

Université M'Hamed Bougara-Boumerdes  
Faculté des Hydrocarbures et de la Chimie



Département Transport et Equipements des Hydrocarbures

Mémoire de fin d'études  
En vue de l'obtention du diplôme de

# Master

**Domaine** : Sciences et Technologies

**Filière** : Hydrocarbure

**Option** : Génie mécanique-Mécanique des chantiers pétroliers

Présenté par : **BOUCHERMA Abdeldjalil**

## THEME

**Application des méthodes d'intelligence artificielle pour la maintenance prédictive de la turbine à gaz MS5001D**

Devant le jury :

	Nom et Prénom	Grade	Université/Affiliation
Examineur			
Examineur			
Examineur			
Encadreur	MR. HARHOUT Riad		UMBB
Promoteur	MR. BIREM Mohamed		SH-BP-EQUINOR JV

## REMERCIEMENTS

Gloire à dieu qui a créé, dirigé notre parcours et aidé, pour cela nous disons  
**ELHAMDOULILLAH.**

Je tiens à remercier tout particulièrement mon encadrant **M. HARHOUT** Riad, pour l'aide compétente qu'il m'a apportée, pour sa patience et son encouragement. Son œil critique m'a été très précieux pour structurer le travail et pour améliorer la qualité des différentes sections.

Je tiens à remercier en premier degré mon promoteur **M. BIREM Mohamed** pour son aide immense, la qualité de son suivie ainsi que pour tous les conseils et les informations qu'il m'a prodigué avec un degré de patience et de professionnalisme sans égal.

Je tiens aussi à adresser mes plus sincères remerciements à l'équipe de groupement In Amenas. Incluant **M. BETTAHER Fares** et **M. BENNAMIA Mebarek**. Pour m'avoir offert l'opportunité d'intégrer l'équipe de **SH-BP-EQUINOR** et pour leurs soutiens.

Que les membres de jury trouvent, ici, l'expression de mes sincères remerciements pour l'honneur qu'ils me font en prenant le temps de lire et d'évaluer ce travail.

Je souhaite aussi remercier l'équipe pédagogique et administrative de l'FHC pour leurs efforts dans le but de nos offrir une excellente formation.

Pour finir, je souhaite remercier toute personne ayant contribué de près ou de loin à la réalisation de ce travail.

## Dédicace

“

*À mes parents, vous avez été mes premiers enseignants, mes guides et mes modèles. Votre soutien indéfectible et votre confiance en moi ont nourri ma détermination à réussir.*

*À mes sœurs, vous avez été mes meilleures amies, mes confidentes et mes alliées. Votre présence bienveillante et vos encouragements constants m'ont donné la force de persévérer.*

*À mon petit frère, malgré ton jeune âge, tu as été une source d'inspiration pour moi. Ton innocence, ta curiosité et ta joie de vivre m'ont rappelé l'importance de croire en ses rêves.*

*Et à mes amis, vous avez été mes compagnons de route, mes partenaires d'étude et mes confidents. Vos encouragements, vos conseils et votre présence ont rendu cette aventure encore plus enrichissante.*

*Ce mémoire est le fruit de nos liens indéfectibles et de notre soutien mutuel. Je vous suis reconnaissant d'avoir été présents dans ma vie et je partage avec vous cette réussite qui est aussi la vôtre. Merci du fond du cœur pour tout ce que vous avez fait et continuez de faire.*

*Avec tout mon amour et ma gratitude,*

”

***Abdeldjalil***

## RÉSUMÉ

La maintenance prédictive consiste à prédire les défaillances des machines avant qu'elles ne se produisent, ce qui permet de prendre des mesures proactives. L'une des techniques couramment utilisées dans la maintenance prédictive est l'extraction et l'analyse des données de vibrations des machines. En analysant ces données, il devient possible d'identifier et de prédire les pannes des machines tournantes. Dans ce contexte, afin d'appliquer une surveillance sur l'état de la turbine à gaz **MS5001D**, des techniques d'intelligence artificielle et d'apprentissage automatique, ont été appliquées dans le cadre de notre travail de mémoire de fin d'étude, en exploitant ainsi leurs avantages par rapport aux procédures de diagnostic traditionnelles, notamment l'analyse temporelle et fréquentielle des vibrations.

L'objectif principal de cette étude vise à anticiper les défaillances et les pannes et détecter en temps préalable les éventuelles défaillances de cette turbine à gaz étudié, en offrant ainsi une opportunité d'intervention précoce pour éviter les pannes majeures et les coûts de maintenance élevés.

Cependant une étude et une analyse comparative de différentes approches analytiques et de divers algorithmes d'apprentissage automatique sont appliquées, tels que XGB, Extra Trees et Bagging..., dans le but de sélectionner la méthode la plus efficace pour la détection de défaillances et d'anomalies qui peuvent être engendré au fur et à mesure de fonctionnement de cette turbine.

**Mots-clés :** Maintenance prédictive, turbine à gaz, Intelligence artificielle, apprentissage machine

## **ABSTRACT**

Predictive maintenance consists of predicting machine failures before they occur, enabling proactive measures to be taken. One of the commonly used techniques in predictive maintenance is the extraction and analysis of machine vibration data. By analyzing this data, it becomes possible to identify and predict failures in rotating machines. In this context, condition monitoring of an MS5001D gas turbine, artificial intelligence techniques and machine learning have been applied in our final thesis work, leveraging their advantages over traditional diagnostic procedures, such as time and frequency analysis of vibrations.

The main objective of this study is to anticipate failures and detect potential failures in the studied gas turbine in advance, thus providing an opportunity for early intervention to avoid major breakdowns and high maintenance costs.

However, a study and comparative analysis of different analytical approaches and various machine learning algorithms, such as XGB, Extra Trees, and Bagging, are applied in order to select the most effective method for detecting failures and anomalies that may occur during the operation of this turbine.

**Keywords:** Predictive maintenance, gas turbine, artificial intelligence, machine learning.

## ملخص

الصيانة التنبؤية تتكون من توقع فشل الآلات قبل حدوثه، مما يتيح اتخاذ تدابير استباقية. أحد التقنيات المستخدمة بشكل شائع في الصيانة التنبؤية هو استخراج وتحليل بيانات اهتزاز الآلات. من خلال تحليل هذه البيانات، يصبح من الممكن تحديد وتوقع أعطال الآلات الدوارة. في هذا السياق، تم تطبيق رصد حالة توربينة الغاز **MS5001D** وتقنيات الذكاء الاصطناعي وتعلم الآلة في إطار أعمال مشروع التخرج النهائي، استفادةً من مزاياها مقارنةً بالإجراءات التشخيصية التقليدية، بما في ذلك تحليل الاهتزازات الزمنية والترددية.

الهدف الرئيسي لهذه الدراسة هو التنبؤ بالأعطال والكشف المبكر عن أي عيوب محتملة في التوربينة الغازية المدروسة، مما يوفر فرصة للتدخل المبكر لتجنب الأعطال الكبيرة وتكاليف الصيانة العالية.

ومع ذلك، يتم تطبيق دراسة وتحليل مقارن لمختلف النهج التحليلية ومجموعة متنوعة من خوارزميات تعلم الآلة، مثل XGB، Extra Trees و Bagging، بهدف اختيار الطريقة الأكثر فعالية للكشف عن الأعطال والانحرافات التي يمكن أن تحدث تبعاً أثناء تشغيل هذه التوربينة.

**الكلمات الرئيسية:** الصيانة التنبؤية، توربينة الغاز، الذكاء الاصطناعي، تعلم الآلة.

# **TABLE DES MATIÈRES**

**DEDICACE**

**REMERCIEMENT**

**RESUME**

**TABLE DES MATIERES**

**LISTE DES FIGURES**

**LISTE DES TABLEAUX**

**ACRONYMES**

**INTRODUCTION GENERALE ..... 1**

## **Chapitre 1 : PRESENTATION ET HISTORIQUE DE CHAMP**

1.1.	Introduction.....	2
1.2.	Présentation et historique du champ .....	2
1.2.1.	Présentation .....	2
1.2.2.	Situation géographique.....	3
1.2.3.	Historique du champ .....	4
1.2.4.	Répartition de gisement de Tiguentourine .....	5
1.2.5.	Caractéristiques de réservoir .....	6
1.2.6.	Historique de la production .....	7
1.3.	Conclusion .....	8

## **Chapitre 2 : INTRODUCTION SUR LES TURBINES**

2.1.	Introduction.....	9
2.2.	Historique des turbines à gaz .....	10
2.3.	Classification des turbines à gaz .....	10
2.3.1.	Par le mode de travail.....	10
2.3.2.	Par le mode de Construction .....	11
2.3.3.	Par le mode de fonctionnement thermodynamique.....	12
2.4.	Principe de fonctionnement des turbines à gaz.....	14
2.5.	Description de la Turbine à Gaz MS5001.....	15

2.6.	Principe de Fonctionnement de la Turbine à Gaz MS5001 .....	16
2.7.	Sections principales d'une installation de turbine à gaz.....	17
2.7.1.	Section compresseur.....	17
2.7.2.	Section Combustion .....	19
2.7.3.	Section Turbine .....	21
2.7.4.	Les Paliers .....	23
2.7.5.	Système d'échappement et d'entrée .....	24

### **Chapitre 3 : Etat de l'art sur la maintenance des turbines a gaz en utilisant l'IA**

3.1.	L'évolution industrielle et l'industrie 4.0 .....	26
3.2.	Définition de la maintenance industrielle .....	26
3.3.	Les différents types de maintenance industrielle .....	27
3.4.	Démarche d'une approche de maintenance prédictive basée sur les données .....	27
3.5.	Maintenance prédictive et machines tournantes .....	29
3.6.	Les approches fondées sur les connaissances et les expériences .....	30
3.6.1.	Les approches basées sur des modèles physiques .....	30
3.6.2.	Les approches basées sur les données .....	30
3.7.	Conclusion .....	31
3.8.	L'Apprentissage Automatique (Machine Learning).....	32
3.8.1.	Apprentissage supervisé :.....	32
3.8.2.	Apprentissage non supervisé :.....	33
3.9.	Les Algorithmes d'apprentissage de ML.....	33
3.9.1.	Le Random Forest (forêt aléatoire) .....	34
3.9.2.	Régression logistique (Logistic Regression).....	34
3.9.3.	Extra Trees Classifier .....	35
3.9.4.	Bagging .....	36
3.9.5.	XGBoost.....	37
3.10.	L'apprentissage profond (Deep Learning).....	39
3.10.1.	Réseaux de neurones artificiels ANN.....	39

### **Chapitre 4 : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)**

4.1.	Processus d'apprentissage automatique (Workflow).....	42
4.2.	Collection des données .....	43
4.2.1.	Importation et préparation des données sur Python .....	44
4.3.	Description des Données.....	46
4.4.	Représentation des Données .....	49
4.5.	Corrélation des caractéristiques avec la condition.....	56
4.6.	La Construction des modèles d'intelligence artificielle (AI).....	57
4.7.	Les algorithmes de Machine Learning.....	58
4.8.	L'ensemble d'entraînement des trois modèles .....	59
4.9.	L'ensemble de Test des trois Modèles.....	60
4.9.1.	Test de Validation de XGBoost Classificateur.....	60
4.9.2.	Test de validation de Bagging .....	62
4.9.3.	Test de Validation de Extra Trees .....	65
4.10.	Conclusion .....	67
	<b>CONCLUSION GENERALE .....</b>	<b>68</b>
	<b>ANNEXE I.....</b>	<b>69</b>
	<b>ANNEXE II.....</b>	<b>70</b>

## **LISTE DES FIGURES**

Figure 1-1: Localisation géographique du champ de tiguentourine.....	4
Figure 1-2: La situation du champ de Tiguentourine en 2014 .....	5
Figure 1-3: La situation des différents puits au champ de Tiguentourine en 2015 .....	6
Figure 1-4 : Chemin de gaz d’In Amenas Project .....	7
Figure 1-5: Organigramme de la direction des opérations d’In-Amenas .....	8
Figure 2-1: Schéma d’une turbine à action et à réaction.....	11
Figure 2-2: Schéma de la Turbine mono- arbre .....	11
Figure 2-3: Schéma la de turbine à gaz bi- arbre .....	12
Figure 2-4: Cycle simple d'une turbine à Gas .....	12
Figure 2-5: Diagram T-S D'une turbine à sicle simple.....	13
Figure 2-6: Cycle Généré d'une turbine à Gas .....	13
Figure 2-7: le comportement des pressions et des températures, en termes de qualité, à l'intérieur des différentes sections de la machine correspondant aux phases de fonctionnement susmentionnées.....	14
Figure 2-8: Turbine à gaz à un seul arbre de la série lourde (MS 5001-26,8 MW) .....	15
Figure 2-9: Schéma de principe d'une turbine à gaz .....	16
Figure 2-10: Carter en deux moitiés de la turbine MS5001 .....	17
Figure 2-11: Compresseur axial .....	19
Figure 2-12: Chambre de combustion DL.....	20
Figure 2-13: Composants de la section de combustion.....	21
Figure 2-14: Disposition des distributeurs et ailettes de la turbine .....	23
Figure 3-1 : La révolution industrielle tirée de Rioux (2016) .....	26
Figure 3-2: Les étapes de création d'un modèle de prédiction Adapté de Wanga, Ghani, & Kalegele (2017) .....	28
Figure 3-3: Création d'un modèle d'apprentissage automatique Adapté de Wanga (2017) .....	29
Figure 3-4: Taxonomie des modèles d'apprentissages automatiques tirée de Jaber (2018) ....	33
Figure 3-5: Exemple du Random Forest (forêt aléatoire) .....	34
Figure 3-6: Exemple de la Régression logistique.....	35
Figure 3-7: Exemple du modèle Extra Trees .....	36
Figure 3-8: Exemple du modèle Bagging .....	37
Figure 3-9: Exemple du modèle XGB Classificateur.....	38
Figure 3-10: Les branches et sections des méthodes de calcul. ....	40
Figure 3-11: Architecture des réseaux neuronaux artificiels.....	40
Figure 4-1: Processus d'apprentissage automatique Workflow .....	43
Figure 4-2: Capteurs de déplacement tiré de Data Logger Inc (2016).....	44
Figure 4-3: Importation des données.....	44
Figure 4-4: Importation des données de Déplacement .....	45
Figure 4-5: Importation des données de Velocity .....	45
Figure 4-6: Importation des données d'Acceleration.....	46
Figure 4-7: Importation des données de pression d'huile et de la Charge de Générateur .....	46
Figure 4-8: Visualisation des données de Velocity.....	49
Figure 4-9: Visualisation des données d'Accélération .....	49

Figure 4-10: Visualisation des données de pression et de la charge. ....	50
Figure 4-11: Visualisation des données de Déplacement.....	51
Figure 4-12: Description de l'anatomie du Box Plot.....	52
Figure 4-13: Box Plot pour la somme des différences consécutives de Velocity .....	53
Figure 4-14: Box Plot pour la somme des différences consécutives d'Accelération .....	53
Figure 4-15: Box Plot pour la somme des différences consécutives de Déplacement.....	54
Figure 4-16: Box Plot pour la somme des différences consécutives des pressions et de la Charge .....	55
Figure 4-17: Les résultats obtenus pour la variable "Condition" .....	56
Figure 4-18: diagramme de corrélation des caractéristiques avec la condition .....	56
Figure 4-19: La précision des algorithmes de ML expérimenter .....	58
Figure 4-20: Précision sur l'ensemble d'entraînement des trois modèles.....	59
Figure 4-21: Matrice de confusion – Entraînement des trois modèles.....	59
Figure 4-22: Comparaison entre les valeurs réelles et prédites par le XG Boost.....	60
Figure 4-23: La matrice de confusion de la performance du modèle XGB .....	61
Figure 4-24: Comparaison entre les valeurs réelles et prédites par le Bagging .....	63
Figure 4-25: La matrice de confusion la performance du modèle Bagging.....	64
Figure 4-26: Comparaison entre les valeurs réelles et prédites par le Extra Trees .....	65
Figure 4-27: La matrice de confusion la performance du modèle Extra Trees.....	66

## **LISTE DES TABLEAUX**

Table 4-1: Les Données utilisés dans le système de maintenance prédictive de la turbine à gaz MS5001 .....	47
Table 4-2: Indicateurs supplémentaires sur de modèle XGB.....	61
Table 4-3: Indicateurs supplémentaires sur de modèle Bagging.....	63
Table 4-4: Indicateurs supplémentaires sur de modèle Extra Trees.....	65

## **LISTE DES ABRÉVIATIONS ET ACRONYMES**

**ANN** : Artificial Neural Network

**DL**: Deep Learning

**DT**: Decision Tree

**GTG**: Gas Turbine Generator

**IA**: Intelligence Artificiel

**IoT**: Internet of Things

**KNN**: K - Nearest Neighbors

**LR**: Logistic Regression

**ML**: Machine Learning

**MP**: Maintenance Prédictive

**RF**: Random Forest

**SVM**: Support Vector Machine

**XGB**: eXtreme Gradient Boosting

# INTRODUCTION GENERALE

Les turbines à gaz sont des composants essentiels dans de nombreuses industries, notamment dans la production d'électricité dans les installations pétrochimiques. Assurer leur fonctionnement optimal est crucial pour garantir une production d'énergie efficace et fiable. Cependant, les turbines à gaz sont soumises à des contraintes extrêmes et sont sujettes à l'usure, aux défaillances et à la dégradation des performances au fil du temps.

La maintenance des turbines à gaz a été traditionnellement réalisée de manière préventive ou réactive. Cela signifie que les interventions de maintenance étaient planifiées à intervalles réguliers ou effectuées uniquement lorsque des pannes se produisaient. Cependant, ces approches peuvent être coûteuses en termes de temps d'arrêt de l'équipement et de coûts de maintenance. De plus, elles peuvent ne pas détecter les problèmes potentiels avant qu'ils ne deviennent critiques, entraînant ainsi des pannes imprévues et des perturbations dans les opérations de production.

C'est dans ce contexte que la maintenance prédictive et la surveillance de la condition basée sur l'intelligence artificielle (IA) ont apparu comme des approches prometteuses pour optimiser les performances des machines tournantes et en particulier les turbines à gaz. La maintenance prédictive vise à anticiper les défaillances et les pannes en utilisant des données en temps réel et des techniques d'analyse avancées. L'utilisation de l'Intelligence Artificielle (IA) comme outil dans la maintenance préventif, en particulier l'apprentissage automatique, permet d'extraire des modèles et des informations utiles à partir des données collectées, facilitant ainsi la détection précoce des anomalies.

Dans le cadre de cette étude, notre objectif vise à développer un système de surveillance d'état pour les turbines à gaz en utilisant des techniques d'IA avancées. Ce système permettra de détecter les signes avant-coureurs de défaillances et de la dégradation des performances des machines, offrant ainsi une opportunité d'intervention précoce pour éviter les pannes majeures et les coûts de maintenance élevés.

Ce système de surveillance va permettre aux équipes de maintenance et opérateurs d'anticiper les problèmes potentiels, d'optimiser les calendriers de maintenance et d'améliorer la disponibilité et la fiabilité des turbines à gaz.

## 1. PRESENTATION ET HISTORIQUE DE CHAMP

### 1.1.Introduction

Le gaz naturel est la source d'énergie fossile qui a connu la plus forte progression depuis les années 70. Elle représente le cinquième de la consommation énergétique mondiale. En raison de ses avantages économiques le gaz naturel devient chaque jour plus attractif surtout pour les pays occidentaux. Les propriétés de ce produit, comme par exemple le faible intervalle de combustion qui le caractérise, en font l'une des sources d'énergie les plus fiables connue à ce jour. Il représente la deuxième source d'énergie la plus utilisée après le pétrole. D'après le Département américain de l'énergie (EIA), la part du gaz naturel dans la production énergétique mondiale était de 22% en 2004 et les perspectives de développement de la demande sont excellentes il présente un avantage concurrentiel par rapport aux autres sources d'énergie.

En outre, les progrès technologiques améliorent constamment l'efficacité des techniques d'extraction, de transport et de stockage ainsi que le rendement énergétique des équipements fonctionnant à base de gaz naturel.

Le site d'IN AMENAS « TIGUENTOURINE » est un parfait exemple pour illustrer le traitement et la production de gaz naturel. Ce site est un point de production important pour l'économie de l'Algérie.

### 1.2.Présentation et historique du champ

#### 1.2.1. Présentation

Le champ de Tiguentourine a été découvert en 1957 par les premiers puits d'exploration. Le puits TG 2, qui était l'un des premiers puits forés, a révélé une importante quantité de gaz humide dans le Cambro-ordovicien, suivi de plusieurs autres puits producteurs appartenant à la SONATRACH, à l'arrivée de l'association SONATRACH/ BP/ Statoil en 1998, cette dernière a transformé ces puits SONATRACH en monitoring et a commencé le développement du champ par le forage et la ré-complétion de nouveaux puits.

La productivité du réservoir de cette région est caractérisée par la petro physiques suivante:

Alpha : zone avec une perméabilité  $> 1\text{mD}$  et une Porosité  $>5\%$

Beta : zone une perméabilité  $< 1\text{mD}$  et une Porosité  $> 5\%$

La fracturation hydraulique ait venue au secours des zones à faible perméabilité (Beta), c'est depuis la fin des années 90' que cette alternative a permis d'augmenter la production de cette zone de 2 à 25 MM3/jour. Ainsi la fracturation hydraulique permet de réduire le phénomène de condensation rétrograde dans les puits par l'augmentation de la pression du fond.

L'association dans le champ TIGUENTOURINE :

Depuis 1998 SONATRACH /BP/ STATOIL ont signé un contrat de 25 ans pour l'objectif d'exploitation des richesses hydrocarbures, canalisation transport.

➤ SONATRACH



**SO: SOCIETE / NA: NATIONALE / TRA: TRANSPORT**

**C: COMMERCIALISATION / H : HYDROCARBURES**

## Chapitre I : Présentation et historique du champ

---

SONATRACH est la compagnie algérienne de recherche, d'exploitation, de transport par canalisation, de transformation et de commercialisation des hydrocarbures et de leurs dérivés. Elle intervient également dans d'autres secteurs tels que la génération électrique, les énergies nouvelles et renouvelables et le dessalement d'eau de mer. Elle exerce ses métiers en Algérie et partout dans le monde où des opportunités se présentent.

L'entreprise nationale pétrolière et gazière SONATRACH a été créée en 1963. Aujourd'hui elle emploie plus de 35000 personnes et se retrouve en position de jouer un rôle important dans l'économie nationale. Ce qui lui a permis d'occuper le 11<sup>ème</sup> rang parmi les grandes compagnies pétrolières internationales.

➤ **British Petroleum** : 

La société BP est une compagnie britannique de recherche, d'extraction, de raffinage et de vente de pétrole fondée. Elle est la plus grande société du Royaume-Uni et la troisième compagnie pétrolière mondiale.

BP est présente dans plus de cent pays et emploie environ cent quinze mille personnes.

  
**Statoil** : Statoil

Statoil est une compagnie pétrolière norvégienne fondée en 1972. C'est la plus grande entreprise de Norvège avec environ 29 000 employés. Statoil est basée dans la capitale norvégienne du pétrole. Le nom Statoil vient d'une contraction de « Statoil » ou Pétrole d'État.

Le groupe est devenu l'un des plus grands vendeurs de pétrole brut au monde, ainsi qu'un important fournisseur de gaz naturel du continent européen. Statoil possède également un réseau de 2000 stations-service dans neuf pays.

### 1.2.2. Situation géographique

Le champ de Tiguentourine est situé dans la partie Sud du bassin d'Illizi, à environ 850 Km au Sud de la ville de Hassi Messaoud et à 40 Km au Sud-Ouest de la ville d'In Amenas et 70 km à l'ouest du champ d'Edjeleh et 20 km au sud-ouest de celui de La Reculée. Tiguentourine est recouvert en partie par l'Erg Bourarhet. Le champ est rocailleux d'où l'origine de son nom Targui Tiguentourine signifiant les torrents.

Sa localisation en coordonnées Lambert est la suivante :

\* X= 492500 à 532500 Est.

\* Y= 3055000 à 3100000 Nord.

En coordonnées géographiques :

\* Au Nord par la latitude 28°00.

\* Au Sud par la latitude 27°30.

\* A l'ouest par la longitude 9°00.

# Chapitre I : Présentation et historique du champ

\* A l'Est par la longitude 9°30.

