 2019 et 2022, fournissant ainsi une vision globale de l'évolution de ces états sur cette période comme montre la figure 3.17 .

Comparaison de l'État d'Alerte entre 2019 et 2022

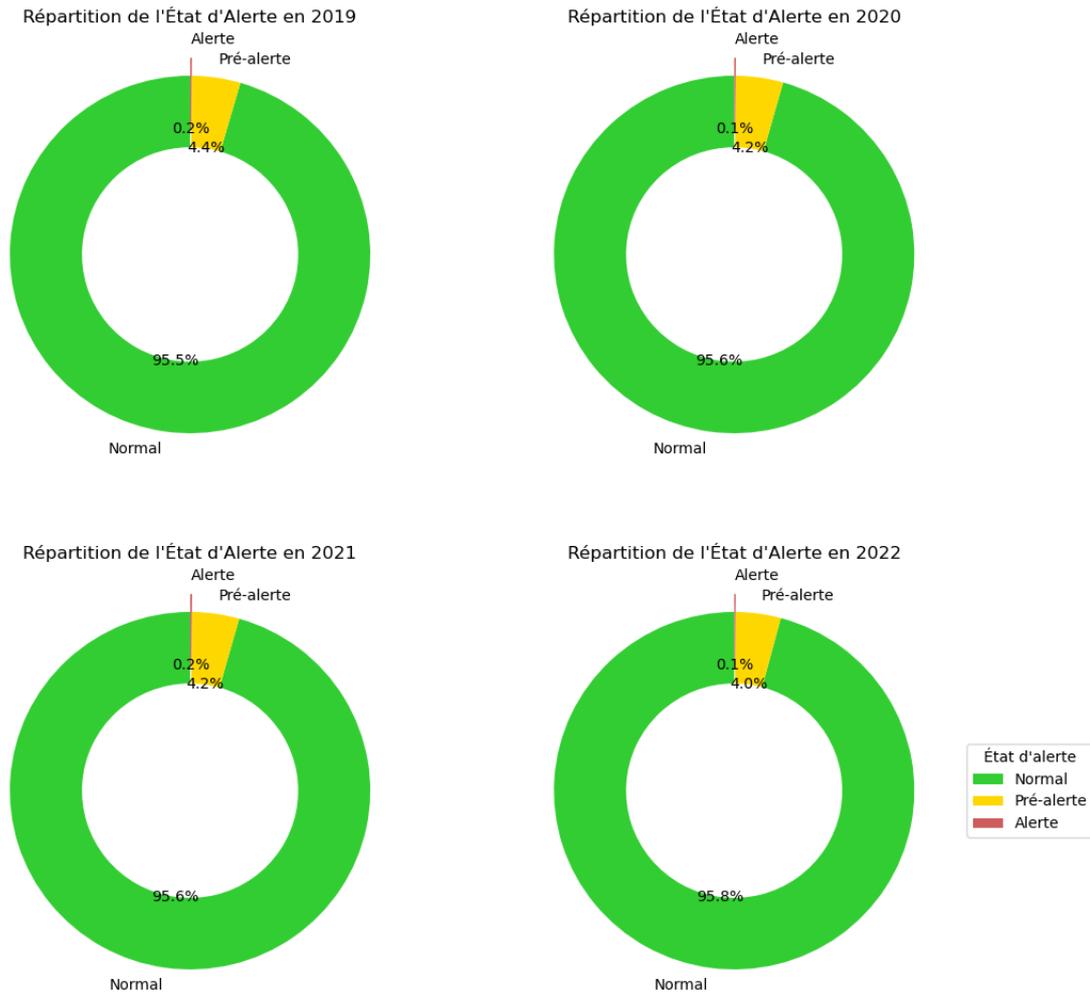


FIG. 3.17 : Diagramme en nuage de points avec barre de couleur pour la visualisation des relations en Alerte.

les résultats de cette comparaison apparaissent dans le tableau 3.11 :

État d'alerte	Pourcentage en 2019	Pourcentage en 2020	\
0 Normal	95.490056	95.616563	
1 Pré-alerte	4.358277	4.235039	
2 Alerte	0.151667	0.148398	
	Pourcentage en 2021	Pourcentage en 2022	
0	95.607383	95.824868	
1	4.226642	4.040635	
2	0.165975	0.134497	

TAB. 3.11 : Comparaison des États d'Alerte entre les Années 2019 et 2022

Les résultats montrent des pourcentages relativement stables pour les états d'alerte "Normal" sur la période. Les états "Pré-alerte" et "Alerte" restent faibles avec de légères variations. La surveillance régulière et les mesures de prévention semblent efficaces. Les résultats révèlent une diminution progressive des états d'alerte critiques au fil du temps. Cela suggère une amélioration de la fiabilité et de la stabilité du système, avec des mesures de prévention plus efficaces.

Pour obtenir des résultats plus précis en termes de pourcentage et d'occurrence, nous avons utilisé la méthode suivante. Nous avons tracé le graphique de l'évolution de l'état d'alerte en fonction de la date en utilisant la fonction 'countplot' de la bibliothèque seaborn (importée sous le nom de sns). Cette fonction compte le nombre d'occurrences de chaque état d'alerte et les représente graphiquement. Ensuite, nous avons calculé le pourcentage d'occurrence de chaque état d'alerte par rapport au nombre total d'occurrences. Nous avons affiché ces pourcentages en utilisant la fonction text. Cette approche nous permet d'obtenir une visualisation plus précise des proportions de chaque état d'alerte dans le graphique. Enfin, pour afficher le graphique complet, nous avons utilisé la fonction plt.show(). Vous pouvez retrouver ce graphique dans la figure 3.18.

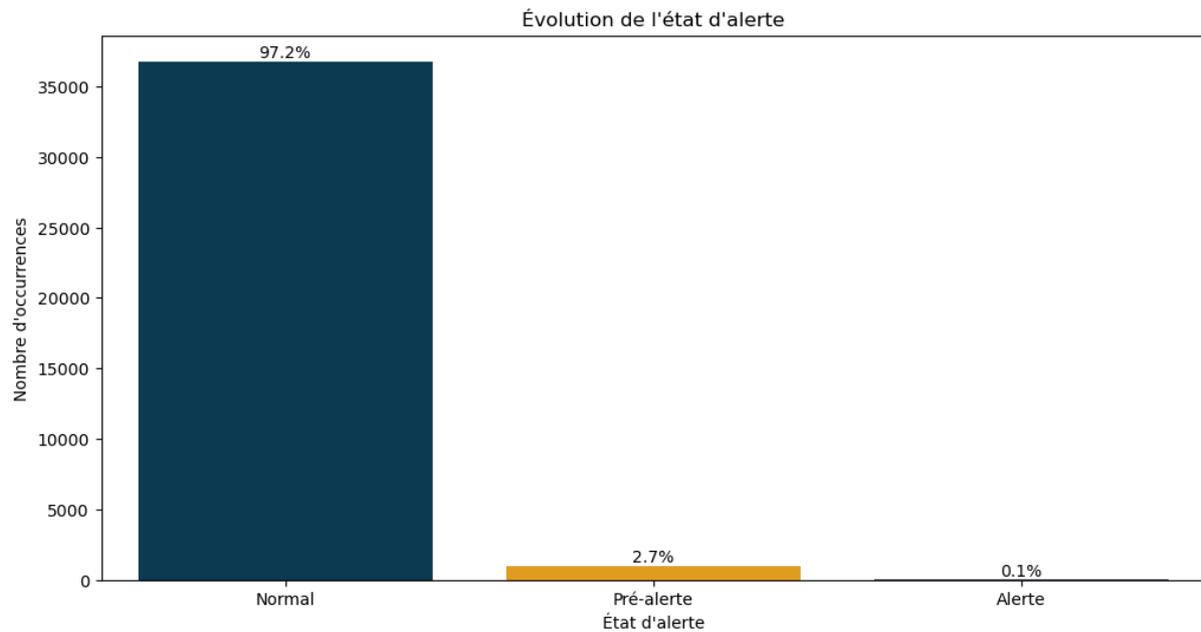


FIG. 3.18 : Évolution de l'état d'alerte au fil du temps (Occurrences et Pourcentages)

3.3.4 Classification des états d'alerte à l'aide de modèles d'ensemble learning

Dans cette phase de notre démarche, nous avons employé des techniques d'apprentissage automatique avancées, plus spécifiquement des méthodes d'ensemble learning, dans le but de classifier en temps réel les états d'alerte actuels de la machine. Pour y parvenir, nous avons entraîné des modèles prédictifs en utilisant les données historiques collectées, en mettant l'accent sur les paramètres les plus pertinents que nous avons identifiés, et en les associant aux états d'alerte correspondants. En évaluant les résultats des matrices de confusion et des rapports de classification, nous serons en mesure de déterminer le modèle le plus performant à utiliser pour les prévisions et la détection des états d'alerte critiques à l'avenir.

Toutefois, lorsqu'une défaillance survient, il est essentiel d'identifier avec précision sa source. À cette fin, nous réalisons des prédictions sur les paramètres les plus pertinents en utilisant les trois modèles d'ensemble learning. Le modèle qui démontre les meilleures performances est sélectionné pour faciliter la prévention future et la localisation de la panne.

Cette approche nous procure plusieurs avantages. D'une part, nous sommes en mesure de déterminer le meilleur modèle à utiliser pour détecter et prévoir les pannes avant qu'elles ne surviennent. D'autre part, nous disposons également du meilleur modèle pour localiser cette panne spécifique. Cette démarche nous permet d'optimiser nos stratégies de détection, de prévention et de localisation des pannes, renforçant ainsi notre capacité à maintenir un niveau élevé de performance et à minimiser les interruptions non planifiées.

Classification des états d'alerte au fil du temps

Cette implémentation utilise des modèles de classification (Random Forest, Gradient Boosting et XGBoost) pour classifier l'état d'alerte d'un système en utilisant des caractéristiques spécifiques. L'objectif est de comparer ces modèles et de déterminer le meilleur en termes de performances et de précision.

Les données sont divisées en ensembles d'entraînement et de test à l'aide de la fonction 'train_test_split' de scikit-learn, avec un ratio de 80% pour l'entraînement et 20% pour les tests. Les caractéristiques et la variable cible sont séparées pour chaque ensemble.

Les modèles sont ensuite instanciés et entraînés sur les données d'entraînement à l'aide de la méthode 'fit'. Ils sont ensuite utilisés pour classifier l'état d'alerte sur les données de test en utilisant la méthode 'predict'. Les classifications de chaque modèle sont comparées pour évaluer leur performance et précision.

Différentes mesures sont utilisées pour évaluer les résultats. Une matrice de confusion est créée pour analyser les classifications correctes et incorrectes pour chaque classe d'état d'alerte. Un rapport de classification est également généré, fournissant des mesures de précision, de rappel et de F1-score pour chaque classe, ainsi que des mesures agrégées pour l'ensemble du modèle.

La comparaison des valeurs réelles et classifiées de l'état d'alerte avec le modèle Random Forest est présentée dans la figure 3.19, tandis que la matrice de confusion correspondante est présentée dans la figure 3.20. Le rapport de classification pour ce modèle est résumé dans le tableau 3.12.

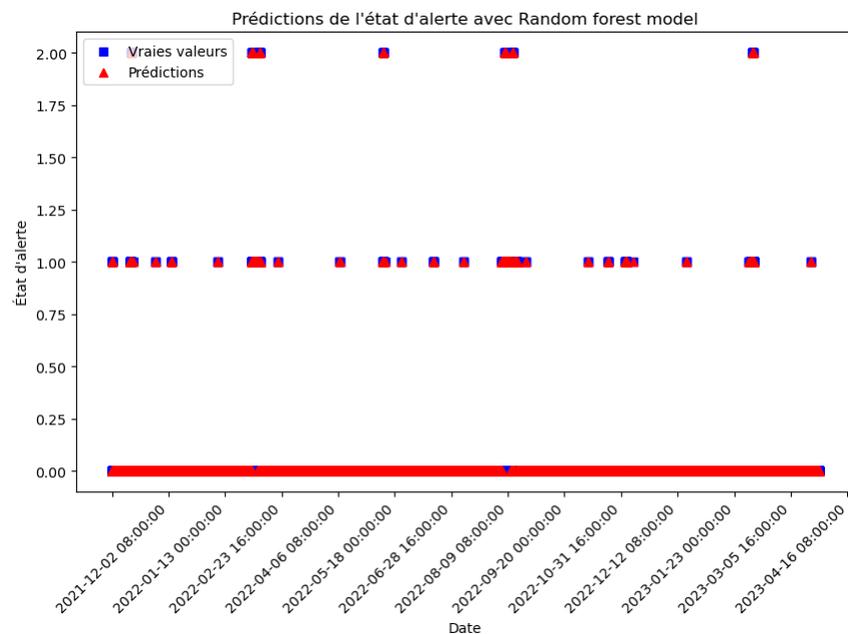


FIG. 3.19 : Prédictions de l'état d'alerte avec Random forest model

Random forest classifier

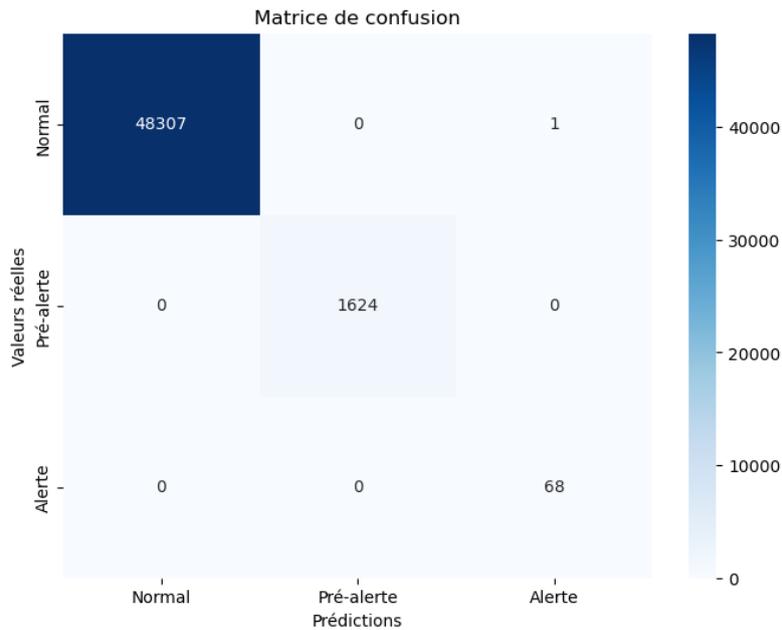


FIG. 3.20 : Matrice de confusion de prédictions de l'état d'alerte avec Random forest model

```

Rapport de classification :
      precision    recall  f1-score   support

 Normal         1.00      1.00      1.00     48308
 Pré-alerte     1.00      1.00      1.00     1624
 Alerte         0.99      1.00      0.99        68

 accuracy              1.00     50000
 macro avg             1.00      1.00      1.00     50000
 weighted avg          1.00      1.00      1.00     50000

 Accuracy: 0.99998
 Precision: 0.9999802898550725
 Recall: 0.99998
 F1 Score: 0.9999800728891972
    
```

TAB. 3.12 : Rapport de classification pour le moodel de random forest

Le modèle Random Forest présente des performances remarquables avec une précision, un rappel et un F1-score de 1.00 pour les classes "Normal" et "Pré-alerte". Pour la classe "Alerte", la précision est de 0.99, mais le rappel est de 1.00. L'accuracy globale du modèle atteint 0.99998, indiquant une prédiction correcte de l'état d'alerte dans la grande majorité des cas.

Gradient boosting classifier La comparaison des valeurs réelles et classifiées de l'état d'alerte avec le modèle Gradient Boosting est présentée dans la figure 3.21, tandis que la matrice de confusion correspondante est présentée dans la figure 3.22. Le rapport de classification pour ce modèle est résumé dans le tableau 3.13.

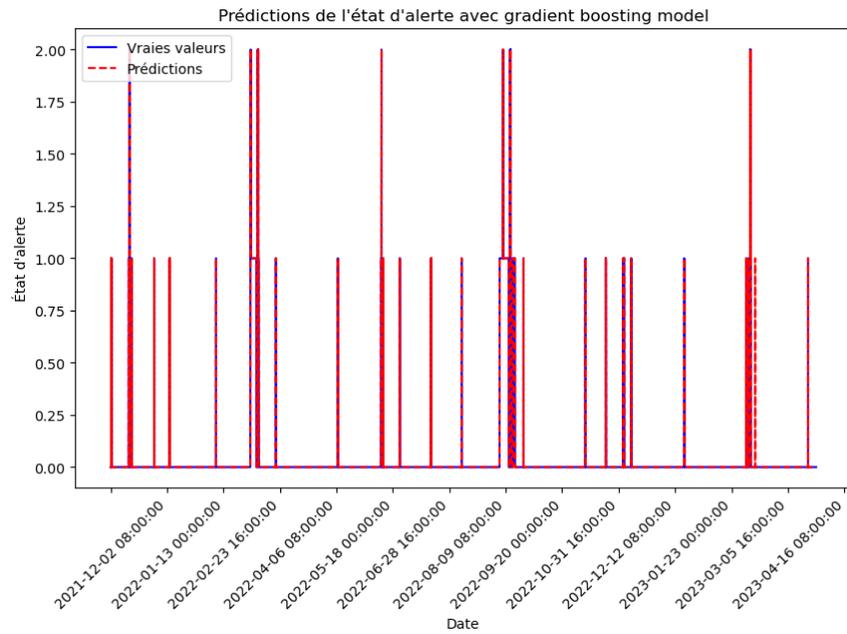


FIG. 3.21 : Prédictions de létat d'alerte avec Gradientboosting model

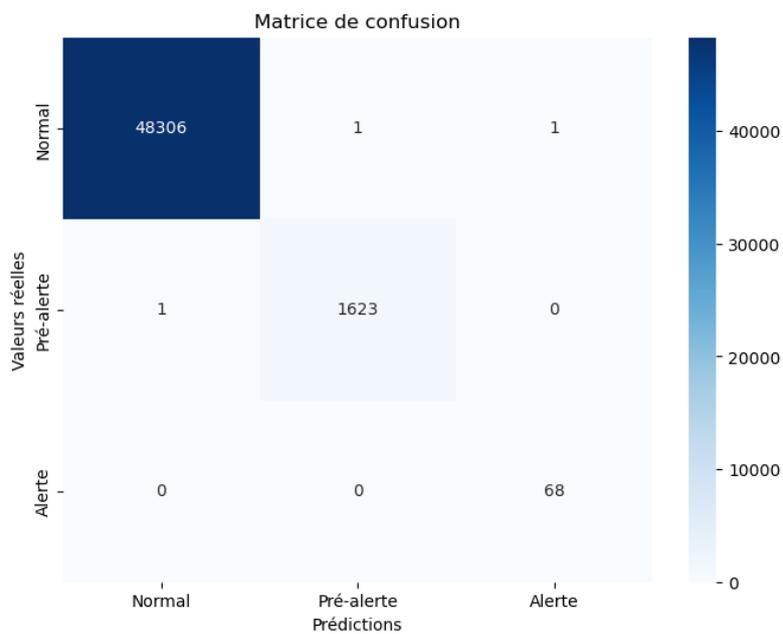


FIG. 3.22 : Matrice de confusion de prédictions de létat d'alerte avec Gradient boosting model

```

Rapport de classification :
      precision    recall  f1-score   support

   Normal         1.00      1.00      1.00     48308
  Pré-alerte      1.00      1.00      1.00     1624
    Alerte        0.99      1.00      0.99         68

 accuracy         1.00         1.00         1.00     50000
  macro avg        0.99         1.00         1.00     50000
  weighted avg     1.00         1.00         1.00     50000

Accuracy: 0.99994
Precision: 0.999940289441054
Recall: 0.99994
F1 Score: 0.99994007268219
    
```

TAB. 3.13 : Rapport de classification pour le moedel de gradient boosting forest

Le modèle Gradient Boosting présente également des performances exceptionnelles avec une précision, un rappel et un F1-score de 1.00 pour les classes "Normal" et "Pré-alerte". Pour la classe "Alerte", la précision est de 0.99, indiquant quelques prédictions incorrectes, mais le rappel est de 1.00, ce qui signifie que tous les exemples réels de la classe ont été correctement capturés. L'accuracy globale du modèle est élevée, atteignant 0.99994, ce qui indique une prédiction correcte de l'état d'alerte dans la grande majorité des cas

XGboosting classifier La comparaison des valeurs réelles et classifiées de l'état d'alerte avec le modèle XGboosting est présentée dans la figure 3.23, tandis que la matrice de confusion correspondante est présentée dans la figure 3.24. Le rapport de classification pour ce modèle est résumé dans le tableau 3.14.