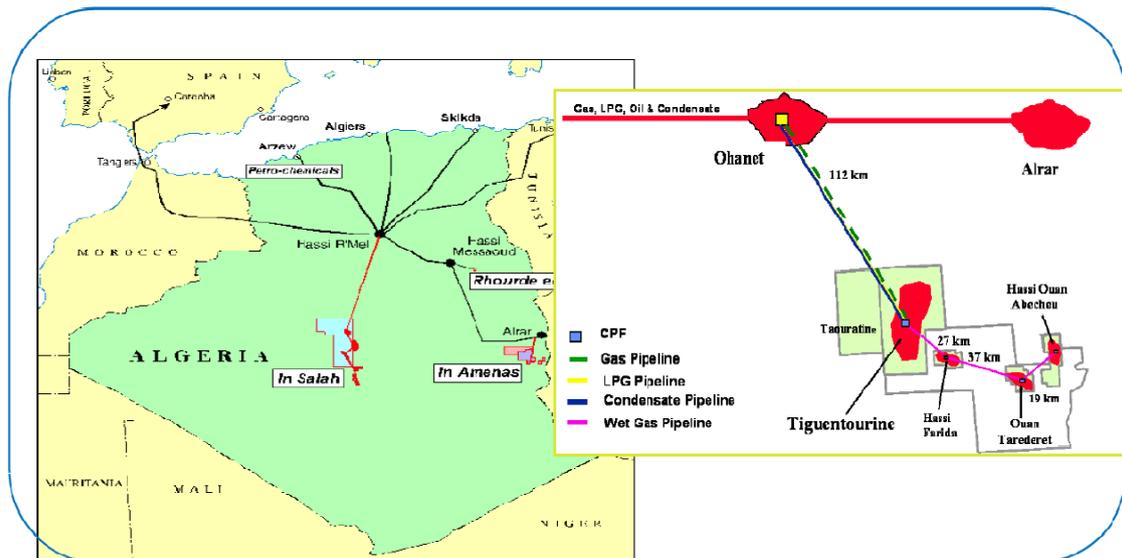


Figure 1-1: Localisation géographique du champ de Tigentourine

## 1.2.3. Historique du champ

La région de Tigentourine se compose de deux réservoirs d'huile qui sont le carbonifère D2, D4, D6 et le Dévonien F2, F4, F6, dans les champs satellites (Hassi Farida, Ouan Taredert, et Hassi Ouan Abecheu), qui se trouvent immédiatement au sud-est. Et un réservoir cambro-ordovicien de gaz à condensat dans les champs Tigentourine et La Reculée.

L'accumulation de gaz à condensat de Tigentourine (TG) a été découverte en 1957 ; par le forage du puits Tigentourine 2 (TG 2). Les horizons de gaz peu profonds ont été exploités depuis 1962. En 1995/1996 ; six puits ont été fracturés hydrauliquement, avec des taux de 2 à 5MMCF / D. En 1999/2000, cinq puits ont été produits pour écoulement étendue et s'accumulent fois et un programme d'échantillonnage de fluide complet a été entrepris.

Le forage de développement a commencé en Juin 2001. A partir de Mars 2003, neuf (9) puits ont été forés et testés. Par conséquent, 8 puits ont été complétés pour la production au cours du programme de développement, les puits sont mis en production en 2005.

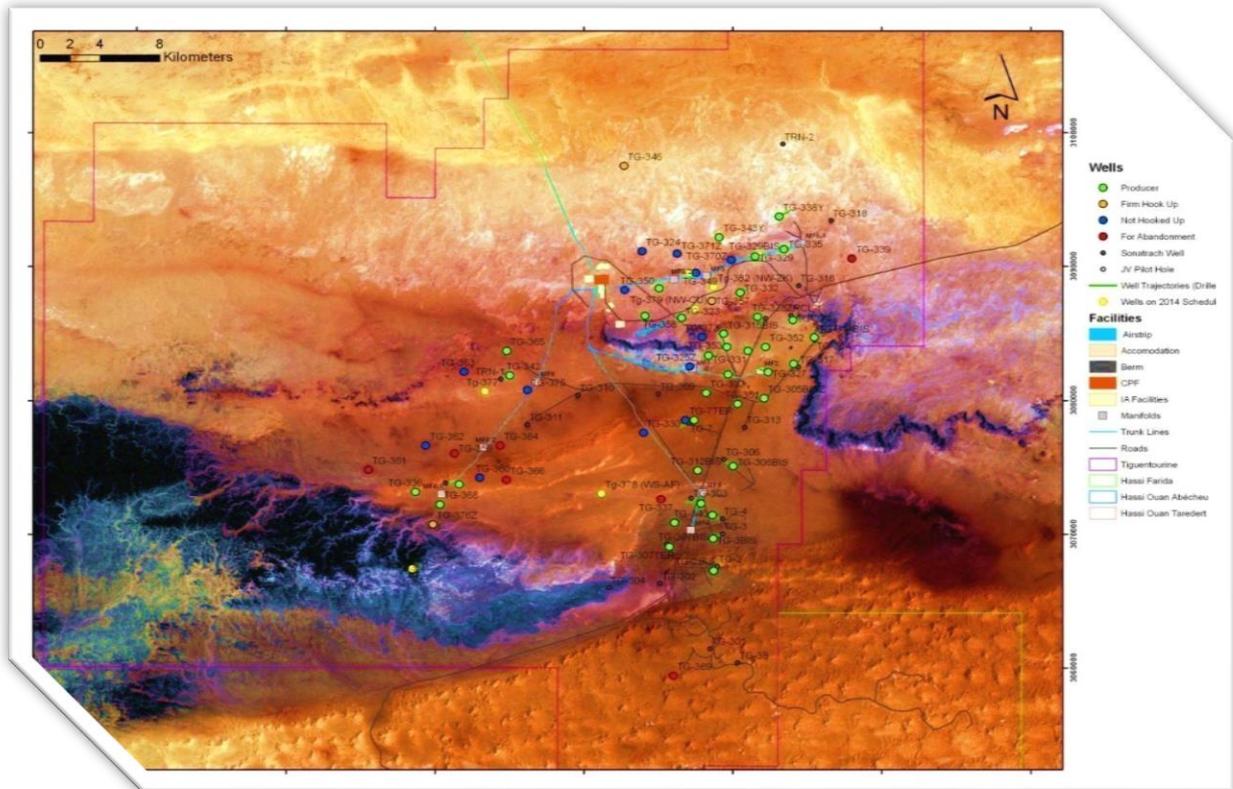
Les puits du champ nord (16 puits producteurs) sont reliés aux Manifolds MF1, MF2 et MF5.

Les puits du champ sud (7 puits producteurs) sont reliés aux MF3 et MF4.

La figure suivante c'est un schéma descriptif de la situation des différents puits dans les différents champs.

Lors des tests, le débit d'eau était si faible 3m<sup>3</sup>/jour, ce qui ne reflète pas la présence d'un aquifère.





**Figure 1-3:** La situation des différents puits au champ de Tiguentourine en 2015

### 1.2.5. Caractéristiques de réservoir

Le réservoir de gaz à condensat exploité dans la région de Tiguentourine est caractérisé par une roche Cambro-ordovicien gréseuse (environ 500 Million années) avec les caractéristiques suivantes :

- Des puits à moyenne profondeur d'environ 2200m.
- Une épaisseur du réservoir qui varie entre 20 - 200m.
- Sédiments Marins et terrestres.
- Très hétérogène.
- Pas d'aquifère.
- Une importante présence de failles (2 failles).
- Une perméabilité qui peut atteindre 2 Darcy.
- La porosité  $> 5\%$ .
- La température varie de 110 et 125 C°
- Une pression initiale du gisement estimée est de 3200 psi.
- Compressibilité de la Roche.

## Chapitre I : Présentation et historique du champ

### 1.2.6. Historique de la production

Le réservoir est constitué de deux couches : MS2 (Supérieur) et MS1 (inférieur). Les 47 puits sont forés par l'association JVGAS (Joint-Venture Gaz) et répartis sur 06 manifolds, dénommés 1, 2, 3, 4, 5 et 6.

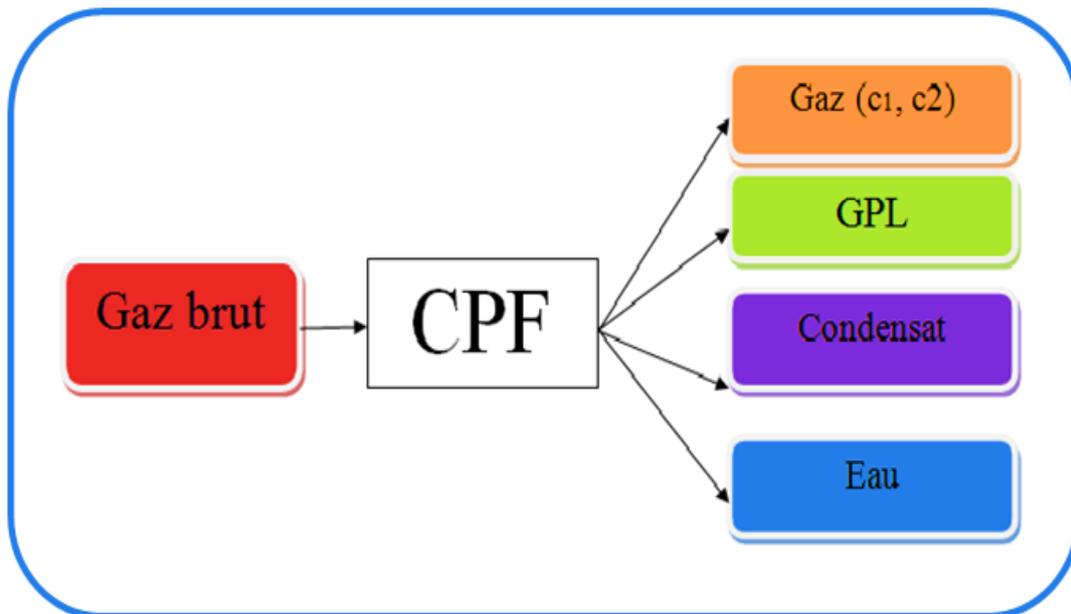
- Les manifolds 01, 02 et 05 sont au Nord.
- Les Manifold 03 et 04 sont au Sud.
- Le manifold 06 est au Sud-ouest.

Le potentiel Maximum actuel du champ est de 31 Mm<sup>3</sup>/jours de gaz à condensat.

Puits producteurs :

Actuellement le champ de Tiguentourine contient Seulement **49** puits qui sont mis en production. La profondeur moyenne des puits est de 2200 m, permettant ainsi d'exploiter un réservoir composé.

Le gaz brut produit est acheminé du puits vers le manifold, pour atteindre les Installations centrales de traitement le CPF (Central Processing Facility) qui séparent le gaz et les produits liquides et les livrent aux lignes d'exportation, un produit pré-raffiné peut donc être transporté jusqu'au point de livraison final au Nord du pays.



**Figure 1-4** : Chemin de gaz d'In Amenas Project

## 1.3. Conclusion

L'objectif principal de l'usine CPF est de maximiser la production des hydrocarbures (condensat, Gaz et GPL), pour augmenter les revenus de l'économie nationale.

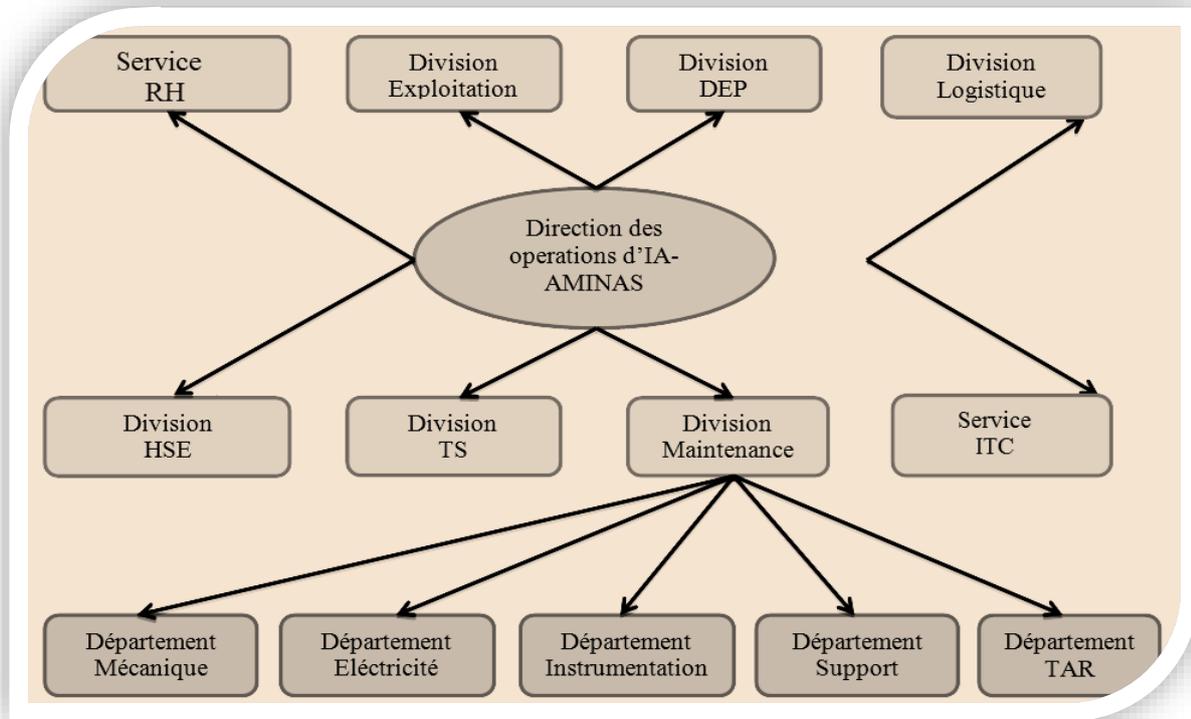


Figure 1-5: Organigramme de la direction des opérations d'In-Amenas

## 2. INTRODUCTION SUR LES TURBINES

### 2.1. Introduction

Une turbine à gaz est un type de moteur qui convertit l'énergie d'un flux de gaz en travail mécanique. Elle fonctionne selon le principe du cycle de Brayton, qui consiste à comprimer l'air, à ajouter du combustible et à l'enflammer, puis à détendre le gaz à haute température à travers une turbine pour produire de l'énergie.

Dans une turbine à gaz, l'air atmosphérique est aspiré dans un système d'admission et comprimé par un compresseur. L'air comprimé est ensuite dirigé vers une chambre de combustion où le carburant est injecté et mélangé à l'air comprimé. Le mélange air-carburant est enflammé, ce qui crée un flux de gaz à haute température. Ce gaz chaud se dilate à travers une série d'aubes de turbine, ce qui les fait tourner. La rotation de la turbine est utilisée pour entraîner un arbre de sortie qui peut être connecté à divers dispositifs, tels que des générateurs électriques ou des hélices d'avion, pour produire un travail mécanique.

Les turbines à gaz offrent plusieurs avantages, notamment un rapport poids/puissance élevé, une taille compacte, des capacités de démarrage et d'arrêt rapides et de faibles émissions par rapport à d'autres types de moteurs. Elles sont utilisées dans diverses applications, telles que la production d'électricité dans des systèmes centralisés et distribués, la propulsion d'aéronefs et les processus industriels nécessitant une puissance mécanique.

Les turbines à gaz peuvent fonctionner avec différents carburants, notamment le gaz naturel, le diesel et même des sources renouvelables comme le biogaz. Elles sont connues pour leur efficacité et leur fiabilité, ce qui en fait un choix populaire dans de nombreuses industries.

Les turbines à gaz sont très utiles dans l'industrie car ce sont des dispositifs qui génèrent de l'énergie mécanique. Ils peuvent être utilisés dans nombreuses industries :

#### **Application Fixes :**

Ces applications sont destinées aux usages industriels suivants :

- Entraînement de générateurs, afin de produire de l'énergie électrique par un cycle ouvert.
- Entraînement de générateur, pour produire de l'énergie électrique par un cycle combiné.
- Entraînement de générateur, pour produire de l'énergie électrique par cogénération.
- Entraînement de compresseur - Entraînement de pompe.
- Entraînement du compresseur de pipeline.
- Entraînement de pompe par pipeline.
- Processus industriel particulier.

#### **Application Mobiles :**

Ces applications ont été les premières à être introduites en termes de temps. Elles comprennent les domaines suivants :

- chemins de fer.
- la propulsion marine.
- l'aviation et la traction routière.

### 2.2. Historique des turbines à gaz

Les premières turbines à gaz sont apparues sur le marché à la fin des années 1940 ; elles étaient généralement utilisées dans les chemins de fer et avaient l'avantage de brûler du carburant liquide, même de faible qualité (en raison des limitations des processus de raffinage). La turbine MS3001 construite par GE, d'une puissance de 3 312 MW, était spécifiquement utilisée pour les services de locomotive.

Les progrès réalisés dans la technologie des matériaux et dans la recherche approfondie sur la combustion ont permis des améliorations rapides des performances de ces machines, en termes de puissance spécifique et d'efficacité, obtenues en augmentant les températures maximales dans le cycle thermodynamique.

Dans ce domaine, on peut distinguer trois générations, différenciées par les plages de température maximale (en °C) des gaz à l'entrée du premier étage du rotor de la turbine :

- 1e génération :  $760 < T_{max} < 955$
- 2e génération :  $955 < T_{max} < 1124$
- 3e génération :  $1149 < T_{max} < 1288$

Évidemment, l'augmentation de la température d'entrée à la première turbine a eu comme effet une augmentation du rendement thermodynamique, qui est passé des valeurs inférieures à 20% dans les premières machines, à des valeurs courantes supérieures à 40% (turbine à gaz LM6000).

### 2.3. Classification des turbines à gaz

On peut classer les turbines selon différents modes :

- Le mode de travail.
- Le mode de fonctionnement thermodynamique.
- Le mode de construction.

#### 2.3.1. Par le mode de travail

##### a. Turbine à action :

Le principe de fonctionnement d'une turbine à action est que la transformation thermodynamique du fluide se produit uniquement dans le directeur (entre les aubes fixes). Les aubes mobiles n'ont qu'un rôle à jouer, qui est de transformer l'énergie cinétique acquise lors de l'expansion ( $P_1 > P_2$ ) en travail mécanique transmis au rotor. L'évolution des gaz dans la roue est réalisée sans variation de pression statique ( $P_1 = P_2$ ).

##### b. Turbine à réaction :

Dans les turbines à réaction, nous savons que la détente se produit à la fois dans les canaux fixes et dans les canaux mobiles, c'est-à-dire qu'une partie de l'énergie thermique est convertie en énergie cinétique et mécanique dans la roue. L'évolution des gaz dans la roue s'accompagne d'une variation de la pression statique ( $P_1 > P_2 > P_3$ ).

## Chapitre II : Introduction sur les turbines

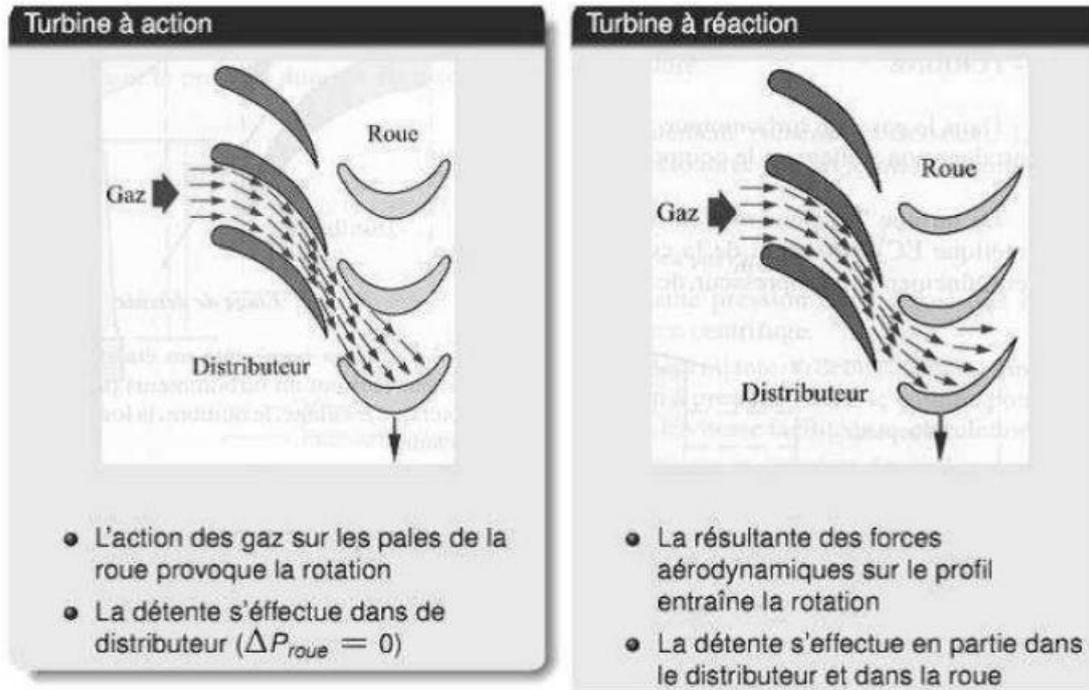


Figure 2-1: Schéma d'une turbine à action et à réaction.

### 2.3.2. Par le mode de Construction

#### a. Turbine mono-arbre :

Le compresseur et la turbine sont montés sur le même arbre, ce qui leur permet de tourner à la même vitesse. Ce type est utilisé pour des applications ne nécessitant pas de variations de vitesse, telles que l'entraînement de générateurs pour la production d'électricité.

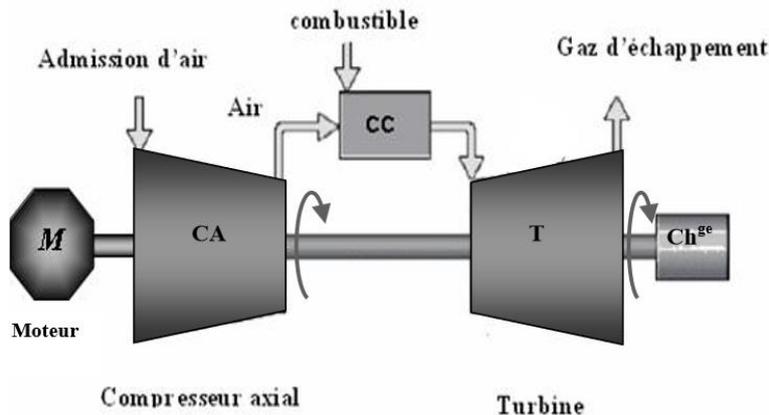


Figure 2-2: Schéma de la Turbine mono- arbre

#### b. Turbine Bi-arbre :

Les deux sections de la turbine ne sont pas mécaniquement connectées, ce qui leur permet de tourner à des vitesses différentes. Ce type est utilisé dans des applications qui nécessitent une large variation de vitesse, comme l'entraînement de compresseurs. Le

## Chapitre II : Introduction sur les turbines

compresseur et l'impulseur haute pression (TE1) sont appelés générateurs de gaz, généralement la vitesse du générateur de gaz est constante, mais la vitesse de l'impulseur basse pression (TE2) varie en fonction de la vitesse de la machine.

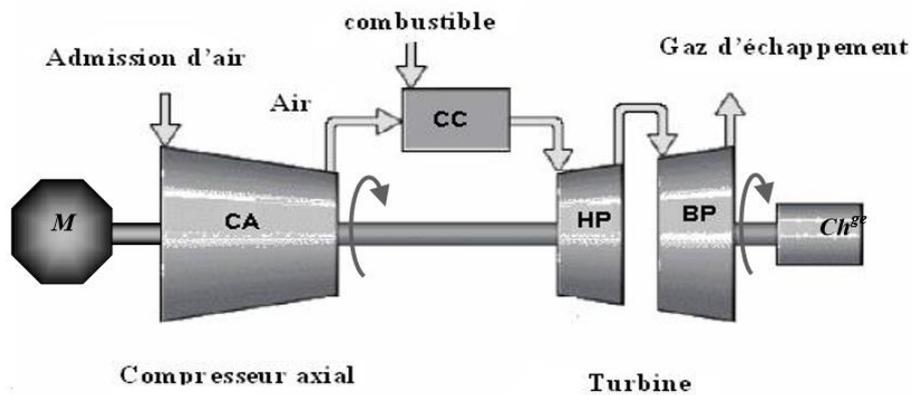


Figure 2-3: Schéma la de turbine à gaz bi- arbre

### 2.3.3. Par le mode de fonctionnement thermodynamique

La turbine à gaz à cycle ouvert dont l'admission et l'échappement s'effectuent directement dans l'atmosphère. Ce type de turbine, le plus répandu, est divisé en deux catégories : la turbine à cycle simple et la turbine à cycle régénéré ou mixte.