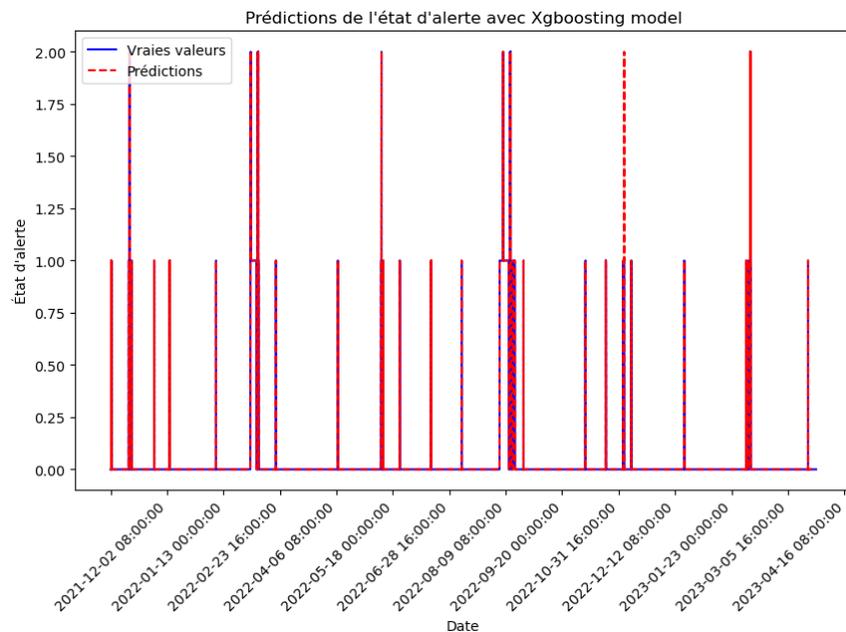


FIG. 3.23 : Prédictions de létat d'alerte avec XGboosting model

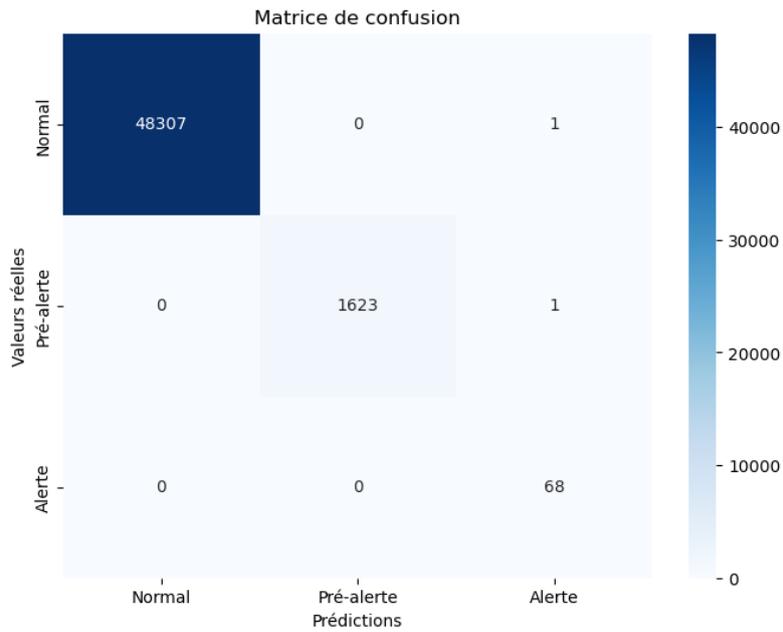


FIG. 3.24 : Matrice de confusion de prédictions de l'état d'alerte avec XGboosting model

```

Rapport de classification :
      precision    recall  f1-score   support

   Normal         1.00      1.00      1.00     48308
  Pré-alerte         1.00      1.00      1.00     1624
    Alerte         0.97      1.00      0.99         68

 accuracy          1.00          1.00          1.00     50000
 macro avg         0.99          1.00          1.00     50000
 weighted avg      1.00          1.00          1.00     50000

Accuracy: 0.99996
Precision: 0.9999611428571429
Recall: 0.99996
F1 Score: 0.999960286671803
    
```

TAB. 3.14 : Comparaison des États d'Alerte entre les Années 2019 et 2022

Le modèle XGBoost présente également des performances remarquables avec une précision, un rappel et un F1-score de 1.00 pour les classes "Normal" et "Pré-alerte". Pour la classe "Alerte", la précision est légèrement inférieure à 1.00 avec 0.97, ce qui indique quelques prédictions incorrectes pour cette classe. Cependant, le rappel est de 1.00, ce qui signifie que tous les exemples réels de la classe "Alerte" ont été correctement identifiés. L'accuracy globale du modèle est élevée, atteignant 0.99996, indiquant une prédiction correcte de l'état d'alerte dans la grande majorité des cas.

Comparaison des performances des modèles la figure 3.25 montre la comparaison des performance des modèles sous forme d'une graphique et la tableau 3.15 montre les résultats de comparaison des performance de ces modèles

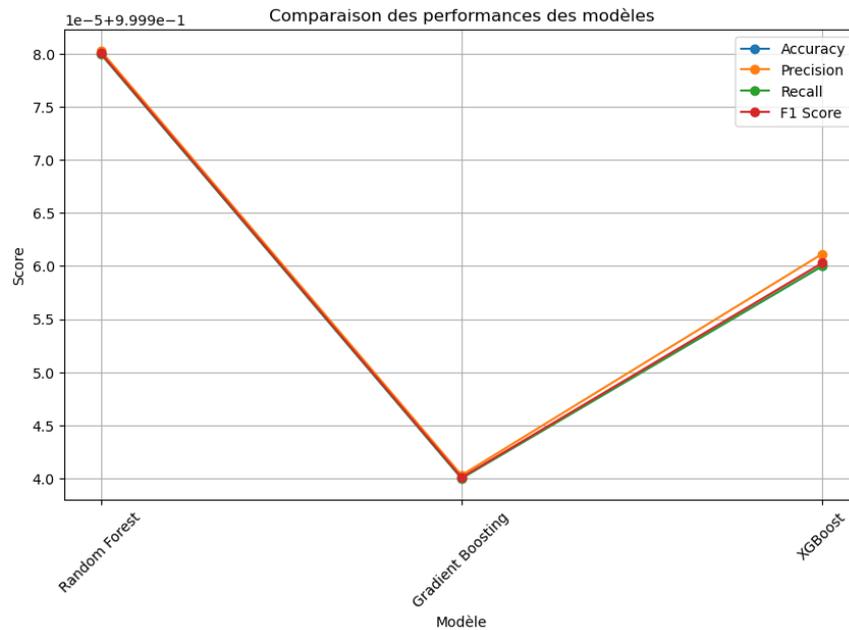


FIG. 3.25 : Comparaison des performances des modèles

	Modèle	Accuracy	Precision	Recall	F1 Score
0	Random Forest	0.99998	0.999980	0.99998	0.99998
1	Gradient Boosting	0.99994	0.999940	0.99994	0.99994
2	XGBoost	0.99996	0.999961	0.99996	0.99996

Le meilleur modèle est : Random Forest

TAB. 3.15 : Résultats de Comparaison des performances des modèles

Les résultats montrent que tous les modèles, à savoir Random Forest, Gradient Boosting et XGBoost, ont des performances très élevées avec une précision, un rappel et un F1-score de 1.00 pour toutes les classes. Cela indique que tous les modèles ont réussi à prédire correctement l'état d'alerte dans la grande majorité des cas.

Cependant, lorsqu'on compare les performances spécifiques des modèles, on constate que le modèle Random Forest a légèrement surpassé les autres. Il présente une précision, un rappel et un F1-score de 0.999980, ce qui est légèrement plus élevé que les valeurs des autres modèles.

Par conséquent, sur la base de ces résultats, nous pouvons conclure que le modèle Random Forest offre les meilleures performances et la plus grande précision parmi les trois modèles évalués. Il est donc recommandé d'utiliser le modèle Random Forest pour prédire l'état d'alerte du système en se basant sur les caractéristiques de courant, de vibration et de contre-pression.

3.3.5 Prédiction de paramètres pertinents

Après la détection des états d’alerte critique de la machine et par l’utilisation des classifications effectuées, il devient nécessaire de détecter les sources potentielles de pannes. Pour ce faire, il est essentiel de surveiller d’autres paramètres pertinents qui ont une influence sur l’occurrence des pannes. Dans cette perspective, nous utilisons des modèles d’ensemble learning pour effectuer des prédictions de ces paramètres afin de détecter les changements anormaux et les tendances indésirables.

Les modèles d’ensemble learning, tels que la régression, sont utilisés pour prédire l’évolution de ces paramètres. Cela nous permet d’identifier les variations inhabituelles ou les schémas anormaux qui pourraient indiquer des problèmes émergents. En anticipant les changements dans ces paramètres, nous sommes en mesure de prendre des mesures proactives pour éviter les défaillances et réduire les temps d’arrêt imprévus. Dans les Figures 3.26, 3.27 et 3.28, nous avons comparé les prédictions des trois paramètres pertinents (courant, vibration et contre-pression) pour chaque modèle d’ensemble learning. La Figure 3.26 montre les prédictions de courant, tandis que la Figure 3.27 présente les prédictions de vibration au cours de la même période. Enfin, la Figure 3.28 illustre l’évolution du contre-pression .

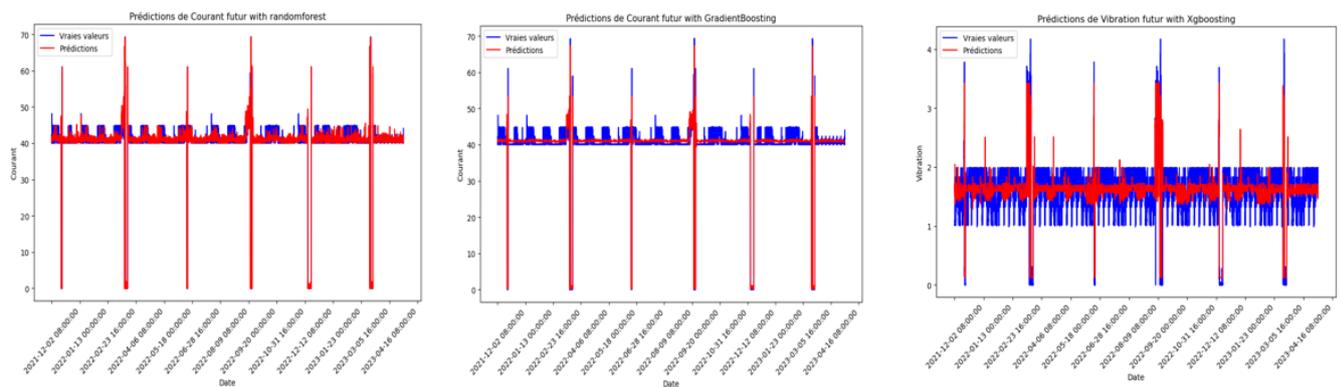


FIG. 3.26 : Prédiction de courant

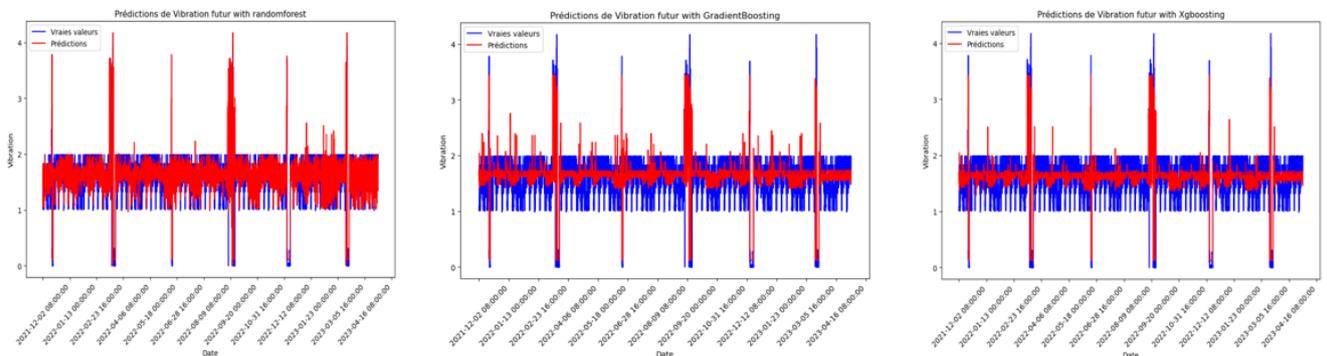


FIG. 3.27 : Prédiction de vibration

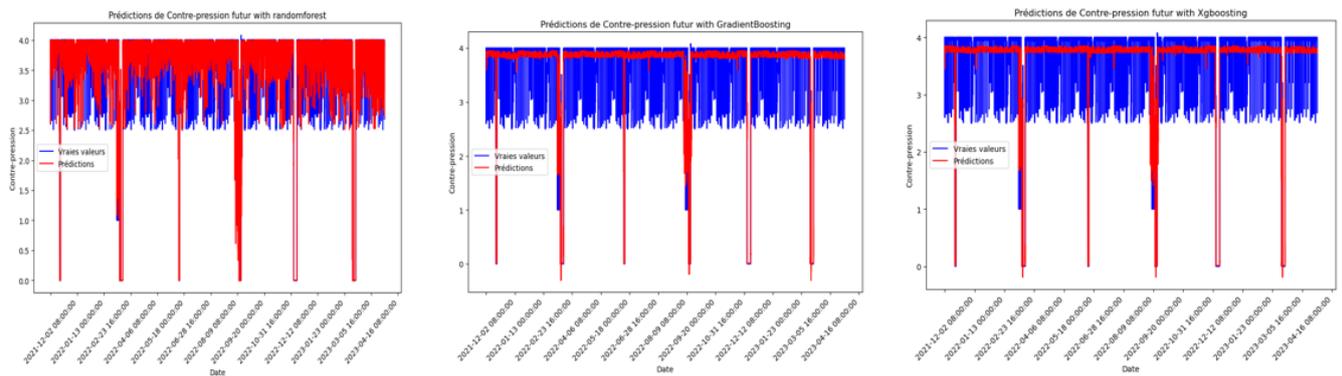


FIG. 3.28 : Prédiction de contre pression

Comparaison des performances de trois modèles

Cette implémentation réalise une évaluation et une comparaison des performances de trois modèles de régression (Random Forest, Gradient Boosting et XGBoost) en utilisant différentes combinaisons de caractéristiques et de variable cible. Les modèles sont entraînés, des prédictions sont effectuées sur les données de test, et des métriques d'évaluation telles que l'erreur absolue moyenne (MAE), l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R^2) sont calculées. Les résultats sont enregistrés dans un DataFrame et affichés sous forme de tableau statistique, comme illustré dans le tableau 3.16. De plus, un graphique comparatif est présenté dans la figure 3.29. Le meilleur modèle est identifié en fonction de la métrique choisie, dans cet exemple, la MAE, et ses détails sont affichés.

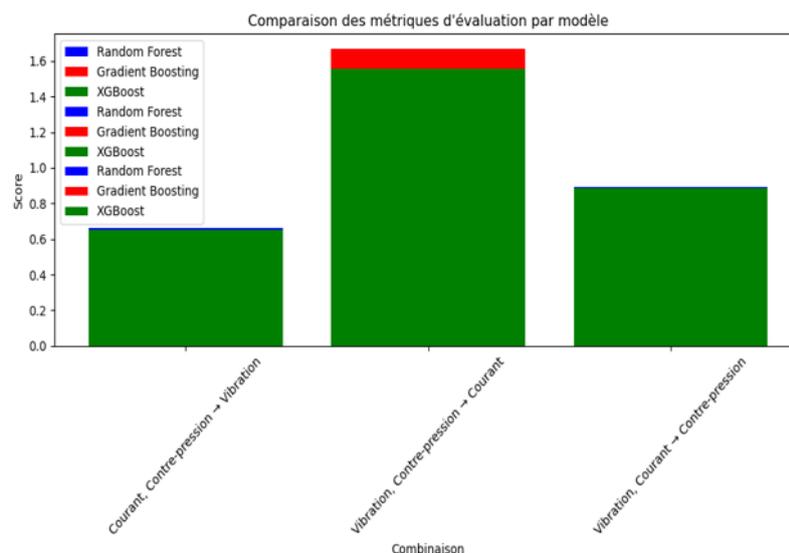


FIG. 3.29 : Graphique comparatif des métriques d'évaluation pour chaque modèle

L'analyse des résultats montre les performances des différents modèles de régression pour chaque combinaison de caractéristiques et de variable cible. Le tableau 3.16 montre les résultats de ce graphique :

	Combinaison	MAE	RMSE	R ²	Model
0	Courant, Contre-pression → Vibration	0.207031	0.263190	0.661861	RF
1	Courant, Contre-pression → Vibration	0.227262	0.278730	0.620752	GB
2	Courant, Contre-pression → Vibration	0.217494	0.266224	0.654019	XGBoost
3	Vibration, Contre-pression → Courant	0.959796	1.545103	0.960390	RF
4	Vibration, Contre-pression → Courant	1.057178	1.668811	0.953793	GB
5	Vibration, Contre-pression → Courant	0.999787	1.553875	0.959938	XGBoost
6	Vibration, Courant → Contre-pression	0.136557	0.269842	0.892620	RF
7	Vibration, Courant → Contre-pression	0.168633	0.289777	0.876168	GB
8	Vibration, Courant → Contre-pression	0.157297	0.276406	0.887332	XGBoost

TAB. 3.16 : Tableau de résultats des métriques d'évaluation par modèle et combinaison de variables

Explication des résultats de chaque colonne du tableau 3.16

1. Combinaison : Cette colonne indique les combinaisons de caractéristiques et de variable cible utilisées dans chaque modèle.
2. MAE (Mean Absolute Error) : Cette métrique mesure l'erreur absolue moyenne entre les valeurs prédites et les valeurs réelles. Un score de MAE plus bas indique une meilleure performance. Dans ce cas, le meilleur modèle est RF (Random Forest) avec une MAE de 0.14, suivi par XGBoost avec une MAE de 0.16 et GB (Gradient Boosting) avec une MAE de 0.17.
3. RMSE (Root Mean Squared Error) : Cette métrique mesure l'écart quadratique moyen entre les valeurs prédites et les valeurs réelles. Elle est similaire à la MAE, mais donne plus de poids aux erreurs importantes. Les scores de RMSE suivent la même tendance que la MAE, où RF obtient le meilleur score suivi de XGBoost et GB.
4. R² (Coefficient de détermination) : Cette métrique évalue la proportion de la variance dans la variable cible qui est expliquée par les caractéristiques utilisées. Elle mesure la qualité de l'ajustement du modèle aux données. Les scores de R² varient de 0 à 1, où une valeur plus élevée indique un meilleur ajustement. Dans notre cas, RF obtient le meilleur score de R² pour toutes les combinaisons, suivi de près par XGBoost et GB.

les résultats montrent que le modèle Random Forest (RF) offre généralement les meilleures performances en termes de MAE, RMSE et R² pour les différentes combinaisons de caractéristiques et de variable cible. La combinaison qui donne les meilleurs résultats est "Vibration, Courant → Contre-pression". Le meilleur score de MAE obtenu est de 0.14, ce qui indique une bonne précision du modèle dans la prédiction de la variable cible.

3.4 Elaboration d'un plan de maintenance préventive

Le plan de maintenance préventive a été établi en se basant sur les résultats des techniques de machine learning et une approche basée sur l'AMDEC, qui permet d'identifier

Chapitre 3. Implémentation des techniques et résultats

et de classer les modes de défaillance potentiels ainsi que leurs conséquences sur le séparateur centrifuge Alfa Laval PX90. Les résultats complets de l'AMDEC, incluant les évaluations de criticité et les actions recommandées, sont présentés dans **annexe C**.

Sur la base des informations fournies par l'AMDEC et les techniques de machine learning, nous avons élaboré un plan de maintenance préventive détaillé, qui inclut les différentes variables de surveillance, les fréquences de surveillance, les seuils d'alerte, ainsi que les actions spécifiques à entreprendre. Ce plan de maintenance préventive, présenté dans le **tableau 3.12** ci-dessous qui a été conçu en tenant compte des recommandations et des meilleures pratiques pour assurer la fiabilité et la disponibilité optimales du séparateur centrifuge Alfa Laval PX90.

Tâche de maintenance	Responsable	Fréquence (h)	Type de maintenance
Nettoyage des bol et disques	Technicien	600	Préventive Systématique
Vérification des joints	Technicien	720	Préventive systématique
Remplacement des joints	Technicien	4320	Corrective
Vérification des roulements	Technicien	8640	Préventive systématique
Lubrification des composants	Technicien	2160	Préventive systématique
Vérification des paramètres d'opération et réglages	Technicien	720	Préventive systématique
Inspection des composants	Technicien	8640	Préventive systématique

TAB. 3.17 : Tableau recapitulatif des interventions

3.5 Conclusion

En conclusion, notre étude a démontré que l'utilisation de l'AMDEC et des techniques d'apprentissage automatique avancées offre une approche efficace pour la mise en place d'une stratégie de maintenance prédictive. Nous avons pu évaluer les risques de défaillance, classifier en temps réel les états d'alerte, prédire les paramètres pertinents pour la localisation des défauts et mettre en œuvre des mesures préventives. Cette approche a permis d'améliorer la fiabilité, l'efficacité et la disponibilité de la machine, tout en réduisant les temps d'arrêt imprévus et les coûts de maintenance. Grâce à cette approche intégrée, nous avons renforcé notre capacité à maintenir un niveau élevé de performance et à minimiser les interruptions non planifiées. Ces résultats soulignent l'importance de l'utilisation des méthodologies avancées et des outils d'apprentissage automatique pour la gestion proactive des défaillances et la prise de décisions éclairées en matière de maintenance industrielle.

Conclusion et perspectives

Conclusion générale

Dans ce mémoire, nous avons étudié la prédiction des défauts du séparateur centrifuge type Alfa Laval PX90 en utilisant des techniques d'apprentissage automatique. Cette étude a pour objectif d'améliorer les performances, la fiabilité et la disponibilité des machines tournantes et particulièrement ce séparateur centrifuge en assurant leur fonctionnement nominal le plus longtemps possible par la détection et l'anticipation des défauts ou pannes avant qu'elle devienne trop grave, ainsi que l'estimation des durées de vie restantes des équipements et le coût de maintenance a posteriori. Un état de l'art a été établi sur les notions de l'intelligence artificielle, machine learning et les différentes techniques d'apprentissage afin de dégager les algorithmes adéquats pour modéliser notre problématique.