#### a. Turbine à cycle simple :

C'est une turbine qui utilise un seul fluide pour générer de l'énergie mécanique après détente, et le gaz, qui a encore un potentiel énergétique, est rejeté dans l'atmosphère par une cheminée.

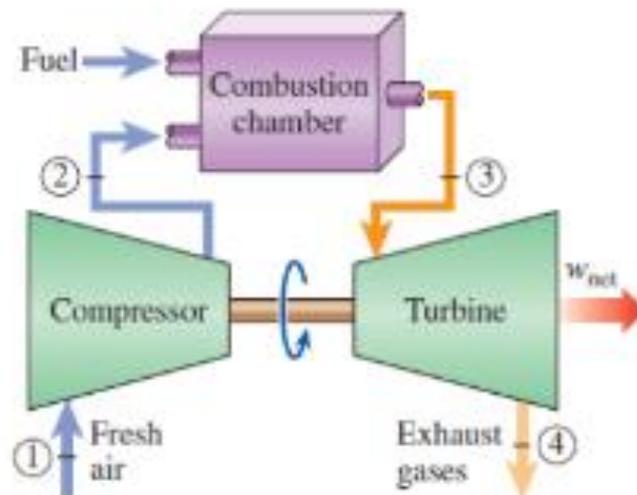


Figure 2-4: Cycle simple d'une turbine à Gas

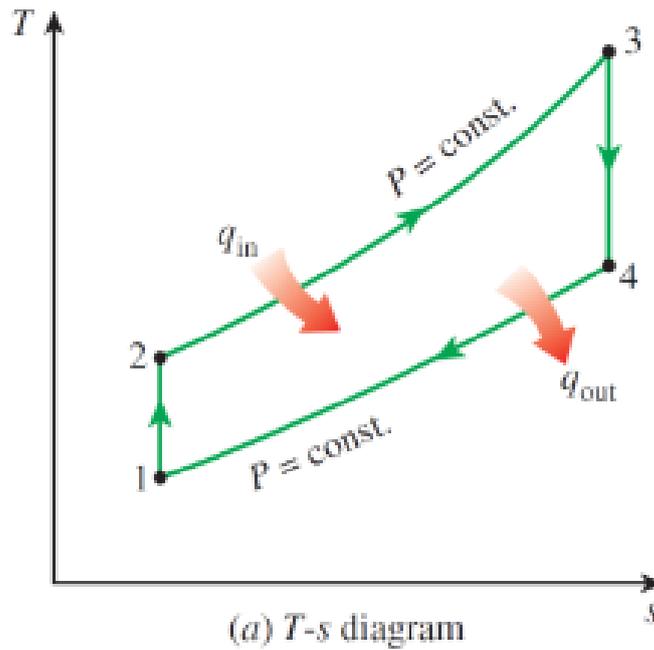


Figure 2-5: Diagram T-S D'une turbine à sicle simple

**b. Turbine à cycle régénéré :**

C'est une turbine dont le cycle thermodynamique fait intervenir plusieurs fluides moteurs, dans le but d'augmenter le rendement de l'installation.

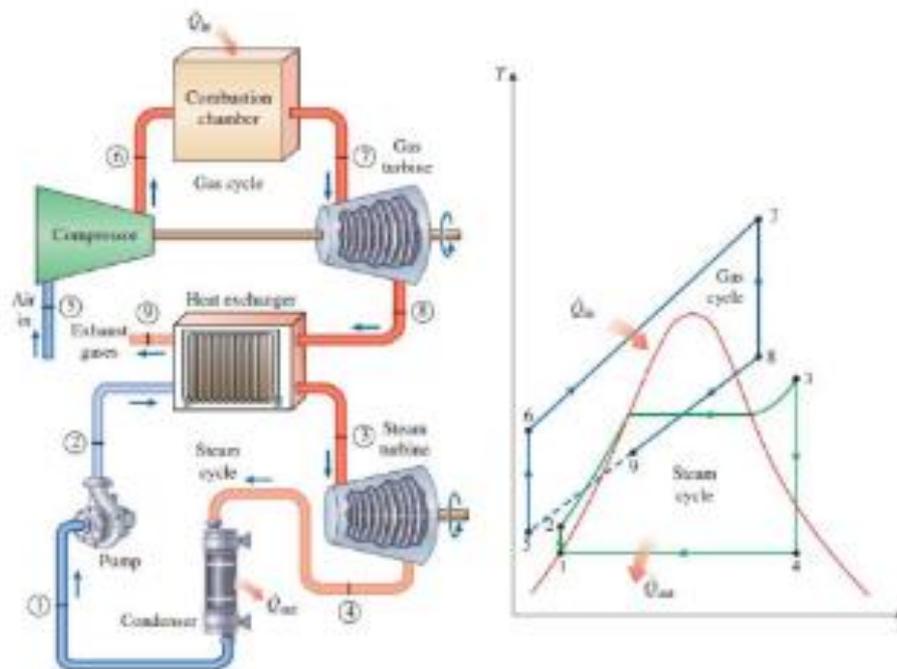
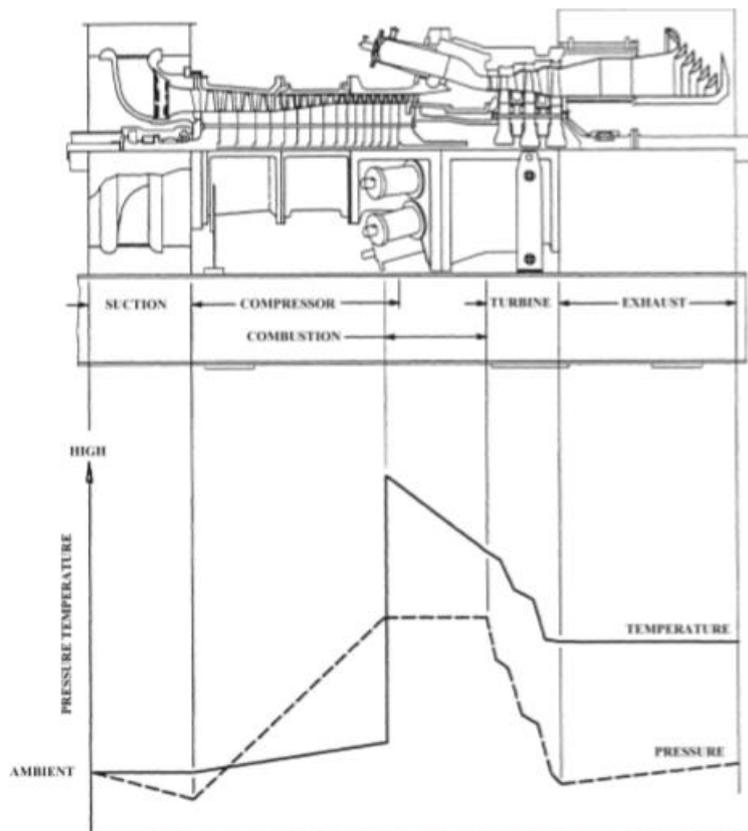


Figure 2-6: Cycle Généré d'une turbine à Gas

### 2.4.Principe de fonctionnement des turbines à gaz

Une turbine à gaz fonctionne de la manière suivante :

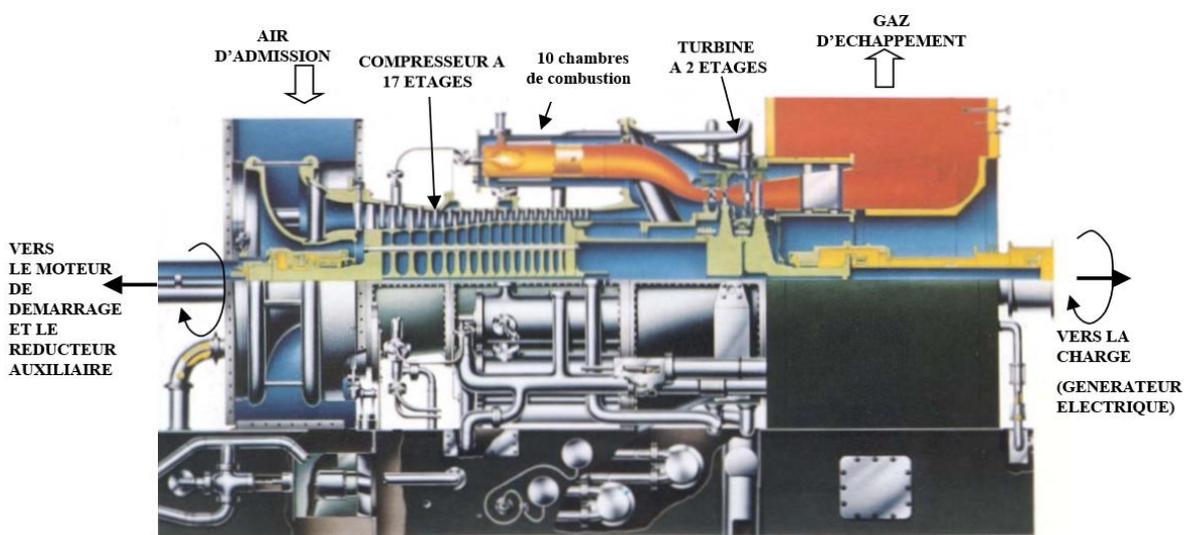
- Elle aspire l'air du milieu environnant ;
- Elle le comprime à une pression plus élevée ;
- Elle augmente le niveau d'énergie de l'air comprimé par l'ajout d'un gaz combustible qui subit une combustion dans une chambre de combustion ;
- Il dirige l'air à haute pression et à haute température vers une section de turbine, qui convertit l'énergie thermique en énergie mécanique qui fait tourner l'arbre ; cela sert, d'une part, à fournir de l'énergie utile à la machine entraînée, couplée à la machine au moyen d'un accouplement et, d'autre part, à fournir l'énergie nécessaire à la compression de l'air, qui s'effectue dans un compresseur relié directement à la section de turbine elle-même ;
- Il expulse dans l'atmosphère les gaz à basse pression et à basse température résultant du processus de transformation susmentionné.



**Figure 2-7:** le comportement des pressions et des températures, en termes de qualité, à l'intérieur des différentes sections de la machine correspondant aux phases de fonctionnement susmentionnées.

### 2.5. Description de la Turbine à Gaz MS5001

La turbine à arbre unique MS5001 est une turbine compacte à usage intensif conçue pour une longue durée de vie et une maintenance aisée. La turbine à gaz MS5001 est la solution idéale pour la production d'électricité industrielle où une maintenance réduite, la fiabilité et l'économie d'utilisation du combustible sont requises. Les faibles coûts d'investissement font de la centrale MS5001 un système économiquement attractif pour la production d'électricité en période de pointe. Le MS5001 est parfaitement adapté à la cogénération et permet d'atteindre des indices d'utilisation du combustible très élevés et de réaliser des économies de combustible considérables. Les applications typiques sont les installations industrielles pour la cogénération d'électricité et de vapeur industrielle ou les systèmes de chauffage urbain.



**Figure 2-8:** Turbine à gaz à un seul arbre de la série lourde (MS 5001-26,8 MW)

#### Informations sur la conception :

Compresseur :

- Compresseur à flux axial, 17 étages
- Rapport de pression 10,5:1

Combustion:

- Combustion can-annulaire, 10 chambres

Turbine:

- 2 étages
- Tuyères du premier étage refroidies

Ensemble :

- Turbine complète montée sur une seule plaque de base
- Enceinte intégrée à la plaque de base offrant une accessibilité maximale pour la maintenance de la turbine à gaz et des auxiliaires.
- Configuration standard (à l'exclusion des conduits d'admission/évacuation/système) :

## Chapitre II : Introduction sur les turbines

- dimensions :  $L \times L \times H = 11,6 \text{ m} \times 3,2 \text{ m} \times 3,7 \text{ m}$  ;
- Le poids 87,5 t

Contrôle des émissions :

- Systèmes d'injection de vapeur ou d'eau pour la réduction des NOx
- Système de combustion sèche à faible taux de NOx (DLN)

### 2.6.Principe de Fonctionnement de la Turbine à Gaz MS5001

La turbine à gaz 5001 fonctionne selon le principe du cycle Brayton. Tout d'abord, de l'air ambiant est aspiré et comprimé par un compresseur, augmentant ainsi la pression. Ensuite, le carburant est injecté dans la chambre de combustion, où il est mélangé avec l'air comprimé et brûlé. Cette combustion libère une grande quantité d'énergie thermique, générant des gaz chauds à haute pression. Ces gaz à haute pression sont dirigés vers la turbine, où ils se détendent et transfèrent leur énergie cinétique à la turbine. La turbine est composée de plusieurs étages, chacun étant équipé d'aubes qui captent l'énergie des gaz en expansion pour entraîner l'arbre de la turbine. L'arbre de la turbine est relié à diverses charges, telles que des générateurs électriques ou des compresseurs, transformant ainsi l'énergie cinétique en énergie mécanique utile. Finalement, les gaz d'échappement à basse pression sont rejetés dans l'atmosphère, où ils se dissipent. Ce processus permet à la turbine à gaz 5001 de convertir efficacement l'énergie chimique du carburant en énergie mécanique, en offrant une source d'énergie polyvalente pour diverses applications industrielles et de production d'électricité.

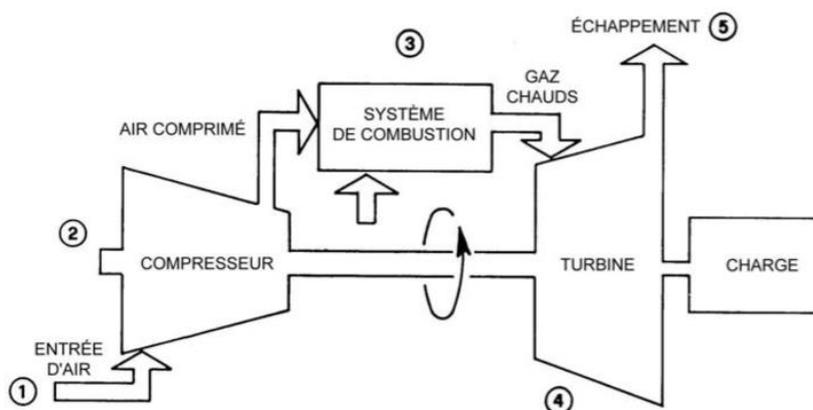


Figure 2-9: Schéma de principe d'une turbine à gaz

### 2.7. Sections principales d'une installation de turbine à gaz

#### 2.7.1. Section compresseur

Le compresseur axial comprend le rotor et le carter de compresseur, l'aubage directeur d'entrée, et deux aubages directeurs de sortie. Dans le compresseur, l'air introduit est confiné dans l'espace entre le rotor et le stator, étant comprimé d'un étage à l'autre au moyen d'une série alternée d'ailettes tournantes (rotor) et d'ailettes stationnaires (stator) à profil aérodynamique. Les ailettes du rotor fournissent la force nécessaire pour comprimer l'air à chaque étage, et les ailettes du stator orientent le flux d'air afin qu'il pénètre dans l'étage stationnaire suivant sous un angle approprié. L'air comprimé sort par le carter de refoulement du compresseur pour être introduit dans les chambres de combustion. De l'air est également extrait du compresseur pour assurer le refroidissement de la turbine et l'étanchéité de joint d'huile de palier.

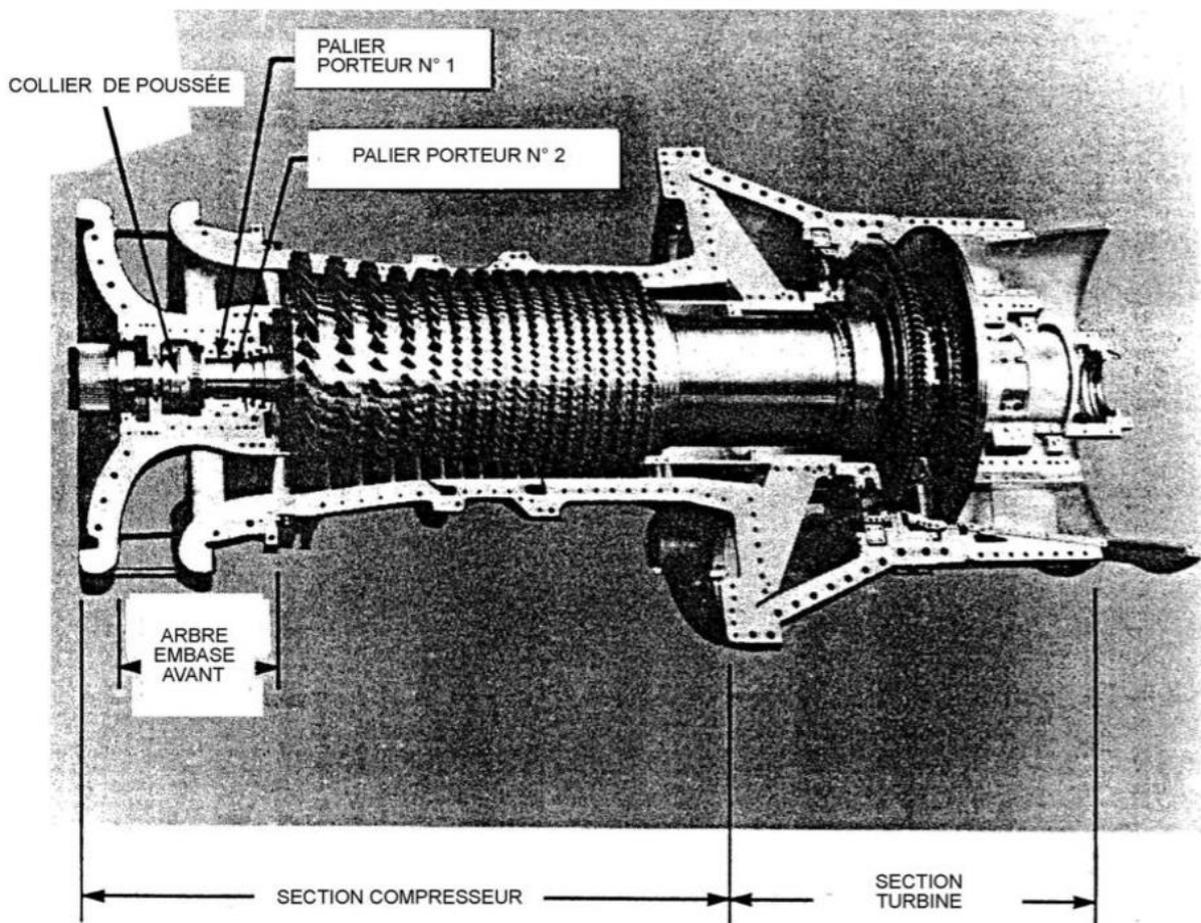


Figure 2-10: Carter en deux moitiés de la turbine MS5001

#### a. Le Rotor :

Le rotor d'une turbine à gaz est composé d'un assemblage de roues et d'un faux-arbre à l'avant, maintenus ensemble par des tirants d'assemblage. Chaque roue et la partie à roue du faux-arbre avant ont des encoches sur leur périphérie, où les ailettes du rotor de compresseur sont

## Chapitre II : Introduction sur les turbines

---

insérées et fixées axialement par des pièces d'espacement. Ces ailettes sont conçues avec un profil aérodynamique pour une compression efficace à haute vitesse. Les roues et le faux-arbre sont assemblés avec des emboîtements appariés pour garantir leur concentricité et sont maintenus ensemble par les tirants. Lors de l'assemblage, les roues sont positionnées de manière sélective pour réduire les corrections d'équilibrage. Une fois assemblé, le rotor est soumis à un équilibrage dynamique. Le faux-arbre avant est usiné pour inclure le collet de poussée qui supporte les charges avant et arrière, le tourillon du palier n° 1, la surface d'étanchéité pour les joints d'huile du palier n° 1 et le joint d'air basse pression du compresseur.

### **b. Stator :**

Il englobe les sections du compresseur et de la turbine, et est constitué des carters d'admission, avant, arrière et d'échappement. Chacun de ces carters est divisé en deux parties, avec un plan de jonction horizontal, ce qui facilite les opérations de maintenance.

### **c. Carter d'aspiration :**

Il oriente l'air extérieur provenant de l'équipement d'admission d'air et le dirige vers les ailettes du compresseur. Cette section comprend l'aubage directeur d'entrée, le palier n° 1 et les joints d'air basse pression. Sur les modèles N et P, ainsi que sur certains compresseurs de modèle R, l'aubage directeur d'entrée peut être orienté grâce au système de commande.

### **d. Carter avant :**

La section avant du carter du compresseur est située après la section d'admission. Elle abrite les ailettes fixes des étages 0 à 3. L'air extrait du troisième étage du rotor (entre les étages 2 et 4 du stator) s'écoule à travers quatre orifices situés sur le pourtour de la section arrière du carter du compresseur.

### **e. Carter arrière :**

La section arrière, qui se trouve après la section avant, abrite les ailettes fixes des étages 4 à 9 du stator. L'air extrait du 10e étage du rotor (entre les étages 9 et 10 du stator) s'écoule à travers quatre orifices alignés axialement avec les orifices utilisés pour l'extraction de l'air du 4e étage.

### **f. Carter de refoulement :**

La section de refoulement du carter de compression contient les ailettes fixes des étages 10 à 15 et les aubages directeurs de sortie. Une cloison centrale évasée soutient les chambres de combustion, entourée de montants profilés. L'espace annulaire entre l'enveloppe interne et le carter extérieur permet à l'air comprimé d'entrer dans la section de combustion avec une pression statique accrue.

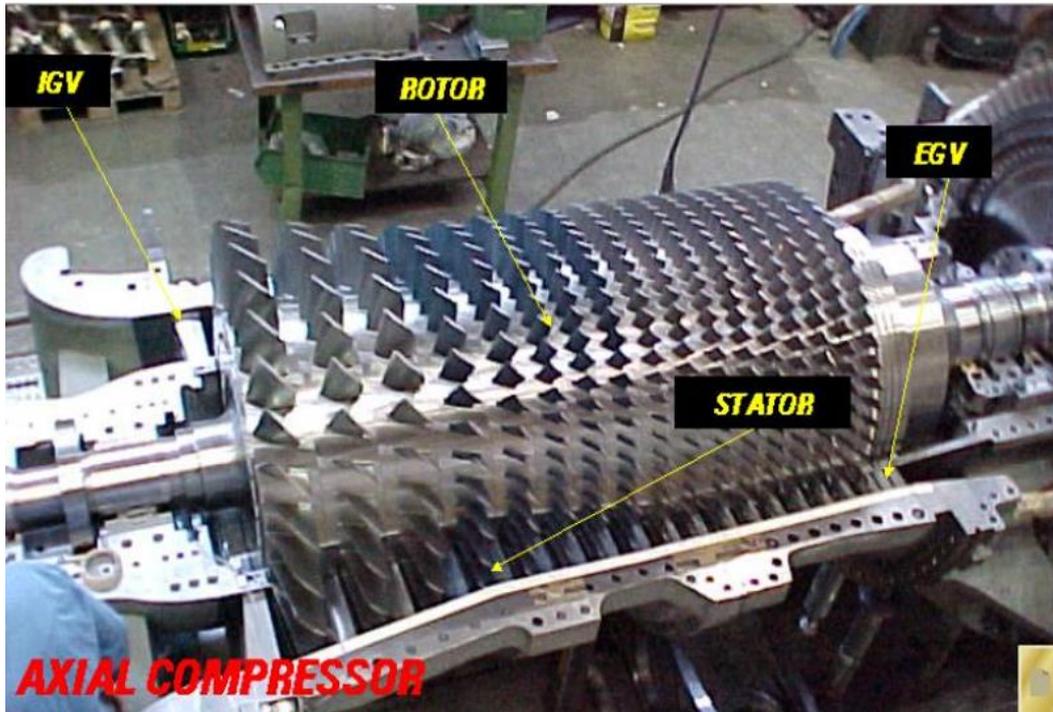
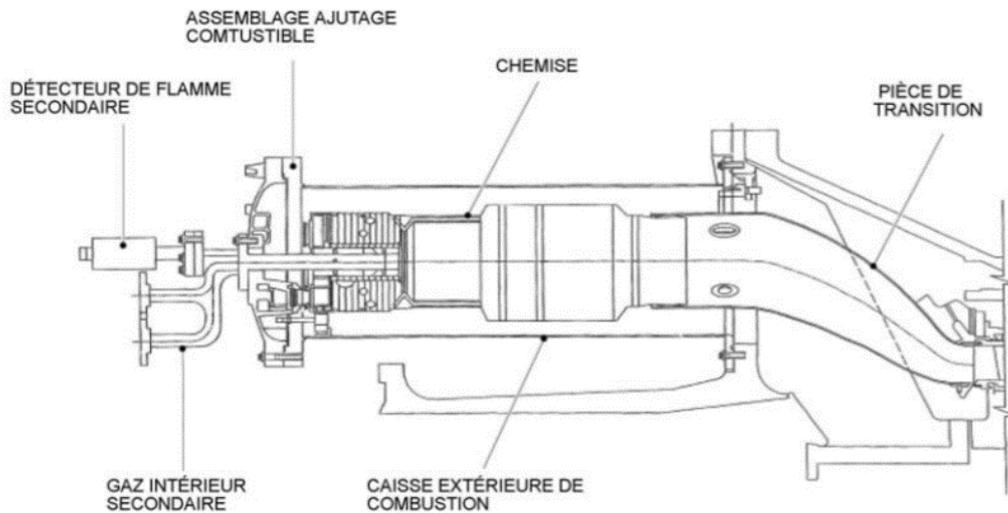


Figure 2-11: Compresseur axial

### 2.7.2. Section Combustion

Le système de combustion est de type inverse et comprend dix chambres de combustion réparties sur la périphérie du carter axial de refoulement du compresseur. Les composants suivants sont inclus dans le système : le carter de la chambre de combustion avec les couvercles correspondants, les chemises et les couvercles, les buses de combustible primaires (5 par chambre), les buses de combustion secondaires (1 par chambre), les détecteurs de flamme refroidis par eau (4 par machine), les bougies d'allumage et les accessoires, ainsi que les accessoires de la chambre de combustion tels que les chemises d'écoulement et les tubes de raccordement. De plus, une tuyauterie d'eau est présente pour le refroidissement des détecteurs de flamme.



**Figure 2-12:** Chambre de combustion DL

### **a. Pièces de transition :**

Ce sont les éléments de transition des gaz chauds entre les doublures de combustion et la première buse d'étage. Ils sont fixés à la partie avant de l'ensemble de la buse à l'aide de boulons. L'ensemble de la buse est scellé à la fois à sa périphérie externe et interne pour empêcher toute fuite des gaz chauds. L'ensemble du dispositif de transition ainsi que son arrangement de support maintiennent l'ensemble dans un alignement adéquat, tandis que le passage des gaz et les joints flottants tiennent compte de l'effet de dilatation thermique.

Avant que l'air de décharge du compresseur ne circule dans la chambre de combustion, il doit d'abord contourner les éléments de transition, ce qui permet un échange de chaleur. Cela refroidit les éléments de transition et préchauffe l'air de combustion.

### **b. Injecteur de carburant :**

Chaque chambre de combustion est équipée d'un injecteur de carburant qui introduit le carburant dans le revêtement de combustion. Le carburant gazeux est admis directement dans chaque chambre par des trous de dosage situés sur le bord extérieur de la plaque de tourbillonnement de l'injecteur. Lorsque du carburant liquide est utilisé, il est atomisé et mélangé à de l'air pour former un mélange air/carburant qui est ensuite pulvérisé dans la zone de combustion. L'action de la pointe tourbillonnante confère un mouvement de rotation à l'air de combustion, ce qui favorise une combustion plus complète et le contrôle des émissions.

### **c. Détection de Flamme :**

Le système DLNx-1 est chargé de surveiller la stabilité de la flamme pour contrôler le processus de combustion et protéger la turbine. Quatre détecteurs de flamme sont installés dans des chambres de combustion individuelles autour de la turbine pour détecter la présence

## Chapitre II : Introduction sur les turbines

de flamme dans la zone primaire. De plus, quatre autres détecteurs sont positionnés dans quatre autres chambres de combustion pour détecter la flamme dans la zone secondaire. Les signaux provenant de ces détecteurs de flamme sont traités par la logique de commande et utilisés par différentes fonctions de contrôle et de protection, notamment pour déterminer le mode de combustion DNLx-1.

### d. Système d'allumage :

Deux bougies d'allumage sont positionnées dans deux chambres de combustion pour allumer le combustible dans la zone primaire. Ces bougies sont activées lors du démarrage pour enflammer le combustible, ainsi que lors de certaines phases de transition du DLN<sub>x</sub>-1 nécessitant une reprise de l'allumage dans la zone de combustion primaire. La propagation de la flamme se fait dans les chambres de combustion dépourvues de bougie grâce à des chemises d'écoulement qui relient les zones primaires des chambres de combustion adjacentes autour de la turbine. La flamme est introduite dans la zone secondaire des chambres de combustion en enflammant le combustible de second écoulement provenant de la zone primaire.



Figure 2-13: Composants de la section de combustion

### 2.7.3. Section Turbine

Dans la section turbine, les gaz chauds provenant de la section combustion sont transformés en puissance mécanique. Cette puissance est utilisée pour entraîner le compresseur et la charge externe, et elle est générée par le rotor à deux étages de la turbine. Le premier étage, appelé roue haute pression, et le deuxième étage, appelé roue basse pression, sont solidement fixés ensemble pour former une unité cohérente à travers laquelle les distributeurs du premier et du deuxième étage dirigent les gaz. Ces composants, ainsi que les joints et les déflecteurs d'air associés, sont logés à l'intérieur de l'enveloppe de la turbine.

## Chapitre II : Introduction sur les turbines

---

### **A. Stator de la Turbine :**

La partie avant de l'enveloppe de la turbine abrite l'extrémité arrière des sections de refoulement du compresseur et de combustion. La partie arrière de l'enveloppe de la turbine contient les distributeurs du premier et du deuxième étage ainsi que les protections des rotors du premier et du deuxième étage de la turbine. De l'air est extrait du quatrième étage du compresseur pour refroidir l'enveloppe, puis s'échappe de l'extrémité arrière de l'enveloppe pour refroidir la surface arrière de la roue du deuxième étage de la turbine.

### **B. Distributeur de premier étage :**

Le distributeur de premier étage est composé d'aubes fixes à profil aérodynamique montées entre une paroi intérieure et une paroi extérieure circulaires. Ces aubes sont refroidies par de l'air provenant du compresseur et circulant à travers elles. Le distributeur est divisé en sections fixées à une bague de retenue montée sur l'enveloppe. Les aubes du distributeur sont creuses et possèdent des orifices d'évacuation d'air de refroidissement. Un dispositif de montage permet de retirer la moitié inférieure du distributeur sans déposer le rotor.

### **C. Distributeur et Diaphragme de Second étage :**

Le distributeur de second étage, placé entre les roues de premier et de second étage de la turbine, guide le flux gazeux vers les ailettes de la turbine de second étage. Il est composé d'aubes à profil aérodynamique montées entre une paroi intérieure et une paroi extérieure circulaires. Le distributeur est divisé en sections fixées aux blindages des premier et second étages du stator. Le diaphragme d'isolation des gaz sépare les zones haute et basse pression entre les deux roues de turbine. Il est également divisé en sections et fixé aux secteurs du distributeur. L'air de refroidissement circule à travers les aubes creuses du distributeur, les secteurs creux du diaphragme et le logement arrière des ailettes de premier étage pour ensuite refroidir le logement avant des ailettes de second étage. Des languettes d'étanchéité minimisent les fuites entre les secteurs.

### **D. Rotor de la Turbine :**

Le rotor de la turbine est constitué des roues des premier et second étages, de l'entretoise et de la partie entre la turbine et le compresseur. Les roues sont forgées en alliage d'acier et la roue du second étage comporte un faux-arbre avec un tourillon et une surface d'étanchéité pour le palier n°2. Le faux-arbre est équipé d'une bride à l'extrémité arrière pour l'accouplement avec l'équipement entraîné. Les composants du rotor sont équilibrés et assemblés avant d'être montés ensemble, nécessitant peu de corrections supplémentaires. Le rotor de la turbine est boulonné au rotor pré-équilibré du compresseur, et l'ensemble est soumis à un nouvel équilibrage dynamique pour compenser toute flexion.

### **E. Les Ailettes de la Turbine :**

Les ailettes de la turbine sont fixées aux roues à l'aide de logements en queue d'aronde en forme de chevron. Elles sont équipées de tôles de couverture intégrées et de saillies d'étanchéité axiales et radiales pour réduire les fuites de puissance entre les étages. Leur conception longue vise à répartir les contraintes et à minimiser la température au niveau de

## Chapitre II : Introduction sur les turbines

leur base. Un dispositif de verrouillage tournant est utilisé pour maintenir les ailettes en place en les emmanchant solidement dans la roue.

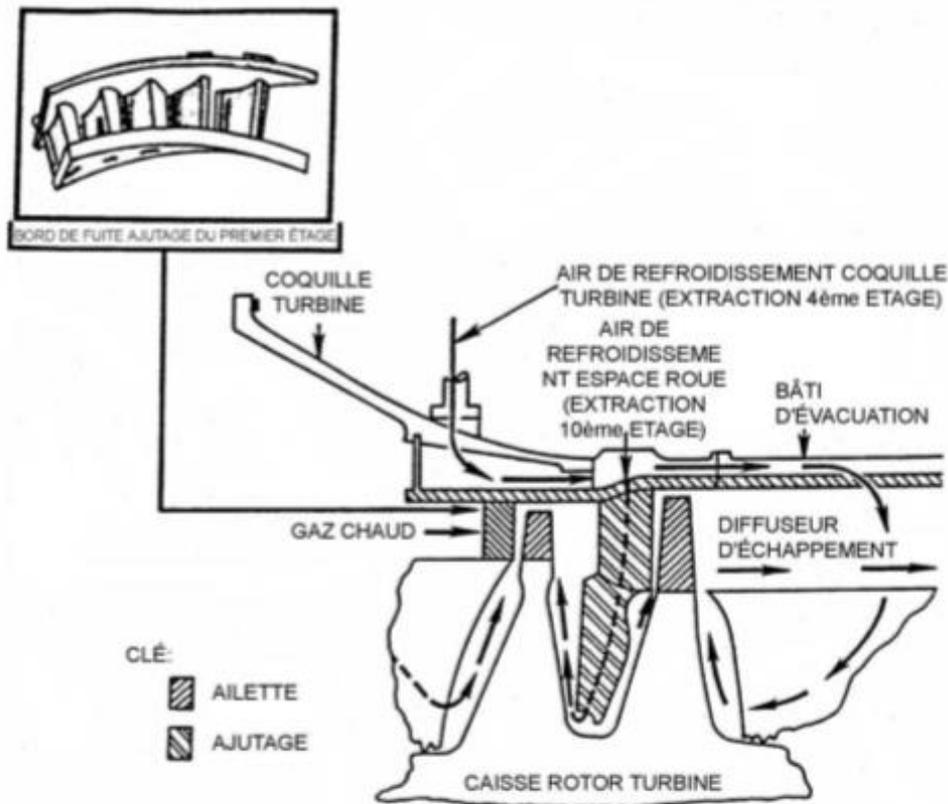


Figure 2-14: Disposition des distributeurs et ailettes de la turbine

### 2.7.4. Les Paliers

La turbine à gaz comprend deux paliers principaux qui soutiennent le rotor et des paliers de poussée pour maintenir la position axiale du rotor par rapport au stator. Ces paliers et leurs joints sont logés dans deux boîtiers, l'un sur le carter d'admission et l'autre sur le carter d'échappement. Ils sont lubrifiés sous pression par le système de lubrification principal, avec l'huile circulant à travers des conduites vers une entrée d'huile dans chaque boîtier.

#### A. Lubrification :

Les deux paliers principaux de la turbine sont lubrifiés sous pression à l'aide d'huile provenant du réservoir d'huile et des réservoirs et tuyaux interconnectés. Une mesure de protection consiste à faire cheminer la tuyauterie d'alimentation le long de la conduite de retour vers le réservoir, dans une configuration appelée double tuyauterie. Cette configuration évite que l'huile de lubrification ne soit projetée sur les équipements adjacents en cas de fuite, éliminant ainsi un éventuel danger. L'huile circule à travers l'espace annulaire autour du coussinet de palier à partir de l'arrivée d'huile du logement de palier. Elle pénètre ensuite dans

## Chapitre II : Introduction sur les turbines

---

les trous usinés du coussinet pour atteindre sa surface. Des joints d'huile empêchent la fuite du lubrifiant le long de l'arbre de la turbine.

### **B. Joints D'huile :**

Des joints à labyrinthe sont utilisés dans chaque palier pour empêcher la fuite de l'huile sous pression. Ces joints sont composés de garnitures à labyrinthe et de déflecteurs, placés aux points stratégiques pour contrôler le flux de lubrifiant. La surface de l'arbre est usinée de manière très lisse au niveau des joints pour réduire le jeu entre le joint et l'arbre. Les joints d'huile sont constitués de deux garnitures radiales avec un espace annulaire entre elles. De l'air sous pression est injecté dans cet espace pour empêcher l'huile de s'écouler le long de l'arbre. Une partie de cette huile retourne vers le réservoir principal et est évacuée vers l'atmosphère via l'évent du réservoir.

### **C. Palier N°01 :**

L'ensemble du palier n°1, situé au centre du carter d'entrée d'air, comprend trois paliers : un palier de poussée actif, un palier de poussée inactif et un palier axial. Il contient également un joint tournant, deux joints à labyrinthe et un logement pour ces composants. Les composants sont fixés au logement pour les empêcher de tourner. Le demi-logement inférieur est intégré au carter d'entrée d'air, tandis que le demi-logement supérieur est une pièce distincte boulonnée au demi-logement inférieur. Les joints à labyrinthe aux extrémités du logement sont pressurisés par de l'air provenant du compresseur. Le joint tournant à l'extrémité avant du palier de poussée retient le lubrifiant et limite l'entrée d'air dans la cavité.

### **D. Palier N°02 :**

L'ensemble du palier n°2 est situé dans le tunnel interne du bâti d'échappement et est fixé au bâti à l'aide d'un dispositif à clavettes. Ce dispositif permet la dilatation due aux variations de température et assure le centrage du palier dans le bâti. L'ensemble du palier comprend une chemise elliptique, des joints à labyrinthe et un logement de palier. Un anneau de retenue de chemise est fixé au demi-logement inférieur. Les composants internes sont fixés au logement pour les empêcher de tourner. Les joints à labyrinthe aux extrémités du logement sont pressurisés par de l'air provenant du compresseur.

#### **2.7.5. Système d'échappement et d'entrée**

La performance et la fiabilité d'une turbine à gaz dépendent de la qualité de l'air qui y pénètre. Pour assurer une exploitation efficace, il est essentiel de filtrer l'air atmosphérique afin de supprimer les contaminants. Le système d'entrée d'air est conçu pour traiter l'air en fonction des conditions de température, d'humidité et de contamination, afin de répondre aux exigences de la turbine. Le système d'échappement réduit les émissions sonores des gaz d'échappement avant leur rejet dans l'atmosphère. Les normes environnementales de propreté et de bruit doivent être respectées en fonction de l'emplacement du site.

### **A. L'entrée d'air :**

Le système d'entrée d'air de la turbine à gaz comprend un compartiment surélevé et un conduit muni d'un silencieux, qui assurent le filtrage, l'atténuation du bruit et la redirection de

---

## Chapitre II : Introduction sur les turbines

---

l'air vers la turbine. L'air traverse le compartiment d'entrée, puis le conduit surélevé équipé de silencieux et de filtres, avant d'entrer dans le plénum d'aspiration et le compresseur. Cette conception surélevée du conduit réduit l'aspiration de poussières et optimise l'efficacité. Les surfaces exposées à l'air d'entrée sont protégées contre la corrosion par une peinture d'apprêt.

### **B. Compartiment d'entrée d'air :**

Le système de filtration de l'air est situé séparément du socle de la turbine et est connecté au conduit d'entrée d'air. Il comprend une unité de filtrage auto-nettoyant de premier étage et une unité de filtrage haut rendement de second étage. Les cartouches de filtration du premier étage sont nettoyées séquentiellement par des jets d'air pulsé sous pression pendant le fonctionnement de la turbine. Ce nettoyage pulsé utilise de l'air provenant de la sortie du compresseur. La présence de ce système de filtration est essentielle pour protéger la turbine des conditions atmosphériques du site d'installation. Cependant, il est important de maintenir correctement les filtres pour assurer une protection adéquate de la turbine.

### **C. Conduit d'entrée d'air :**

Le compartiment d'entrée d'air, situé séparément de la turbine, est monté sur des supports surélevés et résistant aux intempéries. Il est relié au plénum d'aspiration par un conduit d'entrée d'air. Le conduit comprend un plénum à isolation phonique, un coude de 90 degrés, un module silencieux et des sections de conduit. Pour réduire le bruit, des chicanes horizontales en matériau isolant avec des perforations acoustiques sont utilisées. Les parois intérieures du conduit et du plénum sont également revêtues du même matériau isolant. Les chicanes verticales sont conçues pour éliminer les fréquences du compresseur tout en réduisant l'intensité des autres fréquences. Les tôles perforées en acier utilisées dans les silencieux et le conduit ne nécessitent pas d'entretien. La structure de support du système d'entrée d'air est en acier carbone revêtu de plusieurs couches de peinture protectrice.

### **D. Système d'échappement :**

La section d'échappement de la turbine est responsable de la redirection des gaz utilisés pour entraîner les roues de la turbine et de leur libération dans l'atmosphère. Le système comprend plusieurs composants, dont le plénum d'échappement, le joint de dilatation et le conduit intermédiaire. Un élément essentiel est la section d'atténuation phonique située entre le conduit intermédiaire et le conduit d'échappement, qui contribue à réduire le bruit généré lors de l'échappement des gaz.

### **E. Plénum d'échappement :**

Le plénum d'échappement est une structure en forme de caisse conçue pour recevoir les gaz d'échappement avant leur libération dans l'atmosphère via les silencieux. Il est situé à l'extrémité arrière du socle de la turbine et englobe le corps d'échappement, le diffuseur et les vannes de guidage d'échappement. Le plénum est revêtu d'une enveloppe qui augmente son volume et dirige les gaz hors de l'ouverture latérale vers le conduit intermédiaire. Construit en utilisant des techniques de soudage mécano, le plénum est également doté d'une isolation thermique et phonique pour optimiser ses performances.

### 3. ETAT DE L'ART SUR LA MAINTENANCE DES TURBINES A GAZ EN UTILISANT L'IA

#### 3.1.L'évolution industrielle et l'industrie 4.0

L'industrie 4.0 est une notion apparue en 2011 pour améliorer l'efficacité du secteur manufacturier. Face à la complexité croissante, aux demandes changeantes et à la concurrence sur le marché mondial, les entreprises sont confrontées au défi majeur de répondre aux exigences de produits personnalisés. L'industrie 4.0 offre un potentiel d'impact sur les systèmes de production grâce aux avancées rapides de la numérisation et à l'utilisation de technologies telles que l'Internet des objets, le Big Data et l'intelligence artificielle, notamment l'apprentissage automatique. Précédemment, trois révolutions industrielles majeures ont eu lieu : la mécanisation, l'électrification et l'automatisation/mondialisation. La figure ci-dessous illustre ces révolutions

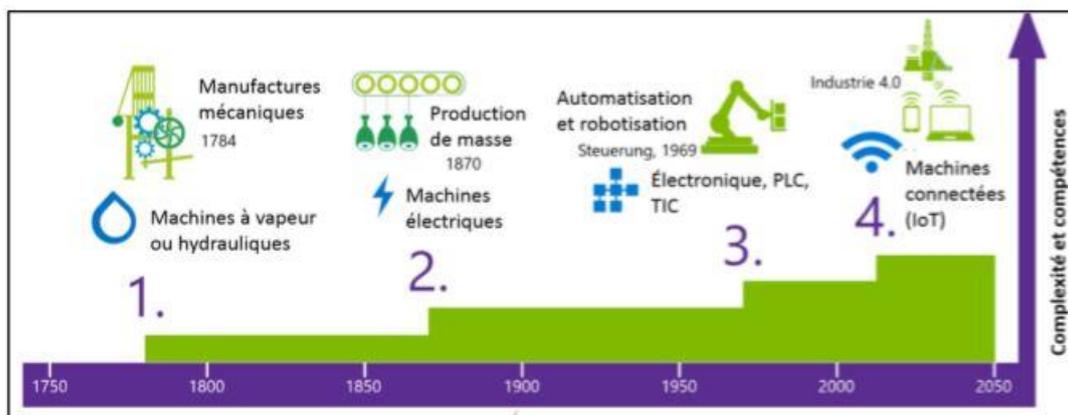


Figure 3-1 : La révolution industrielle tirée de Rioux (2016)

Dans l'industrie, l'évolution vers l'industrie 4.0 peut se faire à plusieurs niveaux, y compris les opérations de maintenance des équipements.

#### 3.2.Définition de la maintenance industrielle

D'après la norme AFNOR (NF X 60 010), la maintenance est définie comme l'ensemble des actions visant à maintenir ou à rétablir un bien dans un état spécifié ou apte à fournir un service déterminé. Assurer une bonne maintenance implique d'optimiser les coûts liés à ces opérations. En effet, quel que soit le secteur d'activité, les entreprises doivent prendre en compte les coûts et les conséquences qu'une défaillance soudaine peut engendrer. Leur productivité repose en grande partie sur l'efficacité de leurs processus de maintenance. Il est donc essentiel pour elles de mettre en place des stratégies de maintenance adaptées afin de garantir le bon fonctionnement de leurs équipements.

### **3.3. Les différents types de maintenance industrielle**

Il y a trois types de maintenance industrielle. Le premier type est la maintenance corrective, qui consiste à réparer un équipement défaillant dès qu'une panne survient. Son objectif est de remettre l'équipement en état de fonctionnement. Il s'agit d'une maintenance réactive, également appelée maintenance curative. Le deuxième type est la maintenance préventive, qui vise à détecter et résoudre les problèmes avant qu'ils ne se produisent. Elle se caractérise par des inspections régulières et planifiées. Le troisième type est la maintenance prédictive. Selon le dictionnaire Cambridge, l'adjectif "prédictif" signifie prédire un événement ou une action future. La maintenance prédictive consiste à anticiper le point de défaillance d'un composant ou d'un système avant qu'une panne ne se produise. Contrairement à la maintenance corrective qui intervient après la panne et à la maintenance préventive qui vise à éviter les problèmes potentiels, la maintenance prédictive évalue l'état de l'équipement existant et prédit les pannes en se basant sur une tendance de détérioration. Des mesures appropriées sont alors prises pour éviter la panne.

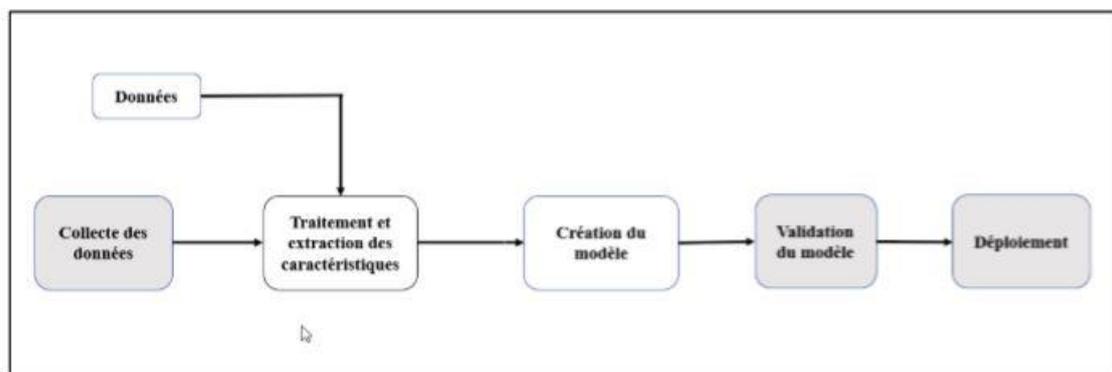
### **3.4. Démarche d'une approche de maintenance prédictive basée sur les données**

Pour mettre en place une stratégie de maintenance prédictive, il est essentiel de disposer de capteurs connectés qui enregistrent en continu les paramètres de fonctionnement de l'équipement concerné. Ces données sont collectées de manière massive, puis transmises à un moteur d'intelligence, comme mentionné par Thyago P et al. (2019). Ce moteur analyse les mégadonnées et les croise avec les rapports d'interventions antérieures effectuées sur les mêmes équipements. Le modèle prédictif identifie progressivement des corrélations entre certaines informations transmises et les pannes. Ainsi, il apprendra que certaines valeurs mesurées sont précurseurs de types spécifiques de défaillances. Lorsque ces valeurs sont à nouveau détectées, le modèle pourra planifier une action de maintenance et ainsi prévenir l'apparition de la panne.