La deuxième partie de ce mémoire propose une solution permettant d'établir le potentiel des modèles d'intelligence artificielle pour l'amélioration du processus de maintenance dans l'industrie par la reconnaissance des défauts de ce séparateur à l'avance. Pour cela, nous avons implémenté trois méthodes de machine learning pour améliorer les performances de prédiction où nous avons opté pour Random Forest, XGBoosting et Gradient Boosting qui sont des techniques d'ensemble learning pour faire une étude comparative sur ces méthodes et cela pour déterminer le modèle le plus performant qui peut détecter les défauts dans notre cas d'étude à la base de l'historique des paramètres de surveillance afin d'établir un plan de maintenance prédictive pour l'année prochaine. Néanmoins afin d'avoir un très bon résultat où une bonne prédiction il est nécessaire d'avoir à sa disposition une large base de données pouvant contenir de nombreuses données brutes collectées sur les équipements à travers des capteurs de vitesse, de température, de courant et de centrizoom. Parce que plus un modèle dispose de données d'entraînement, plus il peut correctement prédire les observations. Les données à leurs tours doivent être cohérentes de meilleure qualité.

Le développement de notre programme nous a permis de nous familiariser avec le langage de programmation Python et Jupyter Notebook une application web open source. Celui-ci facilite énormément le développement des applications. De plus, après l'implémentation des trois méthodes nous avons conclu que dans la classification des états d'alerte et dans la prédiction de paramètres pertinents que le modèle de Random Forest offre les meilleures performances et la plus grande précision parmi les trois modèles évalués pour notre cas d'étude.

Enfin, Ce travail a permis d'approfondir nos connaissances théoriques et pratiques dans le domaine de la maintenance industrielle, en particulier la maintenance prévisionnelle. L'utilisation de l'apprentissage automatique nous a fourni des informations précieuses pour comprendre, améliorer et planifier les ressources matérielles et humaines nécessaires avant l'apparition d'une défaillance. Ainsi, les stratégies traditionnelles de maintenance corrective et préventive peuvent être remplacées par une approche de maintenance prédictive basée sur des modèles prédictifs.

L'évaluation des performances des modèles développés démontrent les avantages de l'intelligence artificielle dans le domaine industriel. En appliquant ces modèles, les entreprises peuvent augmenter la rentabilité de leurs équipements de production et accroître leurs bénéfices. L'intégration de l'intelligence artificielle dans les processus de maintenance offre de nombreux avantages et ouvre de nouvelles perspectives pour une gestion plus efficace des actifs industriels. En résumé, ce mémoire a souligné l'importance de l'apprentissage automatique dans l'amélioration de la maintenance industrielle. Les informations fournies par ces techniques permettent aux responsables de la maintenance de prendre des décisions éclairées, de prévoir les défaillances potentielles et d'optimiser les ressources disponibles, contribuant ainsi à une meilleure performance, fiabilité et disponibilité des équipements

Perspectives

Ce projet de fin d'études ouvre la voie à de nombreuses perspectives passionnantes dans le domaine de la maintenance prédictive et de l'utilisation de l'apprentissage automatique dans l'industrie. Voici quelques pistes prometteuses pour des développements futurs :

- Amélioration des modèles prédictifs :

Les résultats obtenus dans ce projet fournissent une base solide pour l'amélioration continue des modèles prédictifs. En affinant les algorithmes d'apprentissage automatique et en intégrant de nouvelles données, il est possible d'accroître la précision des prédictions et d'identifier un éventail encore plus large de défauts potentiels.

- Application à d'autres domaines industriels :

Les techniques d'apprentissage automatique utilisées dans ce projet peuvent être adaptées et appliquées à d'autres domaines industriels. Des machines tournantes telles que les turbines, les pompes ou les moteurs électriques pourraient bénéficier de la mise en place de systèmes de maintenance prévisionnelle similaires.

Appréciation personnelle

Ce projet de fin d'études a été une expérience enrichissante et valorisante. Nous avons développé mes compétences et approfondi mes connaissances dans le domaine de la maintenance et de l'apprentissage automatique. On est fier du travail accompli et reconnaissant envers toutes les personnes qui nous ont soutenu tout au long de ce parcours.

Bibliographie

- [1] Association Français Normalisation (AFNOR).
- [2] Documentation interne de CEVITAL 2023.
- [3] Fatoumata Yalcoué ,Amor Adnane , “Machine learning pour la maintenance prédictive”, Université Larbi Ben Mhidi d’Oum El-Bouagi, juillet 2021.
- [4] Hans Stahles ,Tumba ”Alfa Laval Separation AB, Separator Manuals, dept. SKL, S-147 80” Suède,2022.
- [5] ADJED Zine-eddine, ARHAB “ Nabil Application de la méthode AMDEC-MACHINE sur un séparateur d’huile au sein de l’entreprise ,CEVITAL-Bejaia, 2017.
- [6] Mendil chafaa, Takka cherif “Etudes technologique d’un groupe électropompe et son système d’étanchéité (garniture mécanique)”, CEVITAL-Bejaia,2017.
- [7] BELMELIANI Yasser merouane, BOUTARFA Ammar, “ Contribution à la détection des défauts pour la maintenance prévisionnelle d’un compresseur centrifuge en utilisant les techniques du Machine Learning”-,Alger ,juin 2022.
- [8] M. Djamel Eddine KAHLERRAS , M. Abdel Hadi MESSAOUD , ”Contribution à l’amélioration du système de contrôle qualité par le Lean Six Sigma Cas : BMS-MONO Electric”, Alger, 2022.
- [9] Ziane ataoua, Yalcoué Fatoumata, Amor Adnane . “Machine Learning Pour La Maintenance Prédictive.”Oum El Bouaghi, 2021.
- [10] Lamouri Samir Grabot Bernard et al. “contribution à la définition d’une méthodologie couplant le traitement automatique du langage naturel et l’apprentissage automatique pour réagir aux perturbations de production”. Thèse de doct. Paris, HESAM, 2021.
- [11] Yongyi Ran et al. “A survey of predictive maintenance : Systems, purposes and approaches”.Nottingham, United Kingdom,2019.
- [12] Polotski, V., Kenne, JP. Gharbi, A. Optimal production and corrective maintenance in a failure-prone manufacturing system under variable demand.Nottingham, United Kingdom,2019.
- [13] A. M. Kazemi, E. Rahimi, and M. Azarafza, ”Cost-benefit analysis of e-maintenance in Industry 4.0: A case study,” International Journal of Production Research ” Jönköping ,Suède, Feb 2018.

Bibliographie

- [14] R. Gunasekaran, S. Subramanian, and V. Palanisamy "Benefits of e-maintenance in Industry 4.0: An Overview" Giza,Egypt, 2021.
- [15] E. W. S. Lee et al, "E-maintenance systems : A comprehensive review of the state of the art" suisse ,2018.
- [16] Wend-Benedo Arnaud Bienvenue Zoungrana. "Application des algorithmes d'apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l'Industrie 4.0". Thèse de doct. Université du Québec à Chicoutimi,2020.
- [17] Hai Zhong et al. "Vector field-based support vector regression for building energy consumption prediction". In : Applied Energy 242 , chine ,2019 .
- [18] L. Breiman, "Bagging predictors, Machine Learning, vol. 24, no. 2, pp. 123–140" , Berkeley,California, 1996.
- [19] Chen, T. and Guestrin, C." XGBoost : A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining" (pp. 785-794), Californie, États-Unis ,2016.
- [20] Dietterich, T. G., An experimental comparison of three methods for constructing ensembles of decision trees : Bagging, boosting, and randomization, Machine Learning, 40:139–158, University of South ,Florida ,2000.
- [21] Moncef GAROUANI, "Towards Efficient and Explainable Automated Machine Learning Pipelines Design Application to Industry 4.0 Data", Doctoral thesis,September 27, 2022.
- [22] Taleb Alaa Eddine, Raouf Bourghaia Amine, "Les mesures préventives contre le risque industriel Application de la méthode (AMDEC)", MEDEA, 2022.
- [23] BENZAIER ChoaiB , LAZGHEM Abd elkader , "Application AMDEC sur Les équipements de contrôle de venue L'appareil de work-over (TP195) " , ouargla , 2017.

Annexes

Annexe A

Présentation de l'entreprise CEVITAL

A.1 Introduction

Crée en 1998 par des fonds privés, CEVITAL est une société par actions (SPA) qui s'inscrit dans le cadre du développement de l'industrie agroalimentaire à l'échelle nationale. Dotée d'un régime de travail continu (24h/24h), elle compte environ 484 employés. Son site d'implantation se situe dans le port de Bejaia, couvrant une superficie d'environ 245 000 m². Les activités du complexe CEVITAL ont débuté en décembre 1998 avec le conditionnement des huiles, suivi en février 1999 du lancement de la construction de la raffinerie qui est devenue opérationnelle en septembre 1999. En tant qu'acteur majeur, CEVITAL joue un rôle significatif dans le développement de l'industrie agroalimentaire nationale. Elle détient une part de marché de 60 pour 100 en Algérie et vise à se positionner en tant que leader sur le marché national, notamment en concurrence avec l'ENCG, son voisin, ainsi qu'un autre opérateur privé. Pour atteindre cet objectif, CEVITAL propose une vaste gamme de produits de qualité.

A.2 Situation géographique

Le Complexe CEVITAL est un conglomérat algérien de l'industrie agroalimentaire, connu et reconnu partout dans l'ordre national et international, spécialisé dans le raffinage des huiles et la fabrication de la margarine, SMEN et le beurre. Créée par l'entrepreneur Issad Rebrab en 1998. CEVITAL Spa est implantée à l'extrémité du port de Bejaïa à 3 Km au sud ouest du centre ville, une partie des constructions est située dans le port à 200 m du quai alors que la plus grande partie des installations est édifiée sur les terrains récupérés situés à proximité du port, situé à 280 Km d'Alger donne l'avantage de proximité économique à celle-ci .[6,7].