Pour ce faire, il existe plusieurs outils disponibles pour chaque phase de construction, adaptés aux caractéristiques spécifiques de l'équipement et du secteur industriel. Dans ce contexte, Radhya, John et Muhammad Intizar (2020) ont proposé des lignes directrices pour aider les décideurs à sélectionner les technologies les plus appropriées en fonction de leurs besoins. Une fois les technologies choisies, la prochaine étape consiste à développer le modèle de maintenance prédictive, qui comprend quatre étapes clés. La première consiste à collecter les données relatives aux équipements, puis à les analyser afin de les classer en état normal et anormal. Ensuite, la deuxième étape implique la modélisation des schémas de défaillance à l'aide d'algorithmes d'identification des anomalies et de les classer en différentes catégories en se basant sur l'historique des pannes. La prochaine étape consiste à développer le modèle prédictif en lui apprenant à reconnaître de nouveaux événements et défaillances au fur et à mesure de leur survenue. Enfin, il est important d'adapter le système pour qu'il puisse mettre à jour sa base de données en fonction des nouvelles informations collectées sur le matériel, ce qui permet d'améliorer continuellement la performance du modèle.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

Les systèmes IoT permettent de raffiner les données collectées, ce qui apporte une nouvelle valeur à l'opérateur du système IoT. Pour obtenir de nouvelles informations, il est nécessaire de modéliser le processus détecté. Ce processus de modélisation et d'extraction de connaissances à partir d'ensembles de données est connu sous le nom d'apprentissage automatique (Kapil & Kiran, 2018). Cela nécessite une quantité suffisante de données disponibles. En plus des données brutes, une description détaillée des données peut être requise en fonction du cas d'utilisation. Par exemple, si l'on souhaite créer un modèle prédisant les défauts, il est nécessaire d'entraîner le modèle à détecter à la fois les données de fonctionnement sans défaut et les données de fonctionnement défectueux. Une fois le modèle entraîné avec ces données, il peut détecter l'état actuel du dispositif (Kapil & Kiran, 2018). Le développement de modèles peut être divisé en cinq étapes distinctes.



**Figure 3-2:** Les étapes de création d'un modèle de prédiction Adapté de Wanga, Ghani, & Kalegele (2017)

Avant la création du modèle à l'aide d'un algorithme d'apprentissage automatique, l'ensemble de données est généralement divisé en deux sous-ensembles distincts : les données d'entraînement et les données de test. Seul le sous-ensemble d'entraînement est utilisé pour créer le modèle, tandis que le sous-ensemble de test est réservé pour évaluer le fonctionnement du modèle créé. Le processus de création d'un modèle d'apprentissage automatique suit un flux de travail présenté dans la figure suivante.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

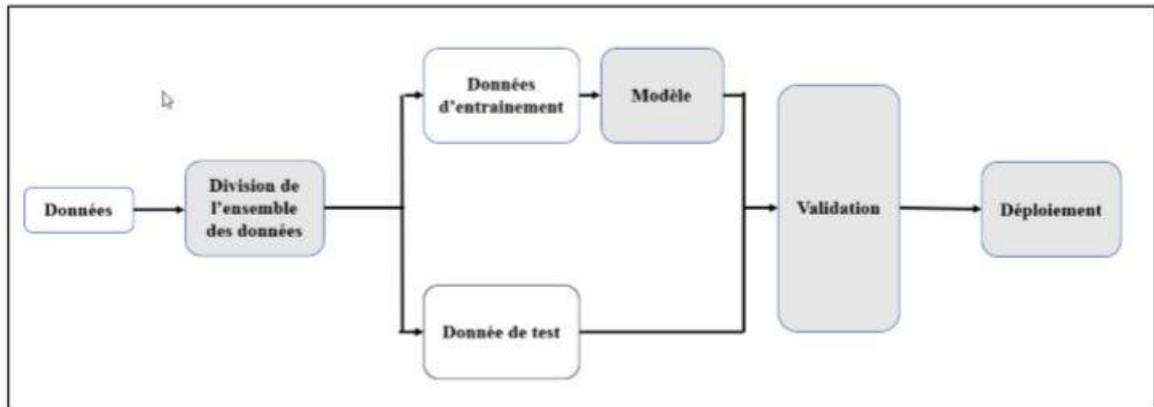


Figure 3-3: Création d'un modèle d'apprentissage automatique Adapté de Wanga (2017)

### 3.5.Maintenance prédictive et machines tournantes

La maintenance prédictive occupe une place de plus en plus importante au sein des groupes de recherche multidisciplinaires, qui visent à créer et intégrer des systèmes liés à l'acquisition de données, à l'infrastructure, au stockage, à la distribution, à la sécurité et à l'intelligence. Des efforts considérables ont été déployés pour développer plusieurs méthodes fiables de détection des défauts. Parmi les techniques éprouvées figurent l'analyse de l'huile de lubrification, le signal acoustique, la surveillance de la température, l'analyse du courant du moteur électrique et l'analyse des vibrations, qui est la plus populaire aujourd'hui.

Cependant, aucune technique n'est capable de détecter tous les défauts de la machine. C'est pourquoi la mesure des vibrations est privilégiée, car elle peut identifier avec précision 90% de toutes les pannes grâce aux changements de signaux de vibration émis par les machines. Le niveau de signal peut également fournir une prédiction précise des futures défaillances et permettre ainsi de surveiller l'état de l'équipement.

Dans cette perspective, les chercheurs Qiao & Lu (2015) affirment que l'analyse du signal provenant de la machine concernée est la meilleure façon de détecter un défaut, son type et son degré. De même, Jin, Zhao, Liu, Lee & He (2014) et Jie, Hou & Yong guang (2015) ont utilisé le signal vibratoire dans la détection des défauts, considérant la surveillance des vibrations comme l'outil le plus efficace pour identifier les défaillances. Cependant, d'autres chercheurs tels que Mobley (2002) suggèrent d'exploiter les signaux électriques tels que le courant et la tension, tandis que Kedadouche, Thomas & Tahan (2012) ont démontré que les émissions acoustiques sont plus fiables pour détecter les fréquences des défauts à basse vitesse.

En outre, plusieurs techniques d'intelligence artificielle (IA) ont été développées pour diagnostiquer les défaillances dans un système et suivre son état en collectant un maximum de données. Selon Deutsch & He (2018) et Wang, Di Maioa & Zio (2017), les approches de maintenance capables de surveiller l'état des équipements à des fins de diagnostic et de pronostic peuvent être regroupées en trois catégories principales.

### **3.6. Les approches fondées sur les connaissances et les expériences**

Trois principales méthodes sont utilisées dans le domaine de la maintenance : les méthodes basées sur des règles, les méthodes basées sur les cas et les méthodes basées sur les connaissances. Ces dernières ont été abordées dans les études de Luo, Hu, Ye, Zhang et Wei (2020), Montero, Jimenez, Rob, Grabot et Bernard (2020), ainsi que Sufiyan et al. (2021). Les approches basées sur les connaissances se présentent généralement sous la forme de règles conditionnelles du type "Si-Alors", qui sont déduites à partir d'expériences passées ou de situations problématiques spécifiques. Cependant, cette approche présente quelques inconvénients, notamment la difficulté d'acquérir des connaissances précises à partir de l'expérience et la limitation d'accès à des experts possédant des connaissances spécialisées. Par conséquent, cela peut entraîner une précision prédictive relativement faible. Néanmoins, cette approche est actuellement utilisée dans les techniques d'exploration de données pour extraire les connaissances nécessaires à partir de bases de données.

#### **3.6.1. Les approches basées sur des modèles physiques**

Ces modèles se distinguent principalement par leur approche de modélisation mathématique, qui prend en compte l'état d'un composant et nécessite une mesure précise de l'état et de la défaillance, ainsi que l'utilisation de méthodes statistiques pour estimer ces paramètres (Wu, Jennings, Terpenney, Gao et Kumara, 2017) et (Lei et al., 2016). Bien que la méthode basée sur un modèle physique puisse fournir une compréhension logique des défauts du système sans nécessiter une collecte importante de données, elle nécessite l'expertise d'experts pour concevoir et établir le modèle. La plupart des équipements sont complexes, qu'ils soient mécaniques ou électriques, ce qui rend la création de modèles de dégradation correspondants difficile en raison du manque de connaissance précise sur les mécanismes de dégradation.

#### **3.6.2. Les approches basées sur les données**

Ces approches sont les plus couramment observées dans l'évolution actuelle des solutions de maintenance prédictive, et elles reposent sur des méthodes statistiques, la reconnaissance ou l'intelligence artificielle (IA) ainsi que des algorithmes d'apprentissage automatique. Dans cette perspective, Baptista et al. (2018) ont comparé plusieurs approches basées sur l'intelligence artificielle à une approche statistique pour prédire les pannes futures d'équipements, et les résultats indiquent que les approches basées sur l'intelligence artificielle surpassent les approches statistiques. Selon de nombreux chercheurs, il est préférable d'utiliser une approche basée sur les données lorsque les modèles de système ne sont pas disponibles, mais que des données de surveillance du système sont disponibles. L'apprentissage automatique (ML), qui fait partie de l'intelligence artificielle, est devenu un outil puissant pour développer des algorithmes prédictifs intelligents dans de nombreuses applications. Il est capable de gérer de grandes quantités de données multidimensionnelles et d'extraire des relations cachées au sein de ces données dans des environnements complexes et dynamiques, tels que les environnements industriels (Wuest, Weimer, Irgens et Thoben,

## **Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA**

---

2016). Ainsi, l'apprentissage automatique offre des approches prédictives puissantes pour les applications de maintenance prédictive. Dans cette approche, les données peuvent être collectées à partir d'appareils en fonctionnement, et il n'est pas nécessaire d'avoir un modèle précis de l'évolution des pannes ou du processus de dégradation des performances (Canizo, Onieva, Conde, Charramendieta et Trujillo, 2017).

Les modèles autorégressifs, les réseaux de neurones artificiels (Fan et al., 2019) et les machines à vecteurs de support sont couramment utilisés pour l'analyse des mégadonnées dans le domaine de la maintenance prédictive (Fan et al., 2019). L'approche basée sur les données est largement utilisée dans les applications de maintenance prédictive, mais la performance dépend du choix approprié de la technique. De nombreux chercheurs ont contribué à l'amélioration des différentes approches de maintenance prédictive.

Récemment, des recherches ont étudié une approche hybride pilotée par un jumeau numérique (DT) qui combine les approches basées sur les données et basées sur le modèle pour créer un lien entre le monde physique et le monde numérique. Cependant, plusieurs travaux suggèrent des méthodes de pronostic basées sur les données, utilisant des algorithmes d'apprentissage automatique classiques ainsi que des systèmes de collecte de données et de surveillance des processus. À cet égard, Hsu, Wang, Lin, Chen et Hsu (2020) ont appliqué des techniques de contrôle statistique des processus et d'apprentissage automatique pour diagnostiquer les défaillances des éoliennes et prévoir les besoins de maintenance en analysant 2,8 millions de données de capteurs collectées sur 31 éoliennes à Taiwan de 2015 à 2017. Contrairement aux études antérieures qui se sont appuyées uniquement sur des données historiques d'éoliennes, cette étude a analysé les données des capteurs en intégrant les connaissances des experts en maintenance dans le processus d'exploration des données. Ils ont utilisé des analyses de Pareto, des diagrammes de dispersion et des diagrammes de cause à effet pour regrouper et classer les types de défaillance des éoliennes. En revanche, Thyago P et al. (2019) ont démontré dans leur article que les signaux de vibration sont les données les plus fréquemment utilisées pour concevoir des modèles de maintenance prédictive, en privilégiant l'utilisation de données réelles afin de construire des modèles fiables, notamment pour les machines rotatives.

### **3.7. Conclusion**

Cette revue de littérature nous a permis d'approfondir notre compréhension de la thématique de recherche et de nous familiariser avec les différentes techniques utilisées dans ce domaine. Elle nous a également permis d'évaluer le niveau d'avancement des recherches existantes et de comprendre les méthodes et approches utilisées dans différents travaux, afin de sélectionner la méthodologie la mieux adaptée aux besoins de Siemens. En ce qui concerne la caractérisation et la détection des défauts des machines rotatives, nous avons constaté que l'analyse vibratoire est la technique la plus pertinente par rapport à d'autres approches telles que l'analyse des huiles, l'analyse de température et la thermographie infrarouge.

## **Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA**

---

Pour mettre en œuvre un modèle de maintenance prédictive, plusieurs approches ont été utilisées dans les travaux antérieurs, mais la plupart des chercheurs considèrent que l'approche basée sur les données est plus intéressante et fiable, pour deux raisons principales :

1) Les avancées technologiques dans les capteurs et les systèmes d'acquisition de données ont permis de collecter de grandes quantités de données liées aux machines, qui peuvent ensuite être analysées à l'aide d'outils d'analyse de données en constante évolution. Cela permet aux chercheurs de comprendre et d'extraire les informations les plus utiles pour leur application.

2) Les systèmes industriels d'aujourd'hui sont complexes, ce qui rend parfois difficile leur modélisation et leur simulation.

À partir de cette revue de littérature, nous avons pu catégoriser notre problématique. Il s'agit essentiellement d'un problème de classification visant à identifier l'état de la turbine de puissance. Cependant, il existe plusieurs techniques d'apprentissage automatique utilisées dans les problèmes de classification. Nous comparerons donc les approches les plus recommandées dans la littérature afin de choisir celle qui convient le mieux à notre étude de cas et qui nous permettra d'obtenir des résultats satisfaisants.

### **3.8.L'Apprentissage Automatique (Machine Learning)**

Le Machine Learning (apprentissage automatique) est une discipline de l'intelligence artificielle (IA) qui utilise des méthodes mathématiques et statistiques (algorithmes) pour permettre aux ordinateurs d'apprendre à partir des données. Dépendamment du type des données disponibles pendant la phase de création du modèle, l'apprentissage machine est qualifié de différentes manières. En effet, après avoir s'être familiarisé avec les données, l'étape suivante consiste à appliquer un modèle pour prédire le type de défaut. La plupart des modèles appliqués à la maintenance prédictive sont basés sur des statistiques ou sur l'intelligence artificielle. Ces modèles sont capables de traiter et de saisir des relations complexes entre les données. Un point clé des modèles d'apprentissage automatique est leur processus d'apprentissage et dépend de l'application, de l'objectif et des données disponibles pour le système (Russel & Norvig, 2012). Il existe deux types d'apprentissages machine comme montré dans la figure 1.4 (Jaber, 2018). Différents types d'apprentissage existent, parmi lesquels les plus couramment utilisés sont :

#### **3.8.1. Apprentissage supervisé :**

Dans l'apprentissage supervisé, la sortie ou la variable de réponse souhaitée est connue, et l'algorithme d'apprentissage automatique établit une correspondance entre les caractéristiques d'entrée et la variable de sortie. Les deux sous-catégories majeures de l'apprentissage supervisé sont la régression et la classification, qui sont déterminées par le type de variable de sortie. Lorsque la variable de sortie est continue, elle relève de la catégorie de la régression.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

D'autre part, pour les problèmes de classification, la variable de sortie contient plusieurs classes ou étiquettes. Dans l'apprentissage supervisé, le processus d'entraînement du modèle se poursuit avec l'évaluation de l'erreur et l'apport d'améliorations jusqu'à l'obtention d'un niveau de précision souhaité.

### 3.8.2. Apprentissage non supervisé :

Dans l'apprentissage non supervisé, il n'y a pas de variable de sortie explicite et les relations sont générées en fonction des données fournies à l'algorithme. Certains des algorithmes appartenant à cette catégorie peuvent révéler des structures cachées et des relations entre les caractéristiques d'entrée. Quelques exemples d'apprentissage non supervisé incluent le regroupement (clustering), les algorithmes de réduction de dimensionnalité et l'apprentissage de règles associatives.

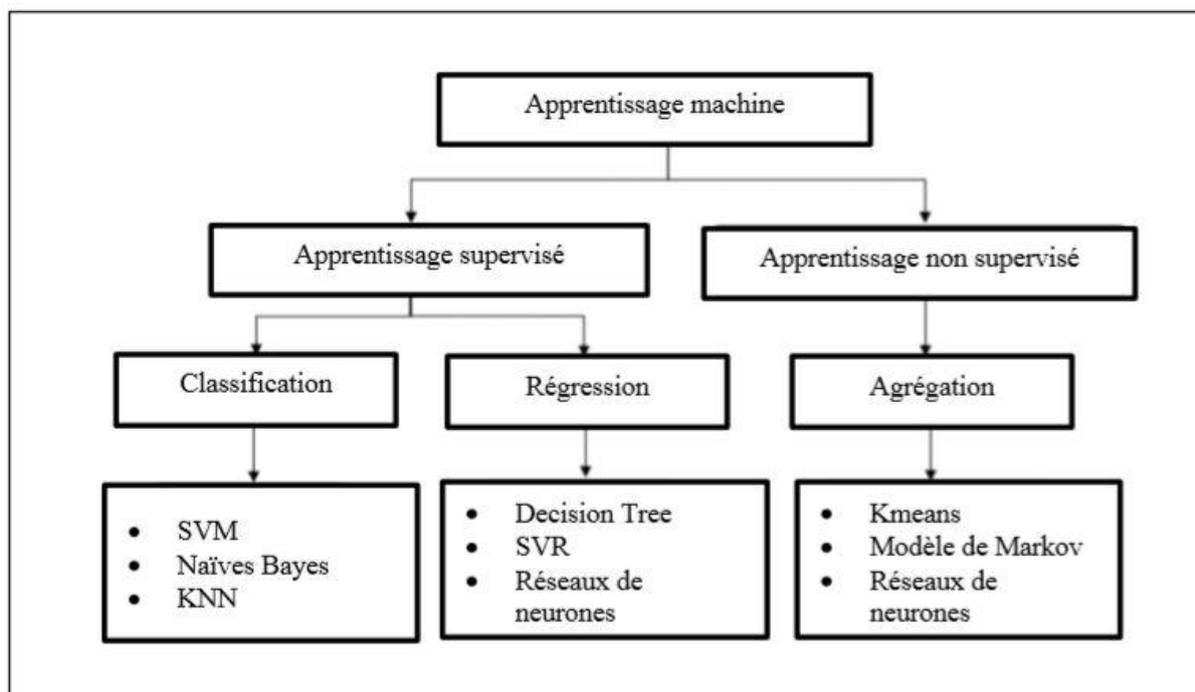


Figure 3-4: Taxonomie des modèles d'apprentissages automatiques tirée de Jaber (2018)

### 3.9. Les Algorithmes d'apprentissage de ML

Les techniques d'apprentissage ont joué un rôle essentiel dans l'application des algorithmes d'apprentissage automatique à divers domaines tels que le traitement du langage naturel, la reconnaissance de la parole, la détection de l'écriture manuscrite, la vision robotique, l'exploration de données, les moteurs de recherche sur Internet, le diagnostic médical, la bio-informatique, etc. Le choix d'un algorithme dépend étroitement de la tâche à accomplir (classification, estimation de valeurs, etc.), ainsi que du volume et de la nature des données.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

### 3.9.1. Le Random Forest (forêt aléatoire)

Est un algorithme d'apprentissage automatique utilisé pour résoudre des problèmes de régression et de classification. Il est composé de plusieurs arbres de décision.

L'algorithme de forêt aléatoire combine les prédictions des arbres de décision pour obtenir un résultat final. Il prédit en prenant la moyenne ou les moyennes des résultats de plusieurs arbres. En augmentant le nombre d'arbres, la précision du résultat s'améliore. La forêt aléatoire surmonte les limites d'un algorithme d'arbre de décision. Elle réduit le surajustement des ensembles de données et améliore la précision.

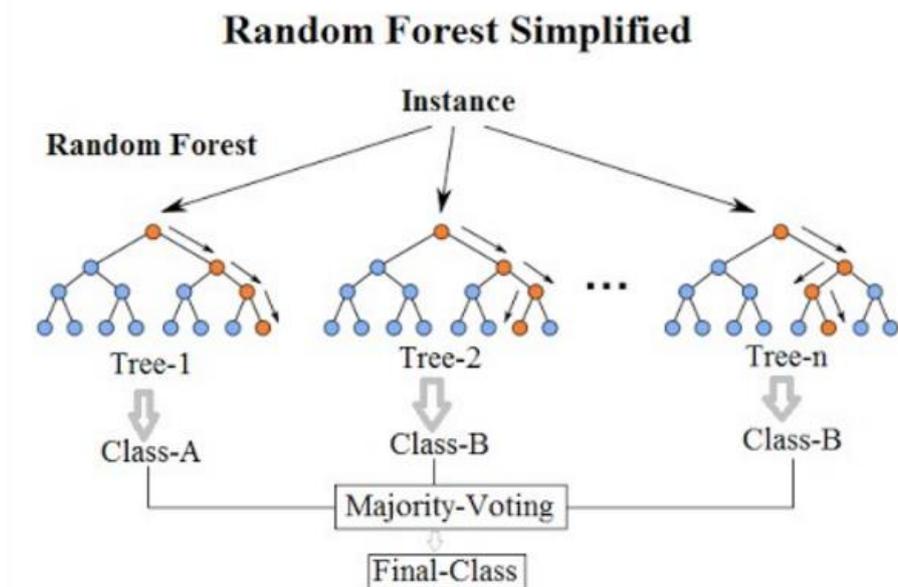


Figure 3-5: Exemple du Random Forest (forêt aléatoire)

### 3.9.2. Régression logistique (Logistic Regression)

La régression logistique est une méthode statistique utilisée pour construire des modèles d'apprentissage automatique lorsque la variable dépendante est dichotomique, c'est-à-dire binaire. La régression logistique est utilisée pour décrire les données et la relation entre une variable dépendante et une ou plusieurs variables indépendantes. Les variables indépendantes peuvent être nominales, ordinales ou de type intervalle.

Le nom "régression logistique" est dérivé du concept de la fonction logistique qu'elle utilise. La fonction logistique est également connue sous le nom de fonction sigmoïde. La valeur de cette fonction logistique est comprise entre zéro et un.

Voici un exemple de fonction logistique que nous pouvons utiliser pour déterminer la probabilité qu'un véhicule tombe en panne, en fonction du nombre d'années qui se sont écoulées depuis sa dernière révision.

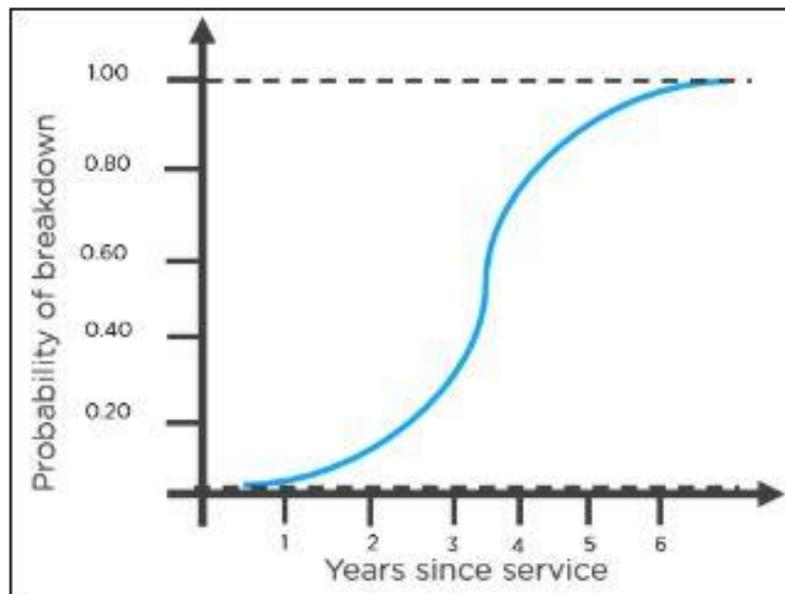


Figure 3-6: Exemple de la Régression logistique

### 3.9.3. Extra Trees Classifier

Le modèle Extra Trees Classifier est un algorithme d'apprentissage automatique de la famille des arbres de décision. Il fait partie de la catégorie des méthodes d'ensemble, où plusieurs modèles sont combinés pour améliorer les performances prédictives.