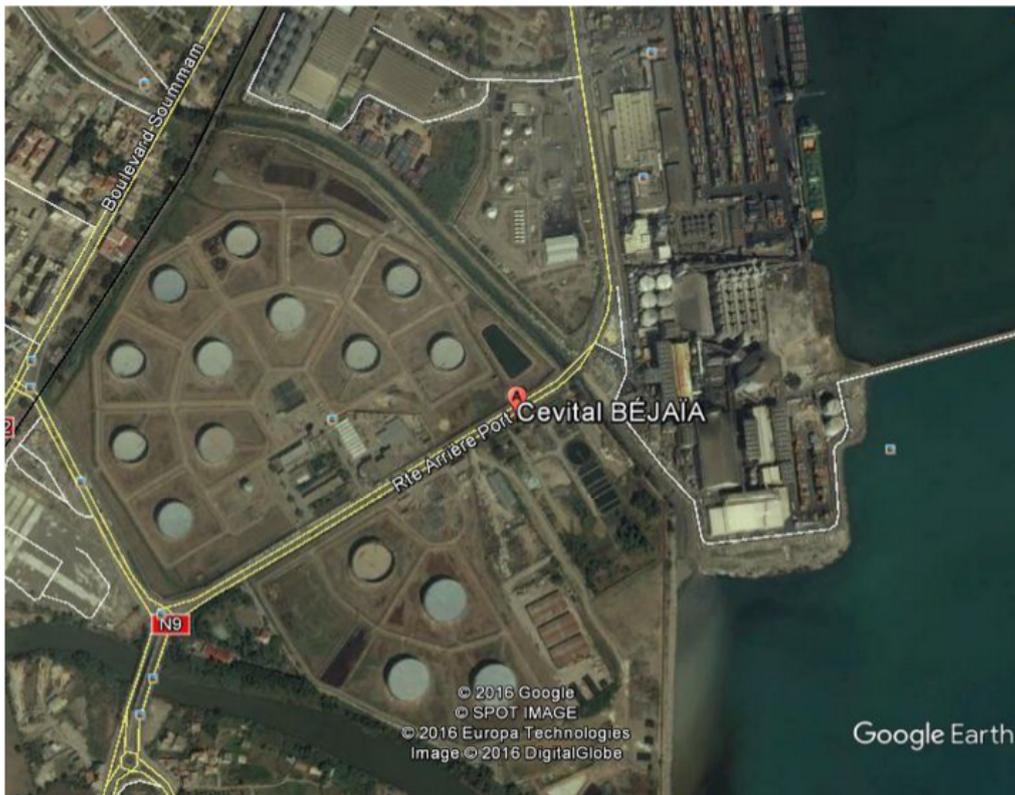


FIG. A.1 : Situation géographique [7]

A.3 Activités

Le complexe CEVITAL se focalise principalement sur le processus de raffinage des huiles végétales brutes et leur mise en conditionnement.[6.7] Les principales activités du complexe comprennent :

- Le raffinage d'huiles brutes.
- La fabrication d'emballages.
- Le conditionnement des huiles dans des bouteilles de 1L, 2L et 5L.
- La production de margarine.
- Le stockage de céréales.
- La fabrication de savon.
- La construction en cours d'un bâtiment d'hydrogénation.
- L'étude en cours pour la mise en place d'une minoterie.

Les huiles CEVITAL disponibles sur le marché sont les suivantes :

- FLEURIAL composé à 100 pour 100 d'huile de Tournesol (TS).

Annexe A. Présentation de l'entreprise CEVITAL

- FRIDOR mélanges de huiles de tournesol (TS), soja (SJ) et huile de palme (ODF).
- ELIO mélange de huile de soja (SJ) et huile de palme (ODF).

Margarine :

- Shortning (graisse végétale)35/37.
- Shortning (graisse végétale) 38/40.
- Margarine de feuilletage –la parisienne.
- Fleurial (tartinage et cuisson) plaquettes 250gr et 500gr Smen

A.4 Structure organisationnelle

La configuration de l'organisation du complexe suit un modèle hiérarchique classique. Cela est illustré par l'organigramme présenté dans la figure suivante :

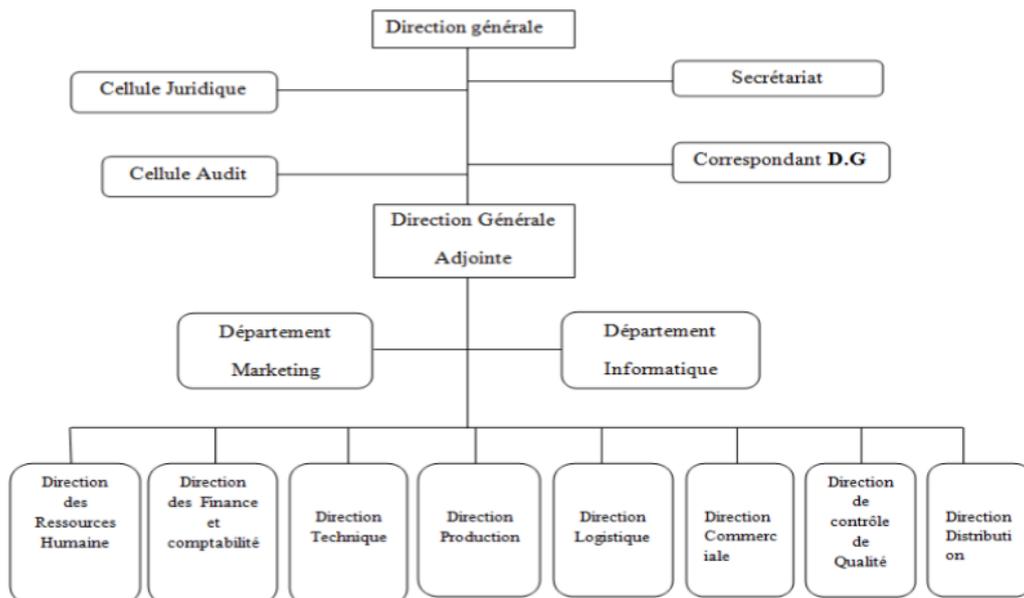


FIG. A.2 : L'organigramme du complexe CEVITAL [7].

A.5 Présentation de la raffinerie

La raffinerie est constituée de trois lignes de production d'huile, désignées comme A, B et C, avec des capacités respectives de 400 tonnes, 400 tonnes et 1000 tonnes, ce qui totalise une capacité de 1800 tonnes par jour. Cette raffinerie est conçue pour traiter différentes qualités d'huiles comestibles telles que le colza, le tournesol, l'olive et le soja.

Chaque type d'huile présente des spécifications spécifiques et nécessite donc des procédés de traitement et des paramètres particuliers. Toutefois, de manière générale, les huiles brutes obtenues à partir de la pression et de l'extraction des oléagineux présentent une acidité supérieure à 0,5 pour cent et contiennent des mucilages, des impuretés, de l'humidité, des pigments colorés et des substances odorantes indésirables. Les éléments indésirables sont éliminés par les opérations suivantes :

- Démucilagination : élimination des mucilages par l'action de l'acide phosphorique, suivie d'une centrifugation.
- Neutralisation : utilisation de la soude caustique pour réduire l'acidité à 0,05 pour cent et élimination des résidus par centrifugation à l'aide d'un séparateur auto-débourbeur.
- Lavage : l'huile est lavée avec de l'eau chaude à 95 °C, puis séchée sous vide à un minimum de 50 tours par minute.
- Décoloration : utilisation d'une terre décolorante pour éliminer les pigments du carotène et de la chlorophylle.
- Désodorisation : distillation des acides gras résiduels et élimination des pigments colorés résiduels sous vide à 2 millibars et à une température de 250 °C.

Une fois ces étapes terminées, l'huile obtenue est exempte d'impuretés, d'humidité et de produits oxydés. Elle est refroidie à 25 °C avant d'être stockée et conditionnée. D'autres opérations spécifiques sont ajoutées à cette chaîne de raffinage en fonction du type d'huile, comme la cristallisation pour l'huile de tournesol et la démucilagination pour l'huile de soja. Des utilités telles que la vapeur, l'eau brute et l'air comprimé sont utilisées dans l'ensemble des procédés de raffinage.

A.5.1 Conditionnement

Pour le conditionnement, il y a quatre chaînes disponibles :

- Deux chaînes pour les bouteilles de 5 litres.
- Une chaîne pour les bouteilles de 1 litre.
- Une chaîne pour les bouteilles de 2 litres.

Les emballages utilisés sont fabriqués en P.E.T. Les préformes sont soufflées (pour les formats de 5L, 2L et 1L) à l'aide d'une souffleuse-forme. Les emballages vides obtenus sont automatiquement dirigés vers une remplisseuse rotative, puis vers une bouchonneuse. Les étapes suivantes comprennent l'étiquetage avec date et enfin la plastification.

A.5.2 Traitement des déchets

Les déchets résultant des différentes opérations de production et de raffinage sont traités sur place au sein du complexe. Une station d'épuration est mise en place pour les eaux usées. Quant aux déchets qualifiés d'huile acide ou d'acide, ils sont revendus aux fabricants de savons, de peintures ou de mastics.

A.5.3 Unités de stockage

La raffinerie dispose des unités de stockage suivantes :

- Huile brute : 45 000 tonnes.
- Huile raffinée : 4 000 tonnes.
- Huile conditionnée : 1 200 tonnes, correspondant à la demande quotidienne du marché national.

A.5.4 Processus de remplissage des bacs, remplissage par bateaux

Le processus de remplissage des bacs et le chargement des bateaux se déroulent de la manière suivante :

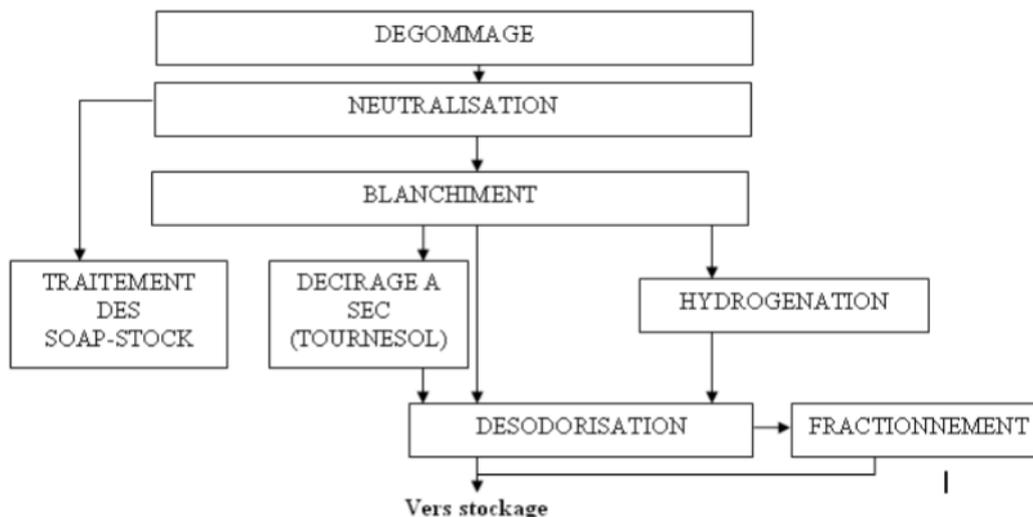


FIG. A.3 : Différentes étapes du processus de raffinage [7].

Annexe B

maintenance et la e-maintenance industrielle

B.1 Introduction

La maintenance industrielle est un élément essentiel pour assurer le bon fonctionnement et la durabilité des équipements dans les environnements industriels. Elle vise à prévenir les pannes, à optimiser les performances des machines et à maximiser la disponibilité des installations. Cependant, avec l'avènement des technologies numériques et de l'Internet des objets (IoT), de nouvelles approches de maintenance ont émergé, ouvrant la voie à ce que l'on appelle la "e-maintenance".

La e-maintenance, également connue sous le nom de maintenance 4.0 ou maintenance prédictive, repose sur l'utilisation des technologies numériques pour améliorer et automatiser les processus de maintenance industrielle. Elle exploite la collecte de données en temps réel, l'analyse des données massives (big data), l'intelligence artificielle et l'apprentissage automatique (machine learning) pour détecter les défaillances imminentes, prévoir les besoins de maintenance et prendre des décisions éclairées.