Le principe de fonctionnement de l'Extra Trees Classifier est similaire à celui des arbres de décision classiques. Cependant, il présente quelques différences clés dans la construction des arbres et la prise de décision. Lors de la construction de chaque arbre de décision, l'Extra Trees Classifier sélectionne aléatoirement un sous-ensemble des caractéristiques et utilise une partie aléatoire des données d'entraînement pour déterminer la meilleure division à chaque nœud. Cette technique est appelée "forêt d'arbres extrêmement aléatoires" (Extra Trees) en raison de la combinaison de l'échantillonnage aléatoire des caractéristiques et de l'échantillonnage aléatoire des données.

L'objectif de l'Extra Trees Classifier est de réduire la variance et le surajustement en introduisant davantage d'aléatoire dans le processus de construction des arbres. En utilisant des sous-ensembles aléatoires de caractéristiques et de données d'entraînement, le modèle essaie de créer des arbres plus diversifiés et moins sensibles aux variations mineures des données d'entraînement.

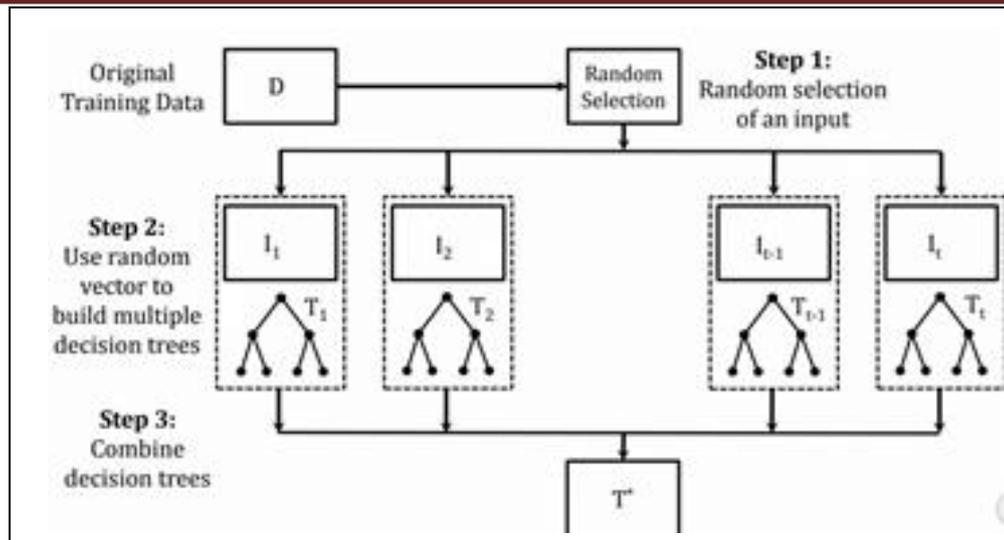


Figure 3-7: Exemple du modèle Extra Trees

Une fois que tous les arbres de décision sont construits, la prédiction est réalisée par vote majoritaire des arbres. Cela permet d'obtenir une prédiction finale plus robuste et de réduire le bruit potentiel introduit par les arbres individuels.

En résumé, l'Extra Trees Classifier est un modèle d'apprentissage automatique basé sur des arbres de décision, qui utilise des sous-ensembles aléatoires de caractéristiques et de données pour construire une forêt d'arbres diversifiée. Ce modèle vise à réduire le surajustement et à améliorer les performances prédictives en introduisant davantage d'aléatoire dans le processus d'apprentissage.

### 3.9.4. Bagging

Le modèle Bagging Classifier (Bootstrap Aggregating Classifier) est un algorithme d'apprentissage automatique qui fait partie de la famille des méthodes d'ensemble. Il vise à améliorer les performances prédictives en combinant plusieurs modèles individuels, appelés classifieurs de base, pour former un modèle plus puissant.

Le principe de fonctionnement du Bagging Classifier repose sur le concept de bootstrap et d'agrégation. Lors de la construction de chaque classifieur de base, un échantillon bootstrap est créé à partir du jeu de données d'entraînement initial. Cela signifie que des échantillons sont tirés au hasard avec remplacement, ce qui permet d'avoir des sous-ensembles de données légèrement différents pour chaque classifieur.

Chaque classifieur de base est ensuite entraîné sur son échantillon bootstrap, généralement en utilisant un algorithme d'apprentissage spécifique tel que les arbres de décision ou les k-plus proches voisins. L'utilisation de différents classifieurs de base permet d'explorer différentes hypothèses et de capturer différentes facettes des données d'entraînement.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

Une fois que tous les classificateurs de base sont entraînés, la prédiction est réalisée en agrégeant les prédictions individuelles. Pour les problèmes de classification, cela peut être fait par vote majoritaire, où la classe prédite est celle qui reçoit le plus grand nombre de votes des classificateurs de base. Pour les problèmes de régression, les prédictions individuelles sont généralement moyennées pour obtenir la prédiction finale.

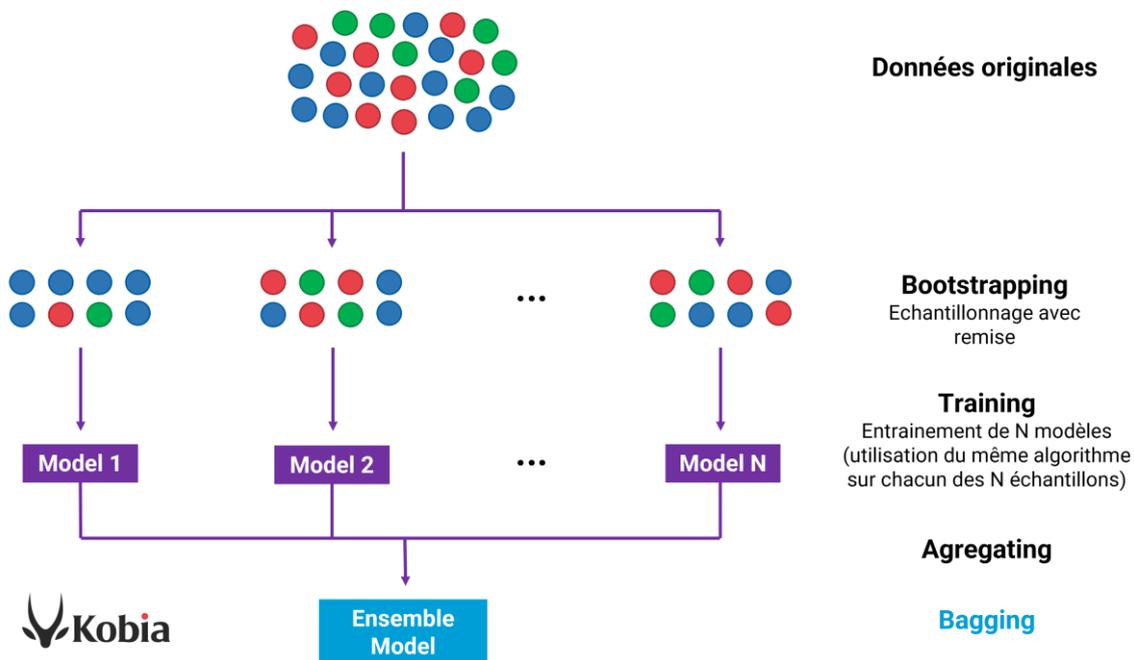


Figure 3-8: Exemple du modèle Bagging

Le Bagging Classifier permet de réduire le biais et la variance des modèles en combinant les prédictions de plusieurs classificateurs de base. En utilisant des échantillons bootstrap et des classificateurs diversifiés, il améliore la stabilité et la généralisation du modèle. De plus, il peut également être utilisé pour estimer l'incertitude des prédictions, ce qui peut être utile dans certains scénarios.

En résumé, le Bagging Classifier est un modèle d'apprentissage automatique basé sur l'agrégation de plusieurs classificateurs de base. Il utilise des échantillons bootstrap et des prédictions agrégées pour améliorer les performances prédictives et réduire le surajustement. Ce modèle est largement utilisé pour la classification et la régression dans de nombreux domaines d'application.

### 3.9.5. XGBoost

Le modèle XGBoost (eXtreme Gradient Boosting) est un algorithme d'apprentissage automatique de type boosting qui est largement utilisé dans le domaine de la classification et de la régression. Il s'agit d'une implémentation extrêmement performante de l'algorithme de

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

boosting qui vise à améliorer les prédictions en combinant plusieurs modèles individuels, appelés arbres de décision faibles, pour former un modèle plus fort.

Le principe de fonctionnement du XGBoost repose sur le concept de boosting itératif. L'algorithme construit les arbres de décision de manière séquentielle, en se concentrant sur les erreurs de prédiction résiduelles des modèles précédents. À chaque itération, un nouvel arbre est construit pour capturer les erreurs résiduelles et améliorer la performance globale du modèle.

Pour minimiser l'erreur, le XGBoost utilise une fonction de coût qui mesure à quel point les prédictions du modèle correspondent aux véritables valeurs cibles. Cette fonction de coût est optimisée en utilisant une approche de descente de gradient, où les poids des arbres de décision sont mis à jour itérativement pour minimiser la fonction de coût.

De plus, le XGBoost intègre plusieurs techniques avancées pour améliorer les performances et la robustesse du modèle. Il utilise une régularisation L1 et L2 pour contrôler la complexité du modèle et éviter le surajustement. Il utilise également la méthode d'élagage pour réduire la taille des arbres et améliorer l'efficacité du modèle.

Le XGBoost se distingue également par sa capacité à gérer des ensembles de données de grande taille, grâce à une mise en œuvre optimisée qui tire parti du parallélisme et de la distribution des calculs. Cela permet de réduire considérablement le temps d'entraînement du modèle.

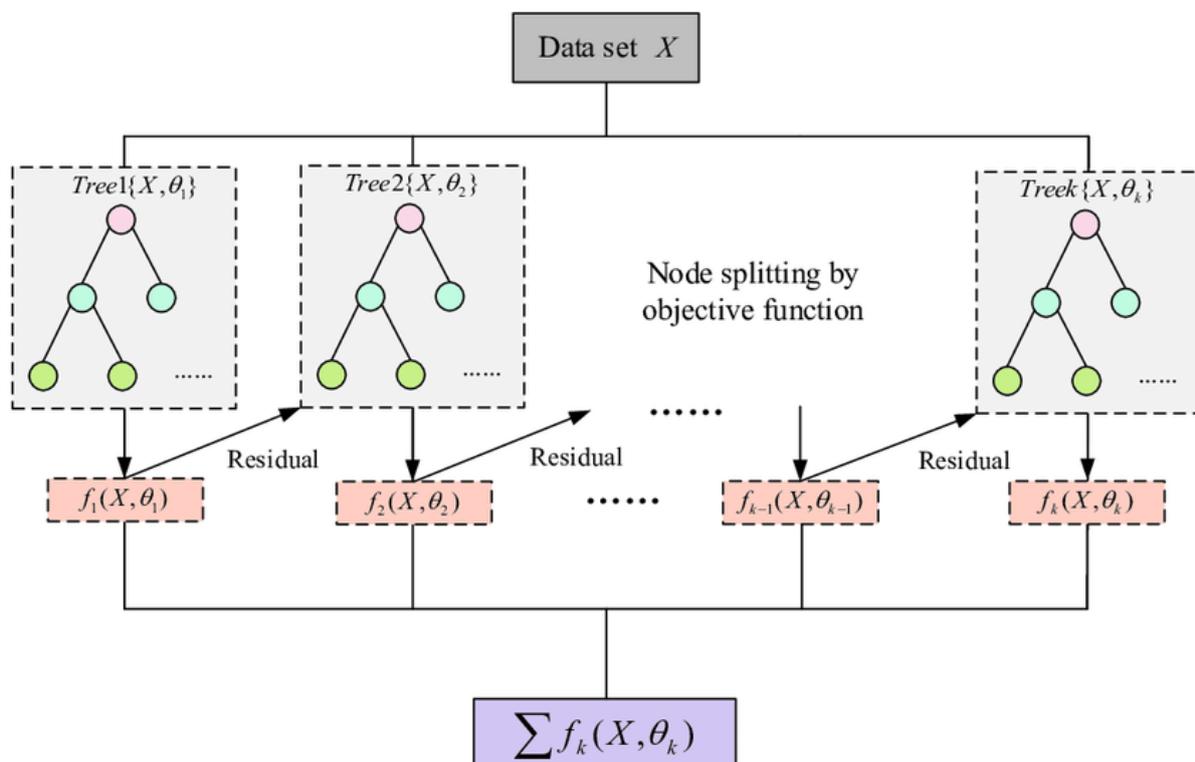


Figure 3-9: Exemple du modèle XGB Classificateur

## **Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA**

---

En résumé, le XGBoost est un modèle d'apprentissage automatique de type boosting qui utilise des arbres de décision faibles pour former un modèle plus fort. Il optimise une fonction de coût à l'aide d'une descente de gradient itérative et intègre des techniques avancées pour améliorer les performances et la robustesse du modèle. Le XGBoost est largement utilisé dans diverses applications en raison de sa précision, de sa rapidité et de sa capacité à gérer de grandes quantités de données.

### **3.10. L'apprentissage profond (Deep Learning)**

Le Deep Learning fait référence à une famille de méthodes d'apprentissage automatique qui utilisent des réseaux neuronaux. Les réseaux neuronaux ont généralement besoin de beaucoup plus de données pour s'entraîner que d'autres méthodes d'apprentissage automatique. Le Deep Learning offre des performances exceptionnelles dans certains domaines, mais pas dans tous. Il excelle dans des domaines tels que la vision par ordinateur, le traitement du langage naturel et le traitement audio. Malgré l'attrait des réseaux neuronaux, ils ne sont pas aussi largement applicables ni aussi conviviaux pour les débutants que d'autres méthodes d'apprentissage automatique. Les aspirants Data scientists devraient commencer par apprendre des méthodes d'apprentissage automatique plus "généralistes" telles que la régression logistique, les forêts aléatoires et les arbres boostés.

#### **3.10.1. Réseaux de neurones artificiels ANN**

Les réseaux de neurones artificiels (ANN), ou plus simplement les réseaux neuronaux, sont de nouveaux systèmes et méthodes de calcul pour l'apprentissage automatique, la démonstration de connaissances, et finalement l'application des connaissances acquises afin de maximiser les réponses de sortie des systèmes complexes (Chen et al., 2019). Un réseau de neurones artificiels (ANN) est un modèle de traitement des données basé sur la façon dont les systèmes nerveux biologiques, tels que le cerveau, traitent les données. Ils se concentrent sur la structure neuronale du cortex cérébral des mammifères, mais à une échelle beaucoup plus petite. De nombreux experts en intelligence artificielle estiment que les réseaux de neurones artificiels sont le meilleur espoir, voire peut-être le seul espoir, de concevoir une machine intelligente.

## Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA

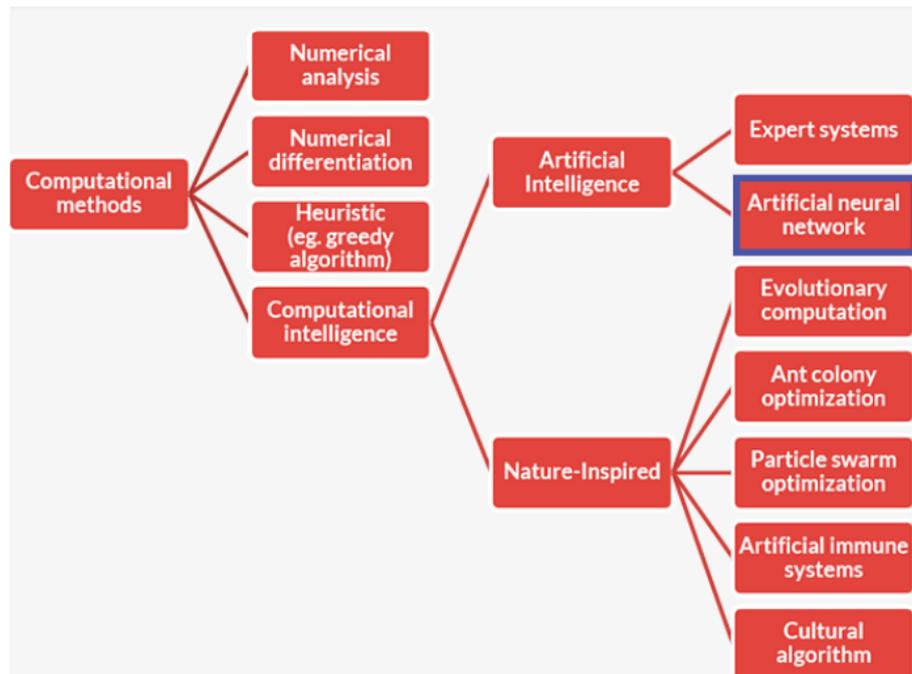


Figure 3-10: Les branches et sections des méthodes de calcul.

Les réseaux de neurones artificiels sont conçus de la même manière que le cerveau humain, avec des nœuds de neurones interconnectés de manière similaire à une toile. Les neurones sont des milliards de cellules qui composent le cerveau humain. Chaque neurone est constitué d'un corps cellulaire qui traite les informations en les amenant vers le cerveau et en les en faisant sortir (entrées et sorties). L'idée principale de ces réseaux est inspirée du fonctionnement du système neuronal biologique, visant à traiter les données et les informations afin d'apprendre et de créer des connaissances. L'élément clé de cette idée est de créer de nouvelles structures pour le système de traitement de l'information.

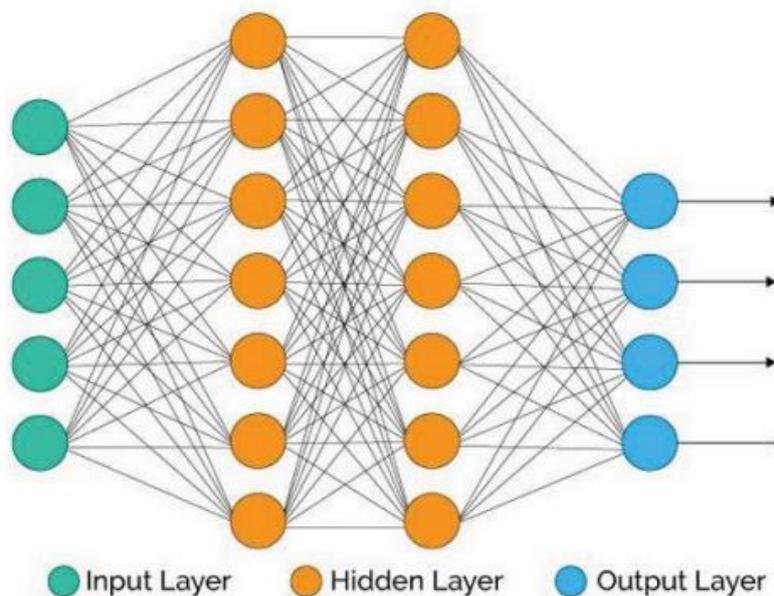


Figure 3-11: Architecture des réseaux neuronaux artificiels

### **Chapitre III : Etat de l'art sur la maintenance des turbines à gaz en utilisant l'IA**

---

Le système est constitué d'un grand nombre d'éléments de traitement étroitement interconnectés appelés neurones, qui travaillent ensemble pour résoudre un problème et transmettre des informations à travers des synapses (connexions électromagnétiques). Les neurones sont interconnectés étroitement et organisés en couches. La couche d'entrée reçoit les données, tandis que la couche de sortie génère le résultat final. Entre les deux, une ou plusieurs couches cachées sont généralement insérées. Cette disposition rend difficile la prédiction ou la connaissance exacte du flux de données. Chaque connexion possède un poids de connexion, et chaque neurone possède une valeur de seuil et une fonction d'activation. On calcule si chaque entrée a un poids positif ou négatif en fonction du signe du poids de l'entrée. Le poids influence l'intensité du signal au niveau d'une connexion. Les neurones ont un seuil au-dessus duquel un signal est transmis uniquement si le signal agrégé le dépasse. La valeur d'activation est la somme pondérée de l'unité de sommation, et la sortie est générée en fonction du signal provenant de cette valeur d'activation.

## **4. La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)**

L'application de l'IA : Machine Learning ou Deep Learning pour la surveillance automatique de l'état des machines se fait avec Anaconda Jupyter.

### **4.1.Processus d'apprentissage automatique (Workflow)**

L'une des principales difficultés de l'application d'un processus d'apprentissage automatique aux données de maintenance est le choix du bon flux de travail, car dans la littérature, il existe de nombreuses approches différentes de ce problème, en fonction de l'origine des données et des objectifs de l'analyse. Dans le présent travail, le flux de travail présenté dans la figure IV-1, sera suivi. De notre point de vue, un projet d'apprentissage automatique doit toujours commencer par l'établissement d'une définition rigoureuse et claire des objectifs, car un tel système remplit une tâche très spécifique et la définition d'objectifs vagues peut signifier que le modèle développé n'est pas capable de prédire exactement ce qu'il est censé prédire. La partie la plus importante de notre projet d'apprentissage automatique est sans doute la capacité à comprendre les données utilisées et la manière dont elles sont liées à la tâche que nous voulons résoudre. Il ne sera pas efficace de choisir un algorithme au hasard, d'utiliser l'ensemble des données dont nous disposons et de s'attendre à de bons résultats. Il est nécessaire de comprendre ce qui se passe dans l'ensemble de données avant de commencer à construire un modèle. Lors de l'élaboration d'une solution d'apprentissage automatique, nous devons répondre ou au moins garder à l'esprit les questions suivantes : À quelles questions essayons-nous de répondre ? L'ensemble des données disponibles permet-il de répondre à ces questions ? Quelle est la meilleure façon de paraphraser ma question en tant que problème d'apprentissage automatique ? L'ensemble de données disponible est-il suffisant pour représenter le problème que nous essayons de résoudre ? Quelles caractéristiques (ou attributs) ont été extraites et pourront-elles conduire à des prédictions correctes ? Comment mesurer le succès de l'application de l'apprentissage automatique ? Comment la solution d'apprentissage automatique interagira-t-elle avec le reste du processus ? Les algorithmes et les méthodes d'apprentissage automatique ne sont qu'une partie d'un processus plus large de résolution d'un problème spécifique, et il est important de garder cela à l'esprit. Parfois, on passe beaucoup de temps à construire des solutions complexes de Machine Learning, pour découvrir au final qu'elles ne résolvent pas le problème que l'on attendait [16]. En approfondissant les aspects techniques de l'apprentissage automatique, il est facile de perdre de vue les objectifs finaux. Il est important de garder à l'esprit toutes les hypothèses créées, explicitement ou implicitement, lors de la construction de modèles d'apprentissage automatique.

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

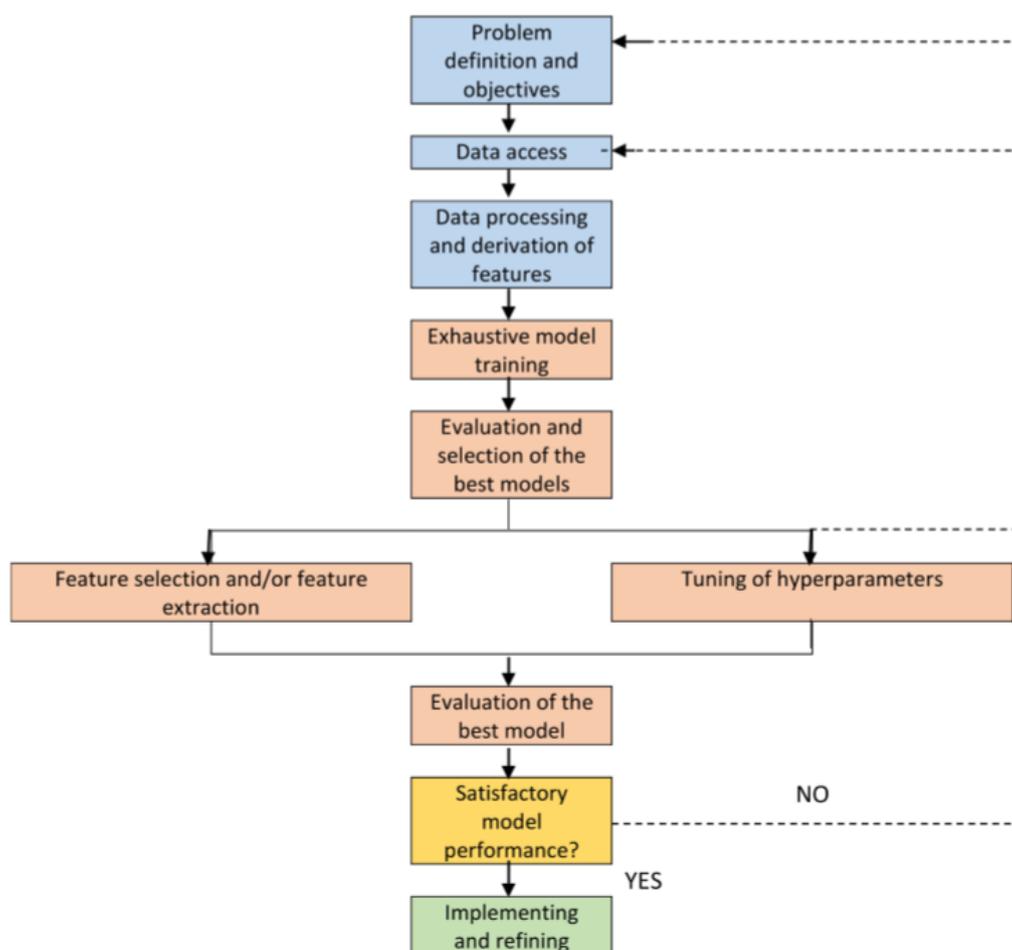


Figure 4-1: Processus d'apprentissage automatique Workflow

### 4.2. Collection des données

Avec les avancées de l'Internet des objets (IoT), les données industrielles massives, également appelées données volumineuses industrielles, sont collectées à partir des équipements surveillés et stockées pour une analyse approfondie. Parmi ces données, les données de surveillance de l'état sont prédominantes, notamment les données de vibration. Dans le cas de notre partenaire industriel, l'entreprise dispose d'un système d'acquisition et d'analyse des signaux vibratoires appelé Bently Nevada.

La vibration peut être mesurée selon trois caractéristiques distinctes : le déplacement, la vitesse et l'accélération. Bien que ces caractéristiques soient mathématiquement liées, elles sont différentes les unes de l'autre. Il est essentiel de sélectionner la mesure de vibration et le type de capteur qui révèlent le mieux les caractéristiques de défaillance attendues.

L'accélération représente le taux de changement de la vitesse. Les vibrations sont généralement mesurées en termes d'accélération à l'aide d'accéléromètres. De même, la vitesse est mesurée en pouces par seconde (in/sec) ou millimètres par seconde (mm/sec). Elle indique

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

le taux de changement de déplacement du signal de vibration et est la mesure de vibration la plus couramment utilisée. Historiquement, le capteur de vitesse a été l'un des premiers capteurs électriques utilisés pour la surveillance de l'état des machines.

Le déplacement représente le changement de position ou de distance d'un objet par rapport à une référence. Il est généralement mesuré en mils ou en micromètres à l'aide d'une sonde de déplacement. Une sonde de déplacement est un dispositif sans contact qui mesure la distance relative entre deux surfaces. Les sondes de déplacement sont souvent utilisées pour surveiller les vibrations de l'arbre ou du rotor par rapport au boîtier de la machine. Habituellement, deux capteurs sont montés à des angles de  $90^\circ$  pour obtenir les axes X et Y, comme illustré dans la figure suivante.

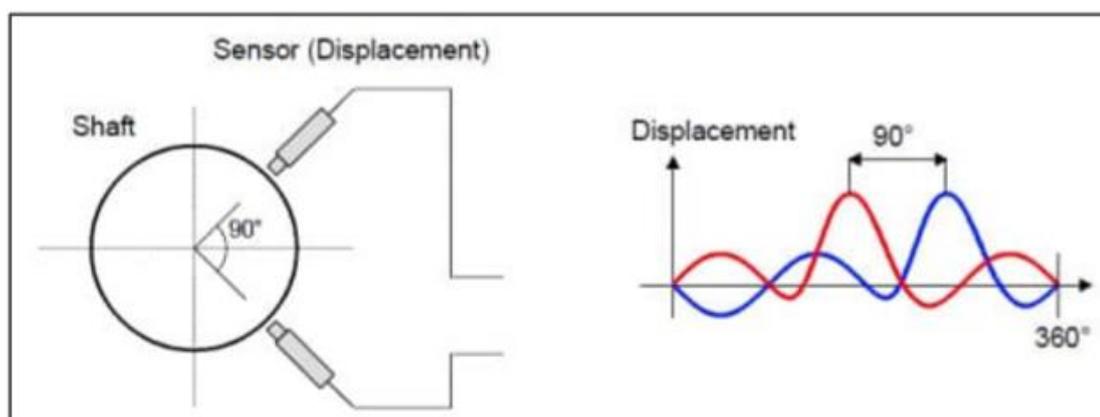


Figure 4-2: Capteurs de déplacement tiré de Data Logger Inc (2016)

### 4.2.1. Importation et préparation des données sur Python

Pour commencer, nous importons les bibliothèques requises telles que Numpy, Pandas, matplotlib, seaborn, sklearn, etc., afin de pouvoir effectuer des opérations mathématiques et algébriques, lire et analyser les Data Frames, visualiser les données et l'esthétique, ainsi que d'interagir avec les bibliothèques numériques et scientifiques de NumPy et SciPy.

- Après, on procède à l'importation de datas pour qu'ils soient par la suite :

```
data = pd.read_excel('Full_Data.xlsx')
data
```

Figure 4-3: Importation des données

Les données qu'on va utiliser sont des données de déplacement, Velocity, Accélération, Pression d'huile, La charge de Générateur, et de Températures.

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

```
Data = pd.read_excel("Displacement.xlsx")
Data
```

	01AD1 ZI- 7052-A GDG COA AXI DEP	01AD1 ZI- 7052-B GDG COA AXI DEP	01XD1 VI- 7015-X GDG COA Dep	01YD1 VI- 7015-Y GDG COA Dep	04XD1 VI- 7017-X TDP CA DEP	04YD1 VI- 7017-Y TDP CA DEP	05XD1 VI- 7020-X RÉD E CA DEP	05YD1 VI- 7020-Y RÉD E CA DEP	06AD1 ZI- 7054-A RÉD ECO A AXI DEP	06AD1 ZI- 7054-B RÉD ECO A AXI DEP	06XD1 VI- 7021-X RÉD ECO A DEP	06YD1 VI- 7021-Y RÉD ECO A DEP	07XD1 VI- 7023-X RÉD R COA DEP	07YD1 VI- 7023-Y RÉD R COA DEP	08XD1 VI- 7022-X RÉD R CA DEP	08YD1 VI- 7022-Y RÉD R CA DEP
0	0.01	0.05	39	16	12	13	16	14	0.15	0.13	10	10	7.0	8	17	17
1	0.00	0.06	40	17	13	32	14	23	0.22	0.21	11	9	6.0	7	17	16
2	0.01	0.05	41	17	12	28	14	13	0.20	0.18	10	24	9.0	11	18	18
3	0.01	0.06	40	17	12	27	14	12	0.18	0.17	10	10	37.0	12	19	19
4	0.03	0.06	41	17	13	29	14	12	0.05	0.04	10	9	8.0	24	45	40
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
115	0.02	0.05	62	25	32	84	12	11	0.22	0.23	8	8	7.0	9	18	17
116	0.03	0.05	65	26	25	0	12	11	0.22	0.23	8	8	7.0	9	18	17
117	0.02	0.03	53	24	18	0	11	11	0.22	0.22	8	8	7.0	8	18	17
118	0.01	0.03	51	24	19	0	11	11	0.18	0.17	8	8	7.0	8	18	17
119	0.04	0.06	62	28	18	0	12	12	0.23	0.24	8	8	7.0	8	17	16

120 rows x 16 columns

Figure 4-4: Importation des données de Déplacement

```
Velocity = pd.read_excel("Velocity.xlsx")
Velocity
```

	01AV1 VI-7016 A GDG COA AXI VIT	01AV1 VI-7016 B GDG COA AXI VIT	04AV1 VI-7018 A TDP CA AXI VIT	04AV1 VI-7018 B TDP CA AXI VIT	09VV1 VI-7025 ALT VIT	10VV1 VI-7026 ALT COA VIT
0	0.8	0.914159	2.4	1.658421	0.3	0.2
1	0.9	0.914159	2.0	1.658421	0.2	0.0
2	0.9	0.914159	2.3	1.658421	0.3	0.0
3	0.8	0.900000	2.0	2.200000	0.3	0.0
4	1.0	1.000000	2.5	2.200000	0.4	0.0
...	...	...	...	...	...	...
115	0.7	0.800000	0.8	0.800000	0.5	0.4
116	0.4	0.400000	0.9	0.600000	0.5	0.4
117	0.9	0.900000	0.8	0.800000	0.6	0.5
118	0.4	0.400000	0.7	0.600000	0.5	0.5
119	0.6	0.600000	0.6	0.800000	0.7	0.5

120 rows x 6 columns

Figure 4-5: Importation des données de Velocity

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

```
Acceleration = pd.read_excel("Acceleration.xlsx")  
Acceleration
```

	05VV1 VI-7028 RÉD ENTRÉE ACC	07VV1 VI-7029 RÉD REND ACC
0	0.56	0.84
1	0.57	0.91
2	0.60	0.92
3	0.56	0.91
4	0.64	1.10
...	...	...
115	0.28	0.59
116	0.87	0.57
117	0.79	0.56
118	0.79	0.56
119	1.00	0.79

120 rows x 2 columns

**Figure 4-6:** Importation des données d'Acceleration

```
Pressure = pd.read_excel("Pressure_and_LOAD.xlsx")  
Pressure
```

	Generator LOAD	OA-PI-7045 DISCHARGE PRESS	OA-PIT-7062 ABC LUB OIL PRESS
0	3.5	5.4	1.6
1	4.0	5.4	1.6
2	3.9	5.5	1.6
3	4.2	5.5	1.6
4	7.0	6.0	1.5
...	...	...	...
115	5.2	5.9	1.9
116	4.6	5.8	1.8
117	5.3	6.0	1.8
118	4.7	6.0	1.8
119	8.8	6.5	1.8

120 rows x 3 columns

**Figure 4-7:** Importation des données de pression d'huile et de la Charge de Générateur

### 4.3. Description des Données

On affiche la description des données pour chaque paramètre, pour faire connaître les caractéristiques des données. En total il y a 120 entrées dans chaque paramètre (16 paramètres

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

---

de déplacement, 06 de Velocity, 02 d'Accélération, 02 de pression d'huile, 01 de la charge de Générateur, et 30 paramètres de température).

La notation générale pour décrire l'information d'un capteur de vibration dans une machine tournante est la suivante :

- Le premier élément est le numéro ou l'identifiant du capteur, qui peut être un nombre ou une combinaison de lettres et de chiffres.
- Le deuxième élément indique la direction de mesure. Cela peut inclure des termes tels que "Vertical", "Horizontal", "Axial", "X", "Y" ou "Z", en fonction de la convention utilisée dans votre domaine.
- Le troisième élément représente l'amplitude de mesure, qui peut être exprimée en termes tels que "Displacement" (déplacement), "Velocity" (vitesse) ou "Acceleration" (accélération).

Par exemple, si nous prenons le premier paramètre "01AD" en utilisant cette notation généralisée, nous pouvons l'interpréter de la manière suivante :

- "01" représente le numéro ou l'identifiant du capteur.
- "A" indique la direction de mesure, qui dans ce cas est "Axial" ou "le long de l'axe".
- "D" fait référence à l'amplitude de mesure, qui dans ce cas est "déplacement".

Ainsi, le capteur "01 A D" peut être interprété comme un capteur situé au palier numéro 1, mesurant l'amplitude du déplacement dans la direction axiale.

**Table 4-1:** Les Données utilisés dans le système de maintenance prédictive de la turbine à gaz MS5001.

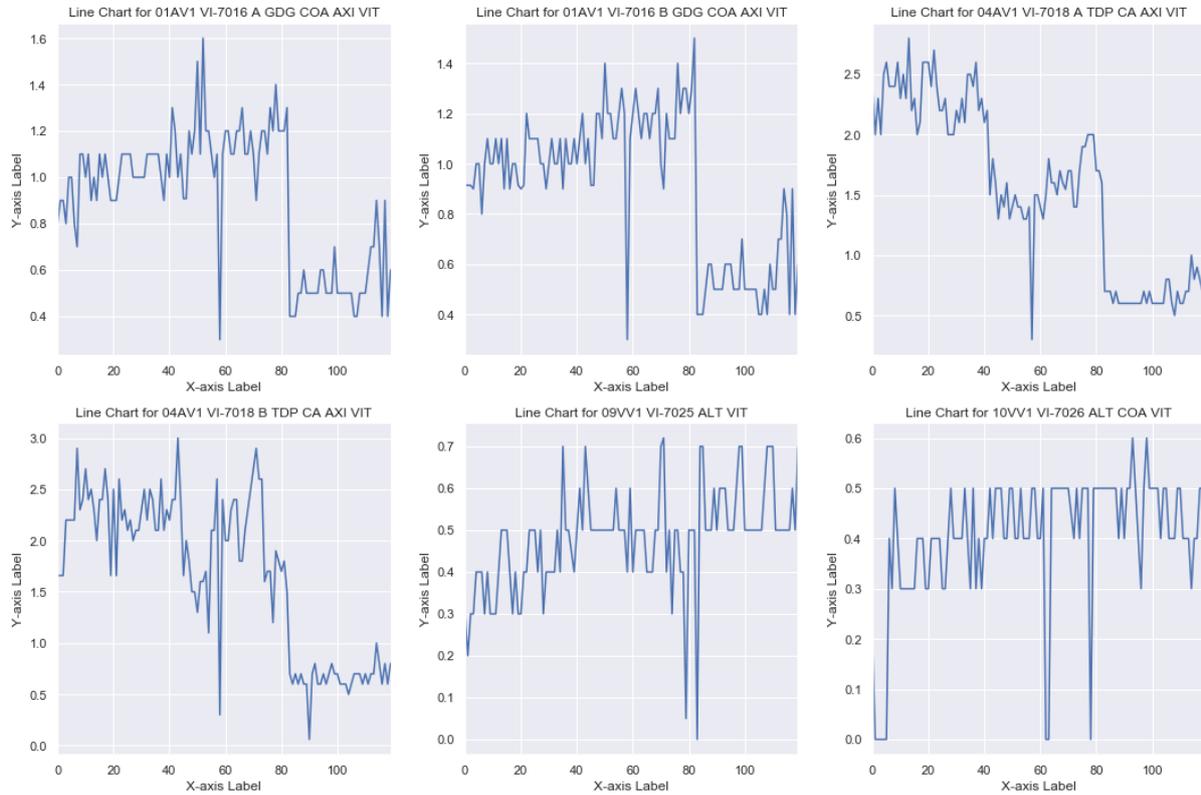
## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

	count	mean	std	min	25%	50%	75%	max
01AD1 ZI-7052A GDG COA AXI DEP	120.0	0.012417	0.046635	-0.39	0.000000	0.010000	0.0300	0.23
01AD1 ZI-7052-B GDG COA AXI DEP	120.0	0.048833	0.040192	-0.36	0.040000	0.050000	0.0600	0.12
01XD1 VI-7015-X GDG COA Dep	120.0	48.808333	13.688796	1.00	39.000000	44.000000	61.0000	81.00
01YD1 VI-7015-Y GDG COA Dep	120.0	21.575000	5.168851	1.00	18.000000	19.000000	27.0000	31.00
04XD1 VI-7017-X TDP CA DEP	120.0	15.316667	10.724184	0.00	12.000000	16.000000	23.0000	73.00
04YD1 VI-7017-Y TDP CA DEP	120.0	24.175000	31.496742	0.00	0.000000	0.000000	63.5000	84.00
05XD1 VI-7020-X RÉD E CA DEP	120.0	12.691667	1.612951	1.00	12.000000	13.000000	14.0000	16.00
05YD1 VI-7020-Y RÉD E CA DEP	120.0	11.008333	1.595666	1.00	11.000000	11.000000	11.0000	23.00
06AD1 ZI-7054-A RÉD ECOA AXI DEP	120.0	0.157563	0.101161	-0.32	0.130000	0.190000	0.2200	0.25
06AD1 ZI-7054-B RÉD ECOA AXI DEP	120.0	0.156050	0.106402	-0.30	0.120000	0.180000	0.2300	0.28
06XD1 VI-7021-X RÉD ECOA DEP	120.0	8.325000	1.856909	0.00	8.000000	9.000000	9.0000	11.00
06YD1 VI-7021-Y RÉD ECOA DEP	120.0	8.450000	1.714251	1.00	8.000000	8.000000	9.0000	24.00
07XD1 VI-7023-X RÉD RCOA DEP	120.0	7.437500	2.776373	6.00	7.000000	7.000000	7.0000	37.00
07YD1 VI-7023-Y RÉD RCOA DEP	120.0	9.458333	1.608255	7.00	9.000000	9.000000	10.0000	24.00
08XD1 VI-7022-X RÉD R CA DEP	120.0	18.900000	2.613475	16.00	18.000000	19.000000	19.0000	45.00
08YD1 VI-7022-Y RÉD R CA DEP	120.0	18.325000	2.352051	8.00	18.000000	18.000000	19.0000	40.00
01AV1 VI-7016 A GDG COA AXI VIT	120.0	0.907627	0.293961	0.30	0.600000	1.000000	1.1000	1.60
01AV1 VI-7016 B GDG COA AXI VIT	120.0	0.914159	0.291581	0.30	0.600000	1.000000	1.1000	1.50
04AV1 VI-7018 A TDP CA AXI VIT	120.0	1.545378	0.707790	0.30	0.700000	1.600000	2.2000	2.80
04AV1 VI-7018 B TDP CA AXI VIT	120.0	1.658421	0.770804	0.06	0.700000	1.800000	2.3000	3.00
09VV1 VI-7025 ALT VIT	120.0	0.478500	0.123259	0.00	0.400000	0.500000	0.5000	0.72
10VV1 VI-7026 ALT COA VIT	120.0	0.403750	0.131597	0.00	0.400000	0.400000	0.5000	0.60
05VV1 VI-7028 RÉD ENTRÉE ACC	120.0	1.412966	6.592969	0.00	0.677500	0.820000	0.9300	73.00
07VV1 VI-7029 RÉD REND ACC	120.0	0.723590	0.169475	0.20	0.597500	0.665000	0.8825	1.10
GENERATOR LOAD	120.0	5.610169	1.271431	2.70	4.700000	5.600000	6.3000	12.00
OA-PI-7045 DISCHARGE PRESS	120.0	5.837179	0.851522	0.85	5.800000	5.900000	6.1000	7.50

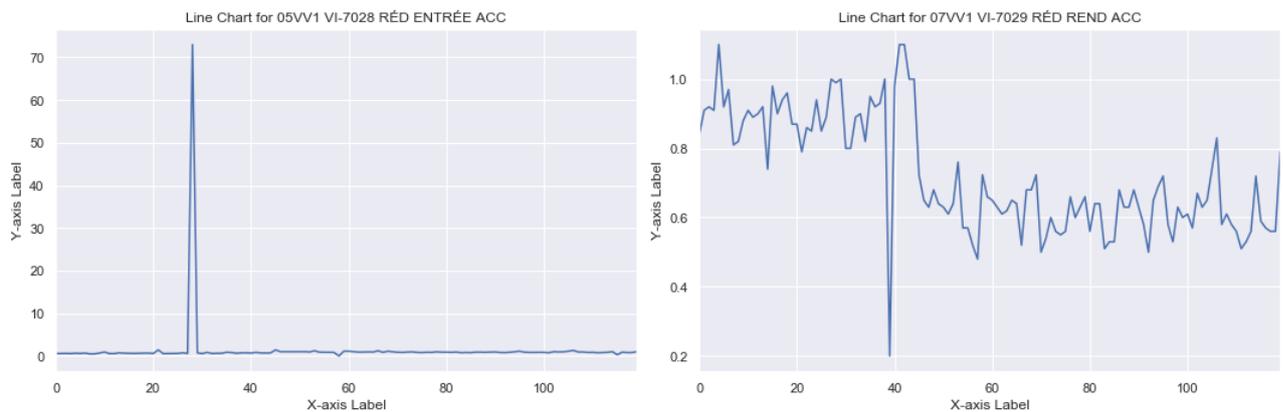
# Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

## 4.4.Représentation des Données

Le **Line Chart** est une visualisation couramment utilisée pour représenter des données qui évoluent dans le temps. Ils sont particulièrement utiles pour analyser et comprendre les tendances, les modèles et les variations des données sur une période donnée. Dans notre cas chaque étiquette (ligne) est collectée et enregistrée dans un intervalle de 3 à 5 jours.



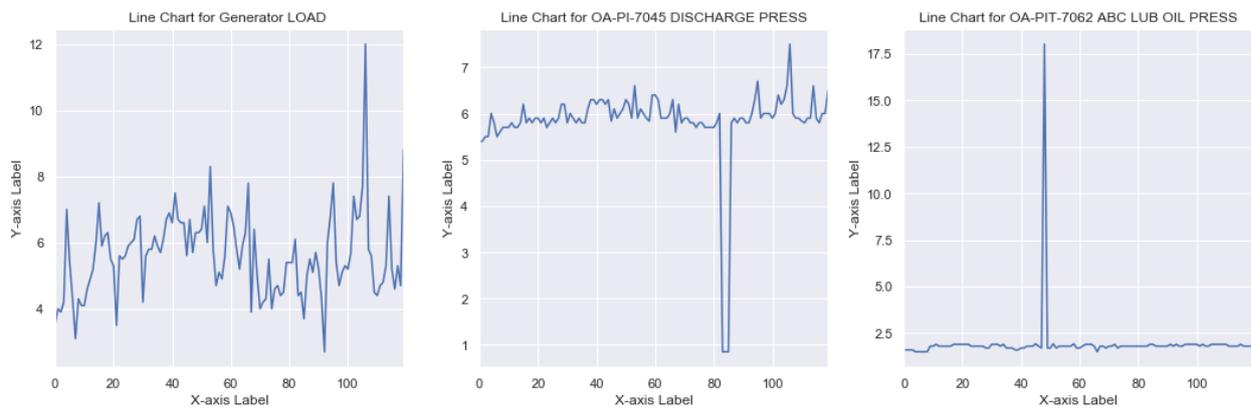
**Figure 4-8:** Visualisation des données de Velocity.