L'avantage majeur de la e-maintenance réside dans sa capacité à passer d'une maintenance réactive à une maintenance proactive. Plutôt que d'attendre qu'une panne survienne, la e-maintenance permet d'anticiper les problèmes potentiels en surveillant en continu les paramètres clés, tels que les vibrations, les températures, les niveaux de pression, etc. Cela permet d'effectuer des interventions de maintenance préventive avant que des défaillances graves ne se produisent, réduisant ainsi les temps d'arrêt imprévus et les coûts associés.

En outre, la e-maintenance facilite la planification et la gestion des activités de maintenance en fournissant des informations en temps réel sur l'état des équipements. Cela permet d'optimiser les ressources, d'améliorer l'efficacité des opérations de maintenance et de réduire les coûts globaux.

Dans cette ère de l'industrie 4.0, la e-maintenance est devenue une composante clé de la transformation numérique des entreprises industrielles. Elle offre de nouvelles opportunités pour améliorer la fiabilité, la productivité et la compétitivité, tout en garantissant des opérations plus durables et respectueuses de l'environnement.

Dans cette étude, nous explorerons les différents aspects de la maintenance et de la e-maintenance industrielle, en mettant l'accent sur les avantages, les défis et les perspectives d'avenir de cette approche révolutionnaire.

B.2 Maintenance industrielle

La maintenance, selon la définition de l'AFNOR, a pour objectif de préserver ou de rétablir un bien dans un état spécifié afin qu'il puisse fournir un service déterminé. Elle englobe les vérifications fonctionnelles, l'entretien, la réparation ou le remplacement des appareils, équipements, machines, infrastructures de construction et services publics nécessaires dans les installations industrielles, commerciales et résidentielles. Ces activités sont effectuées préventivement ou suite à une panne.[13].

B.2.1 Les types de maintenance industrielle

Il y a deux principales catégories de maintenance industrielle :

- La maintenance corrective, qui peut être palliative ou curative
- La maintenance préventive, qui peut être systématique, conditionnelle ou prédictive.

Nous prenons également en compte la maintenance améliorative, car elle est nécessaire dans notre travail. Toutes ces formes de maintenance sont illustrées dans la figure

Maintenance corrective

Ce terme fait référence aux interventions réalisées sur un équipement ou une machine en cas de panne [9]. Ces interventions peuvent être de deux types :

- Palliatives : elles représentent des solutions temporaires visant à permettre à l'équipement de continuer à remplir partiellement ou complètement sa fonction requise.
- Curatives : elles impliquent la réparation définitive de l'équipement, le ramenant à son état d'origine ou à un état lui permettant de remplir pleinement sa fonction.

Maintenance préventive

Ce type de maintenance consiste à intervenir sur un équipement ou une machine avant qu'une panne ne survienne pour prévenir les pannes. Il existe trois sous-types de maintenance préventive[9] :

- Maintenance systématique.
- Maintenance conditionnelle.
- Maintenance prédictive.

1. Maintenance préventive systématique Il s'agit du type de maintenance préventive le plus fréquemment utilisé. Il englobe des interventions planifiées de manière systématique, soit selon des intervalles de temps fixes, soit en fonction de l'utilisation (temps de fonctionnement, nombre de mouvements, etc.). Cette approche est souvent basée sur les spécifications ou les recommandations du fabricant de l'équipement, mais elle peut également être ajustée par l'utilisateur en fonction de son expérience.[9],[12]

2. Maintenance préventive conditionnelle

Ces interventions sont effectuées en fonction d'une condition mesurable. Elles sont donc basées sur des relevés, des mesures ou des contrôles réalisés par un technicien ou à l'aide de capteurs, qui fournissent des informations sur l'état de dégradation des équipements. Des techniques telles que l'analyse vibratoire, la thermographie infrarouge, le niveau d'huile, etc., sont utilisées. Des indicateurs pertinents sont définis pour anticiper les pannes.[9],[12].

3. Maintenance prédictive

Cette forme de maintenance conditionnelle repose sur des prévisions extrapolées à partir de l'analyse et de l'évaluation des paramètres de dégradation d'un bien. Selon la définition de l'AFNOR, la maintenance préventive est définie comme suit : "Maintenance effectuée à des intervalles prédéterminés ou selon des critères spécifiés, dans le but de réduire la probabilité de défaillance ou la détérioration du fonctionnement d'un bien".

Cette approche se fonde sur la prévision du dépassement d'un seuil préétabli qui indique l'état de dégradation de l'équipement avant l'apparition d'un dysfonctionnement ou d'une panne [9].

Maintenance améliorative Moins familière et souvent considérée comme une "activité connexe", la maintenance améliorative englobe un ensemble de mesures techniques, administratives et de gestion visant à renforcer la sécurité de fonctionnement d'un actif sans altérer sa fonction requise, mais en modifiant sa conception d'origine.

Les objectifs de la maintenance améliorative peuvent varier, tels que la réduction de la consommation d'énergie, l'augmentation de la durée de vie des composants, l'amélioration de la maintenabilité ou encore l'optimisation des performances de production. Les interventions de maintenance améliorative prennent la forme d'actions de rénovation, de reconstruction ou de modernisation [9],[12].

En outre, L'AMDEC (Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité) peut être une méthode clé pour la maintenance préventive dans l'industrie. Elle permet d'identifier les défaillances potentielles, évaluer leur impact et prioriser les actions de maintenance. En intégrant l'analyse de données et le machine learning, l'AMDEC devient encore plus puissante [6].

B.3 E-maintenance

B.3.1 Définition

La e-maintenance, ou maintenance électronique, est une approche de la maintenance industrielle qui utilise les technologies de l'information et de la communication (TIC) pour améliorer la gestion des équipements et des processus de production. Elle permet de collecter et d'analyser les données de maintenance en temps réel, d'optimiser la planification et l'ordonnement des activités de maintenance, et de réduire les temps d'arrêt non planifiés [14].

B.3.2 E-maintenance predictive

La e-maintenance prédictive est une approche basée sur la collecte et l'analyse en temps réel des données d'équipements industriels, permettant de prédire les pannes et de planifier les interventions de maintenance de manière proactive, afin d'optimiser les performances et la fiabilité des équipements [14].

Annexe C

AMDEC du séparateur centrifuge PX90

C.1 Définition de l'AMDEC Moyen

L'AMDEC, ou Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité, est une méthode d'analyse qui consiste à examiner les causes potentielles de défaillance des composants d'un système et à évaluer leurs effets. Cette approche peut être appliquée à un produit, à un processus ou à un équipement de production, tel qu'une machine.

Dans cet annexe, nous mettons en pratique cette méthode en l'appliquant à un séparateur d'huile spécifique, en l'occurrence le modèle Alfa Laval PX 90. L'objectif est d'identifier les actions correctives à mettre en place afin de prévenir les défaillances et d'améliorer la fiabilité de la machine.[6]

C.2 Démarche pratique de l'AMDEC sur le séparateur Alfa Laval PX90

Dans cette étape, il s'agit de réaliser une évaluation globale de l'étude et de fournir les éléments nécessaires pour définir et mettre en œuvre les actions requises en toute connaissance de cause. Ce bilan revêt une importance capitale pour exploiter pleinement les résultats de l'analyse.

C.2.1 Initialisation

La phase d'initialisation de l'analyse vise à délimiter le champ d'étude et à définir les objectifs associés à cette analyse.[26]

- Le système étudié est spécifiquement le séparateur Alfa Laval PX90.
- Le groupe de travail est composé d'un ingénieur de maintenance et d'un méthodiste, entre autres. Au cours de notre stage d'un mois à l'entreprise CEVITAL,

notre équipe s'est réunie pour analyser les causes les plus probables de défaillances ainsi que leurs effets sur le système. L'objectif était également de capitaliser sur l'expérience passée, car celle-ci est cruciale pour l'établissement des critères d'évaluation (fréquence, gravité et non-détection).[6]

- Nos objectifs sont les suivants :
 - Identifier les causes de dysfonctionnement et déterminer des actions correctives visant à éliminer les problèmes connus.
 - Élaborer et suivre un plan de maintenance.
 - Définir les points les plus critiques du séparateur.
- Les sources d'information sur lesquelles nous nous appuyons dans cette étude sont les suivantes : – L'historique de maintenance. – L'historique de production. – L'historique des pannes. – L'historique des pièces de rechange. – La documentation technique, telle que la notice d'utilisation et le manuel technique. – L'expertise du personnel du service de maintenance. – Les rapports des travaux effectués chaque mois. – Les informations fournies par le constructeur (y compris les éventuels sous-traitants).

C.2.2 Analyse fonctionnelle

L'analyse fonctionnelle est utilisée pour modéliser de manière structurée la centrifugeuse, ce qui facilite la compréhension de son fonctionnement et permet des analyses critiques approfondies.[6]

En principe, chaque équipement a une raison d'être unique et remplit une fonction spécifique. Pour réaliser cette fonction principale, un ensemble de composants interagissant entre eux est nécessaire. Les systèmes sont constitués de regroupements fonctionnels de sous-systèmes qui remplissent des fonctions de niveau supérieur pour contribuer à la réalisation de la fonction principale.[26]

La décomposition fonctionnelle est généralement représentée sous forme d'une hiérarchie en plusieurs niveaux.[6] – Le moteur électrique entraîne l'arbre horizontal, qui transmet le mouvement à l'arbre vertical avec les roues dentées. – La garniture mécanique et différents joints assurent l'étanchéité du séparateur.

C.2.3 Décomposition fonctionnelle

Le séparateur a été décomposé en sept parties selon son mode de fonctionnement :

- Partie transmission
- Partie étanchéité.
- Partie séparation.

FIG. C.1 : Decomposition fonctionnelle du separateur centrifuge Alfa Laval PX90

C.2.4 Hiérarchisation par criticité

Les défaillances peuvent être classées en deux catégories en fonction de leur niveau de criticité par rapport à un seuil prédéfini.

- Défaillance critique : $C > \text{seuil de criticité}$
- Défaillance non critique : $C < \text{seuil de criticité}$

Généralement, une défaillance est considérée comme critique si sa gravité est élevée (maximum), sauf si les critères de fréquence et de non-détection sont tous les deux égaux à 1.[26]

Dans notre application, le seuil de criticité est fixé à 12.

C.2.5 Evaluation de la criticité

a) Les critères :

L'évaluation de la criticité se fait selon 3 critères principaux :

a.1 La gravité (G) : Le critère de gravité, comme celui de fréquence, doit être très précis dans ses définitions, la sévérité et la gravité étant des notions subjectives.[6]

Niveau	Définition
1	Mineure: défaillance ne provoquant pas l'arrêt de production supérieur à 5 minutes. Aucune dégradation ni production défectueuse
2	Moyenne : défaillance provoquant un arrêt de 5 à 30 minutes et nécessitant une réparation se site.
3	Importante : défaillance provoquant un arrêt de 30 à 60 minutes et/ou nécessitant le remplacement d'un matériel défectueux.
4	Grave : défaillance provoquant un arrêt supérieur à 1 heure et/ou impliquant des risques potentiels pour la sécurité des personnes et des biens.

TAB. C.1 : Critère de fréquence

a.2La fréquence (F) : Le critère de fréquence indique le niveau de probabilité d'apparition d'une défaillance, donc, de la fiabilité en quelque sorte. La définition des niveaux de fréquence doit être précise comme le montre le tableau III.2.[6]

Niveau	Définition
1	Faible : Moins de 1 fois par semestre.
2	Possible : En moyenne 1 fois par mois.
3	Certaine : En moyenne 1 fois par semaine.
4	Forte : Possible 1 fois par jour

TAB. C.2 : Critère de fréquence

a.3 La non-détection (D) :

Le critère D est l'indice de non détectabilité. Il s'évalue à partir du mode de défaillance par une note estimée allant de 1 (dégradation élémentaire) à 4 (défaillance soudaine).

Niveau	Définition
1	Elémentaire : Défaillance possible à éviter.
2	Aisée : Apparition d'une défaillance avec recherche et action corrective évidente.
3	Moyenne : Apparition d'une défaillance, recherche et action corrective menées par un technicien de maintenance
4	Délicate : Défaillance difficilement détectable et nécessite le démontage et un technicien spécialisés

TAB. C.3 : Critère de fréquence

Calcul de la criticité :

$$C = G * F * D$$

La criticité s'obtient en faisant le produit des indices des critères précédents. Cette valeur de criticité s'établit souvent sur une échelle de 1 à 64 (4*4*4), elle permet de connaître à partir de ses propres critères d'évaluation le caractère critique de chacune des causes de défaillance potentielle pour chacun des composants d'un système.[26]

Niveau	Définition
C<9	Faible : Aucun problème particulier. Surveillance habituelle.
9<C<25	Acceptable : Nécessite une surveillance particulière et/ou une révision de la politique de maintenance.
C>25	Forte : Surveillance accrue. Remise en cause de la maintenance. Eventuellement, arrêt pour amélioration.
C=64	Dangereuse : Révision de la politique de maintenance et/ou modification du système. (Arrêt si sécurité est menacée).

TAB. C.4 : Critère de fréquence

Cotation	1	2	3	4
F	Taux d'apparition très faible : moins d'une défaillance pas an	Taux d'apparition faible : 3mois <F<6mois	Taux d'apparition moyen 1sem<F<3mois	Taux d'apparition important : plusieurs défaillances par semaine
G	Durée mineure : aucune dégradation notable du matériel, durée d'intervention t<10min	Durée moyenne nécessite une remise en état de courte durée 10min<t<30min	Durée majeure nécessite une intervention de longue durée 30min<t<90min	Durée catastrophique très critique nécessite une grande intervention t>90 min
D	Evidente : défaillance précocement détectable	Possible : il existe un signe avant coureur de la défaillance	Importante : défaillance difficilement détectable	Impossible : défaillance indétectable

TAB. C.5 : Barème de cotation des critères fréquence, gravité et non détection

Niveau de criticité	Actions à engager
1 < C <12 Criticité négligeable	-Aucune modification de conception. -Maintenance corrective.
12 < C <24 Criticité moyenne	-Amélioration des performances de l'élément. -Maintenance préventive systématique.
24 < C <48 Criticité élevée	-Révision de la conception du sous-ensemble et du choix des éléments. -Surveillance particulière. -Maintenance préventive conditionnelle/prévisionnelle.
48 < C <64 Criticité interdite	-Remise en cause complète de la conception.

TAB. C.6 : Echelle de criticité

Annexe C. AMDEC du separateur centrifuge PX90

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de la défaillance	Détection	F	G	D	C	Action
Joint bleu	Etanchéité	Rupture	-Fatigue -Durée de vie	Garniture usée	Contrôle	2	2	3	1 2	-Vérification de la lubrification -Changement de joint
Joint téflon	Etanchéité	-Déplacement de joint -Rupture	-Fatigue -Durée de vie -Charge	-Bruit -Pièce usée -Fuite	Contrôle	3	3	3	2 7	Changement de joint
Bague de réglage de la hauteur	Etanchéité	-Usure -déformation -Cassure	-Fatigue -Durée de vie	-Réglage perdu	Contrôle	1	3	2	6	Changement de Bague
Garniture mécanique	Etanchéité	-Usure Fissure	Fatigue -Frottement -Charge -Manque d'eau de refroidissement -Rupture des joints	Bruit -Vibration élevée -Changement de vitesse -Faible rendement	-Contrôle -Bruit anormal	4	4	3	4 8	Changement de la Garniture mécanique -Contrôle du système de refroidissement Et le système de lubrification
Joint torique	Etanchéité	-Usure -La hauteur du joint n'est pas exacte -Rupture	-Fatigue -Pas de lubrification	-Bruit -Fissure de la garniture -Fuite	Contrôle	3	4	3	3 6	-graissage -Changement de joint

TAB. C.7 : Application de l'AMDEC machine sur la partie étanchéité

Interprétation : La partie étanchéité comprend trois éléments critiques, dont deux d'entre eux (la garniture mécanique et le joint torique) nécessitent l'intervention du constructeur. Le joint Téflon présente une criticité élevée avec $C=27$.

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de la défaillance	Détection	F	G	D	C	Action
Roue dentée	Transmission	-Usure -Fissure	-Fatigue de matériau -Manque de lubrification	Arrêt de Séparateur	-Bruit anormal	2	3	3	12	Changement des roues -Vérifier la lubrification -Eliminer les jeux
Arbre vertical	Transmission	-Usure -Déformation -Rupture	-Manque de lubrification -Charge -Fatigue	Vibration élevée	Contrôle	1	4	3	12	-Vérifier la lubrification -Réglage de l'arbre -Changement de l'arbre
Arbre horizontal	Transmission	-Usure -Déformation	-Manque de lubrification -Jeux -Vibration	-Vibration élevée -Mauvais fonctionnement	-Contrôle -Bruit	3	4	3	36	-Réglage de l'arbre -Changement de l'arbre -Vérifier la lubrification
Réducteur de vitesse	-Freinage de convoyeur	Mauvais freinage du convoyeur	-Détérioration des engrenages -Manque de lubrifiant	-Mauvais rapport de vitesse -Vibration	Contrôle	2	3	2	12	-Changement de réducteur

TAB. C.8 : Application de l'AMDEC machine sur la partie transmission de mouvement

Interprétation : Au sein de cette partie, il est observé que plusieurs éléments affichent une criticité moyenne de $C=12$, à l'exception de l'arbre horizontal qui présente une criticité particulièrement élevée avec $C=36$. Dans cette situation, l'intervention du constructeur est nécessaire selon les besoins du service de maintenance.

Annexe C. AMDEC du separateur centrifuge PX90

Element	Fonction	Mode de défaillance	Cause de défaillance	Effet de défaillance	Détection	F	G	D	C	Action
Bol	Séparation	-Usure -Fuite -Fissure	-Mauvais nettoyage -Déformation des joints	-Perte de production -Vibration élevé -Bruit -Vitesse de séparateur diminue ou augmente	-Bruit anormal	2	3	3	18	-Bon nettoyage des pièces du bol -Changement du bol
Assiette	Séparation	-Usure -Déformation	-Mauvais nettoyage des assiettes -Mauvais montage -La charge	-Mauvaise séparation -Mauvaise évaluation	Visuel	4	2	2	16	-Nettoyage des assiettes -Changement des assiettes
Centrizoom	Séparation	-Usure -Déformation -Fissure	-Fatigue du matériau -Mauvais réglage -La charge -Vitesse élevée -Pression élevée	-Mauvaise séparation -Mauvaise évacuation	Contrôle	2	2	3	12	-Vérification de la commande -Changement de centrizom -Nettoyage de centrizoom
Electrovanne	- Régularisation de débit -Séparation	- L'électrovanne reste fermée - L'électrovanne reste ouverte	Usure de la pièce interne	Il n'y a pas de régulation de débit	Contrôle	2	3	2	12	Changer l'électrovanne

TAB. C.9 : Application de l'AMDEC machine sur la partie séparation

Interprétation : Dans cette partie, nous observons la présence de plusieurs éléments avec une criticité moyenne, avec des valeurs de $12 < C < 24$. La remise en marche de ces éléments relève uniquement de la responsabilité du service de maintenance.

C.3 La réévaluation de la criticité :

La réévaluation de la criticité consiste à regrouper les éléments selon leur criticité, en les classant par ordre décroissant dans le tableau IV.10. Il est essentiel de prioriser ces éléments pour engager des actions appropriées en conséquence.

Element	Criticité	Action
-Garniture mécanique -Joint torique -Arbre horizontal	48 36 36	Remise complète de la conception
-Joint téflon	27	Surveillance particulière Maintenance préventive conditionnelle
-Bol -Assiettes -joint bleu -Roue dentée -Arbre vertical -Réducteur de vitesse -Électrovanne	18 16 12 12 12 12 12	Amélioration des performances d'éléments. Maintenance préventive systématique
-Bague de réglage de la hauteur	6	Aucune modification Maintenance corrective

TAB. C.10 : Classification des éléments selon leur criticité

–Pour l'intervention du constructeur de la machine, on a choisi la valeur 36 comme seuil de criticité.

C.4 Analyse des résultats

Pour améliorer la disponibilité du séparateur Alfa Laval, il est essentiel de mettre en œuvre des actions de maintenance sur les équipements ayant une criticité supérieure à 12. Les actions recommandées incluent une surveillance périodique et une maintenance systématique ou conditionnelle.

Grâce à notre analyse approfondie, nous avons identifié les risques de dysfonctionnement du système de grenailage, en mettant en évidence les points critiques et en proposant des actions de maintenance pour réduire leur criticité.

Nous avons constaté que la majorité des problèmes rencontrés dans ce système sont liés à l'usure. Afin d'éviter de tels problèmes, il est recommandé de réaliser un contrôle systématique de l'usure. Pour prévenir la propagation de l'usure et les défaillances susceptibles de perturber le fonctionnement normal du système, l'entreprise doit effectuer régulièrement les tâches suivantes :

- Réparations et nettoyage
- Respect des instructions de maintenance systématique telles que le remplacement des pièces défectueuses selon l'agenda périodique recommandé par le constructeur,
- Tenue d'un historique des pannes, réexamen périodique de l'AMDEC,
- Formation du personnel de maintenance à l'AMDEC,

- Maintien d'un stock de sécurité de pièces de rechange essentielles.

C.5 Conclusion

En conclusion, ce chapitre s'appuie sur une analyse concrète des besoins de maintenance préventive des équipements de la centrifugeuse (séparateur d'huile Alfa Laval PX90) en utilisant la méthode AMDEC. L'AMDEC est un outil puissant pour garantir la qualité et la sécurité d'un produit, mais sa mise en œuvre peut être complexe et exigeante. Il est donc recommandé de l'appliquer aux produits critiques en termes de sécurité ou de stratégie pour l'entreprise.