**Figure 4-9:** Visualisation des données d'Accélération

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

---



**Figure 4-10:** Visualisation des données de pression et de la charge.

# Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

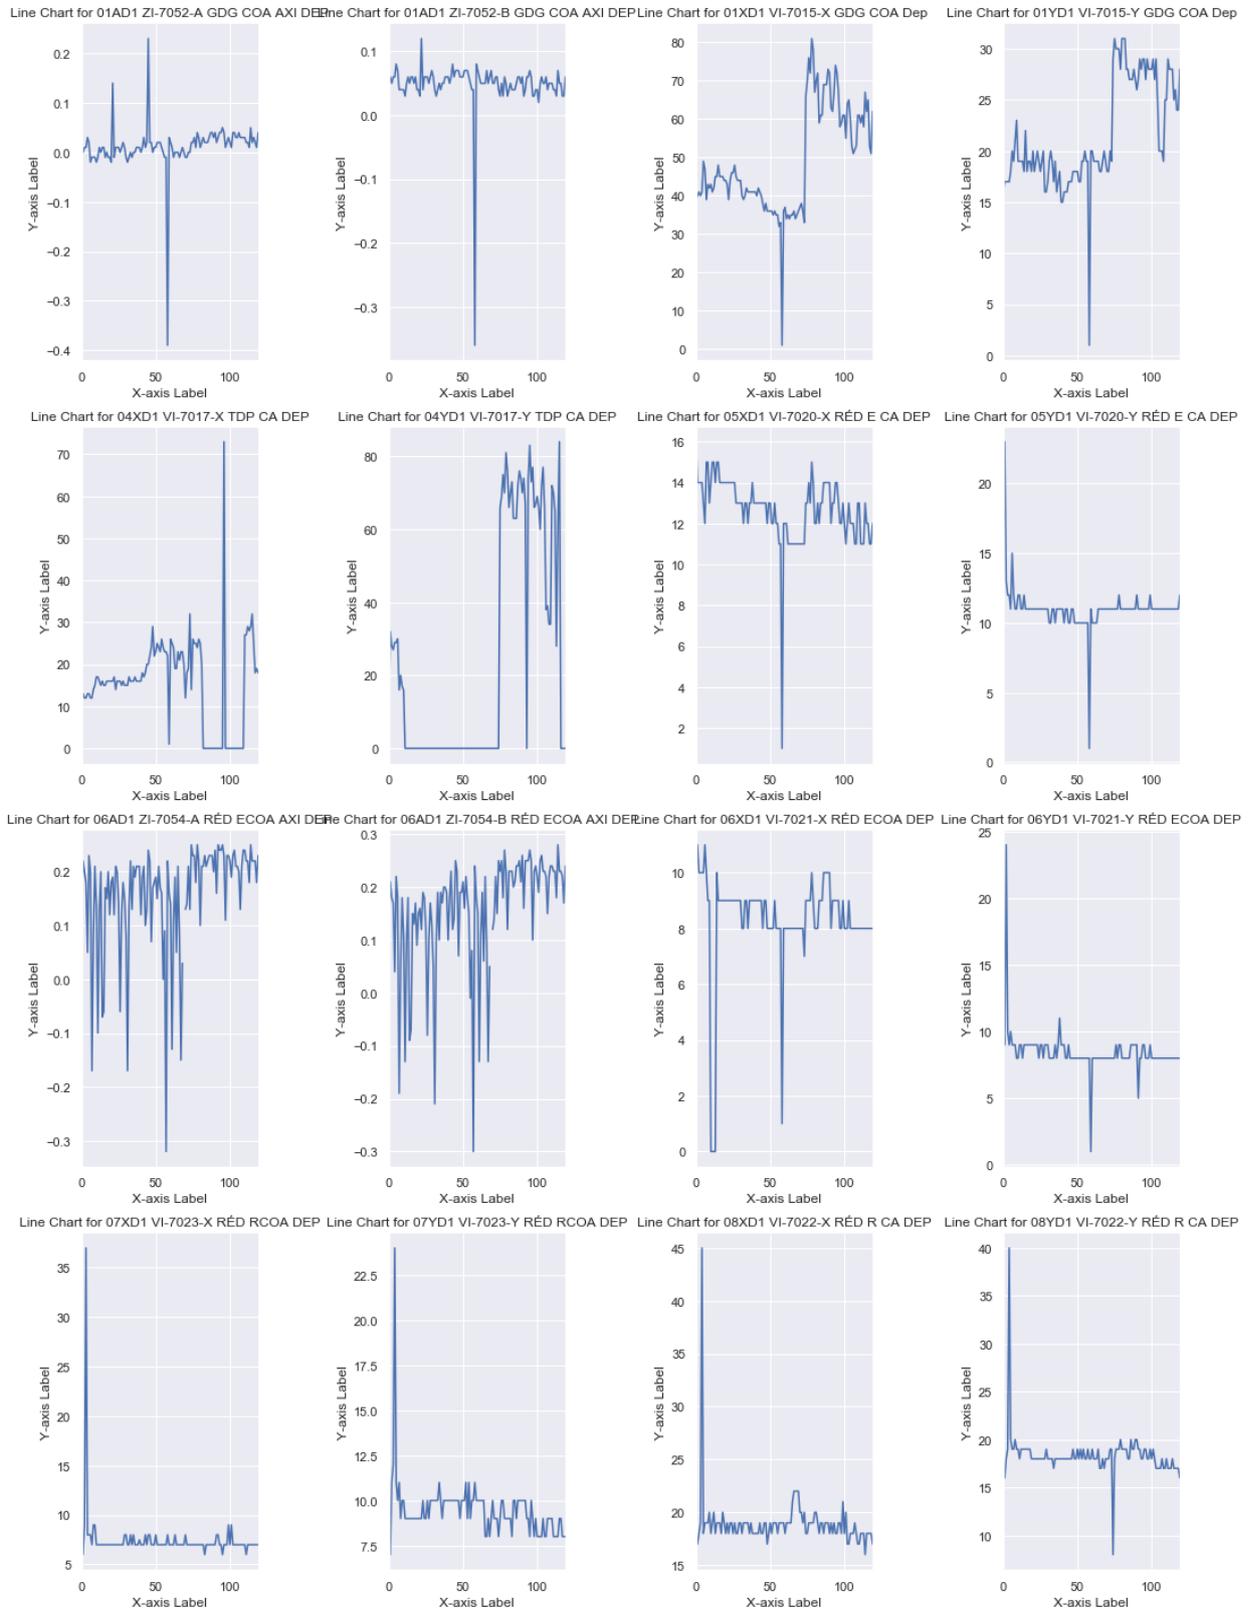


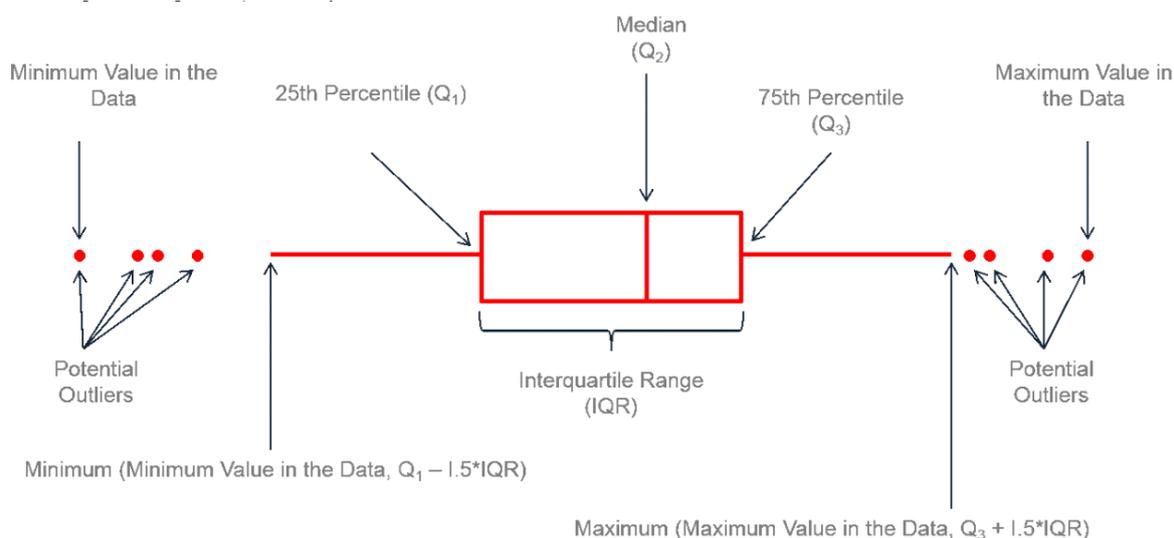
Figure 4-11: Visualisation des données de Déplacement

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

Afin de créer un modèle efficace pour notre système de surveillance conditionnelle de maintenance prédictive, on a entrepris une étude détaillée des variations des données. L'une des techniques qu'on a utilisées est l'utilisation de Box Plot pour analyser la somme des deux différences consécutives entre les points de données.

En calculant les différences entre les points de données consécutifs, nous pouvons capturer le taux de variation ou de changement des données dans le temps. En additionnant ces différences, on peut obtenir une mesure du changement global entre les points de données consécutifs. Cela peut être utile pour identifier des écarts significatifs ou des déviations dans les données, qui peuvent indiquer des anomalies potentielles ou des conditions de pré-alarme.

Le **Box Plot** est un outil graphique qui fournit une représentation visuelle de la distribution et de la variabilité des sommes des différences. Il se compose d'une boîte, qui représente la plage interquartile (IQR) des données, et de moustaches qui s'étendent de la boîte pour indiquer la gamme des données. Tout point de données se situant en dehors des moustaches est considéré comme une valeur aberrante.



**Figure 4-12:** Description de l'anatomie du Box Plot

En examinant le Box Plot, on peut obtenir des informations sur la distribution des sommes des différences. Cela comprend l'identification de la médiane, qui représente la tendance centrale des données, ainsi que les quartiles qui divisent les données en quatre parties égales. De plus, les valeurs aberrantes (anomalies) peuvent être facilement identifiées car elles se trouvent en dehors des moustaches.

L'analyse du **Box plot** permet de comprendre la variabilité globale et les schémas des données. Elle nous permet de détecter tout décalage ou tendance anormale qui pourrait indiquer des problèmes potentiels dans les turbines à gaz. En examinant attentivement les diagrammes en boîte et en tenant compte du contexte des données, nous pouvons obtenir des informations précieuses sur le comportement et les caractéristiques des variables que nous surveillons.

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

Dans l'ensemble, cette approche d'étude de la variation des données et d'analyse du Box Plot pour la somme des différences consécutives offre une méthode robuste pour identifier les anomalies potentielles et les conditions de pré-alarme dans notre turbine à gaz.

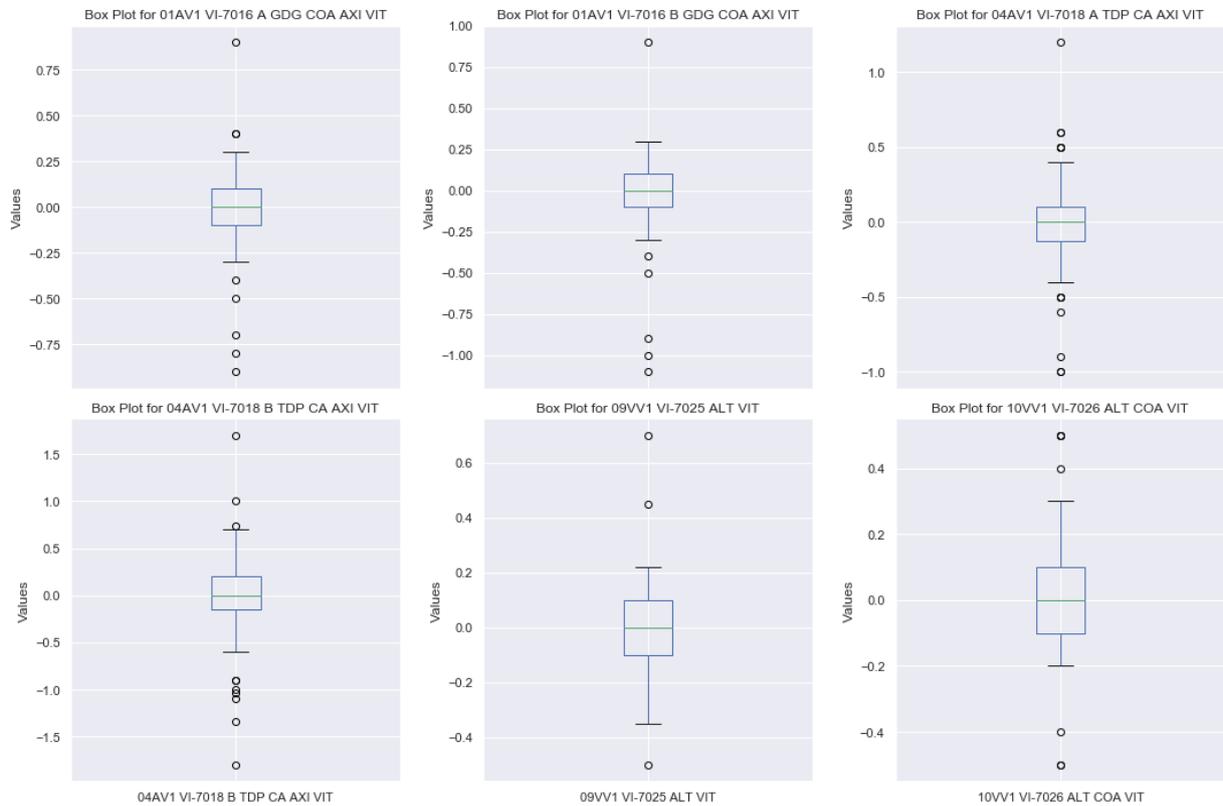


Figure 4-13: Box Plot pour la somme des différences consécutives de Velocity

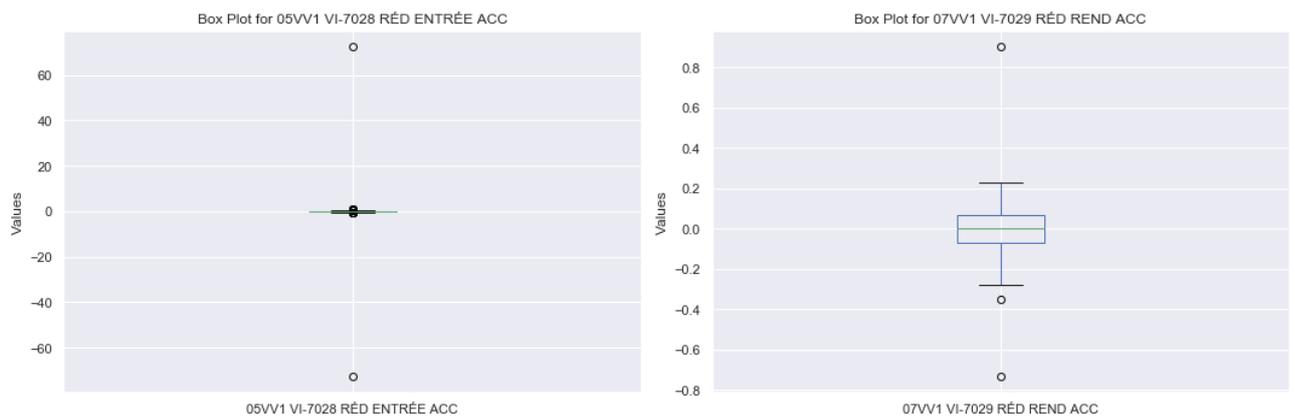
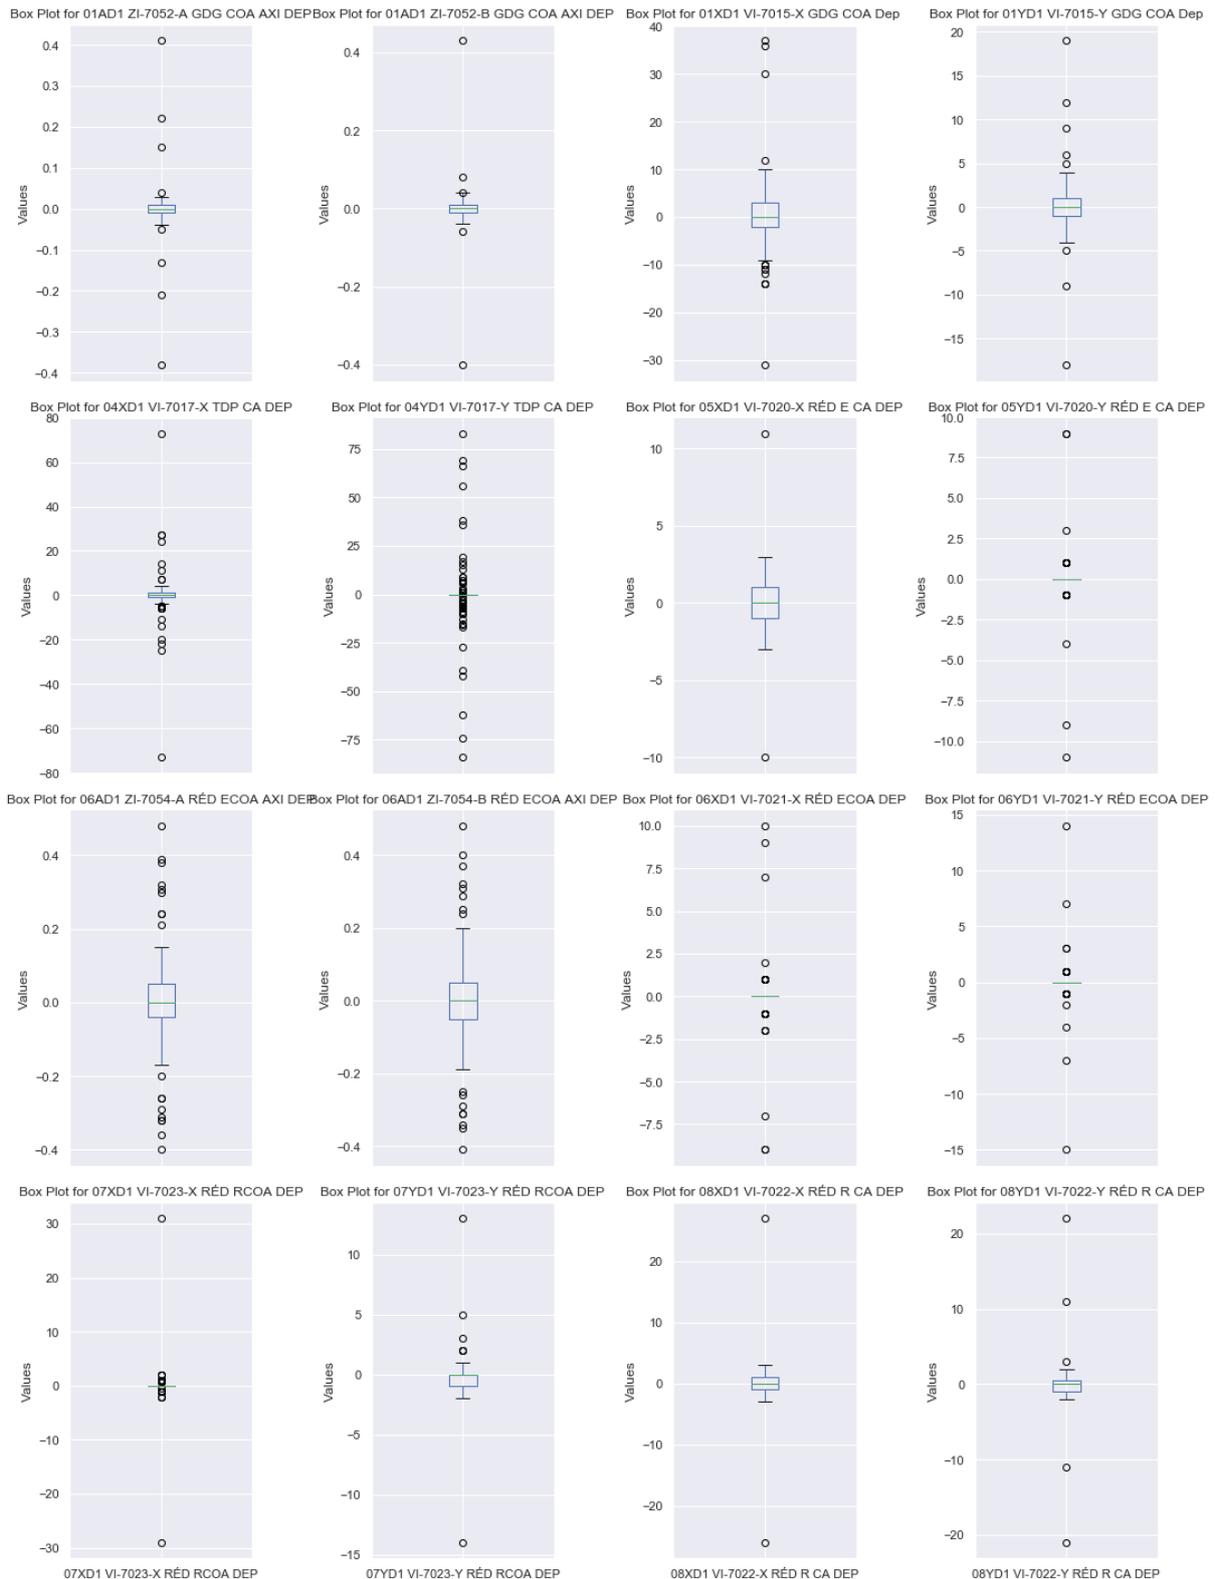


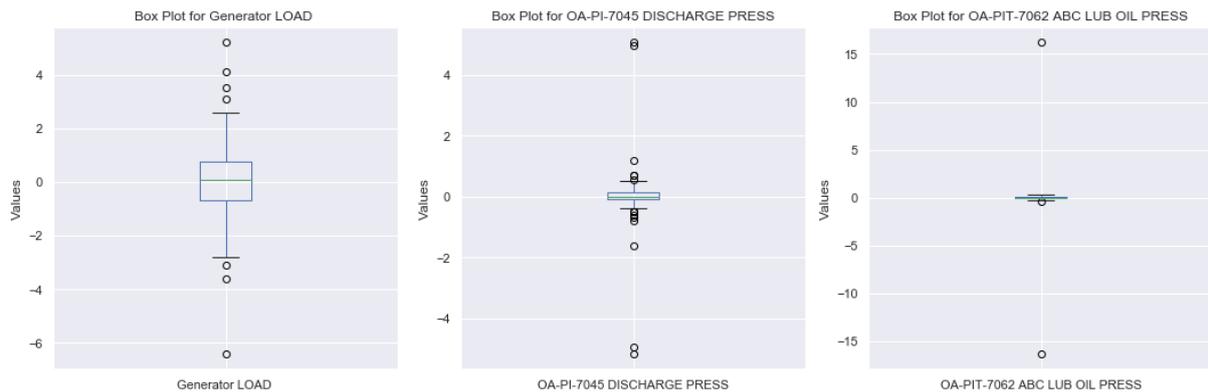
Figure 4-14: Box Plot pour la somme des différences consécutives d'Acceleration

# Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)



**Figure 4-15:** Box Plot pour la somme des différences consécutives de Déplacement

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)



**Figure 4-16:** Box Plot pour la somme des différences consécutives de pression et de la Charge

Après avoir identifié les anomalies potentielles, nous avons créé une autre variable appelée "Condition" qui prend la valeur 1 ou 0. La valeur 0 est attribuée aux turbines en bon état, tandis que la valeur 1 est attribuée aux anomalies (mauvais état).

Cette nouvelle variable, "Condition", nous permet de catégoriser chaque observation en fonction de son état, qu'il soit bon ou présentant des anomalies. En assignant la valeur 1 aux turbines en bon état, nous créons une distinction claire entre les observations normales et celles qui montrent des signes de problèmes.

En utilisant cette variable, nous sommes en mesure de développer des modèles d'apprentissage automatique et des algorithmes de détection des anomalies. En entraînant ces modèles avec les données historiques de la turbine, ils peuvent apprendre à reconnaître les caractéristiques associées aux états de bon fonctionnement et aux états défectueux. Ainsi, lorsque de nouvelles données sont introduites dans le système, nous pouvons les évaluer en fonction de leur similitude avec les exemples d'état bon ou mauvais, et ainsi déterminer si la turbine est en bon état ou présente des anomalies.

L'utilisation de la variable "Condition" nous permet donc de transformer le problème de surveillance conditionnelle en un problème de classification. En classant chaque observation en fonction de son état, nous pouvons prendre des décisions éclairées sur les actions à entreprendre, telles que la planification de la maintenance préventive ou l'intervention immédiate en cas de détection d'anomalies.

En résumé, la création de la variable "Condition" nous permet de représenter l'état de la turbine en utilisant une valeur binaire, facilitant ainsi l'application de techniques de classification et de détection des anomalies. Cela nous aide à prendre des décisions basées sur l'état de la turbine, en nous permettant d'identifier et de réagir rapidement aux problèmes potentiels, et ainsi d'assurer un fonctionnement optimal et fiable de la turbine.

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

```
Entrée [173]: count = merged_Data['Condition'].value_counts()
              print(count)
```

```
0    79
1    40
Name: Condition, dtype: int64
```

Figure 4-17: Les résultats obtenus pour la variable "Condition"

Les résultats obtenus pour la variable "Condition" sont les suivants : 0 avec une fréquence de 79 observations et 1 avec une fréquence de 40 observations. Ces chiffres représentent le décompte des turbines classées respectivement en mauvais état (0) et en bon état (1) dans notre échantillon de données.

### 4.5. Corrélation des caractéristiques avec la condition

Le diagramme de corrélation des caractéristiques avec la condition est un outil visuel qui permet d'analyser la relation entre les différentes caractéristiques d'une machine et son état de fonctionnement. Il est généralement présenté sous la forme d'un graphique à barres.

L'objectif principal de ce diagramme est de mettre en évidence les caractéristiques les plus significativement liées à l'état de la machine. Cela permet de prioriser les facteurs qui ont le plus d'impact sur la condition de la machine et de prendre des décisions éclairées en matière de maintenance ou de prévention des défaillances.

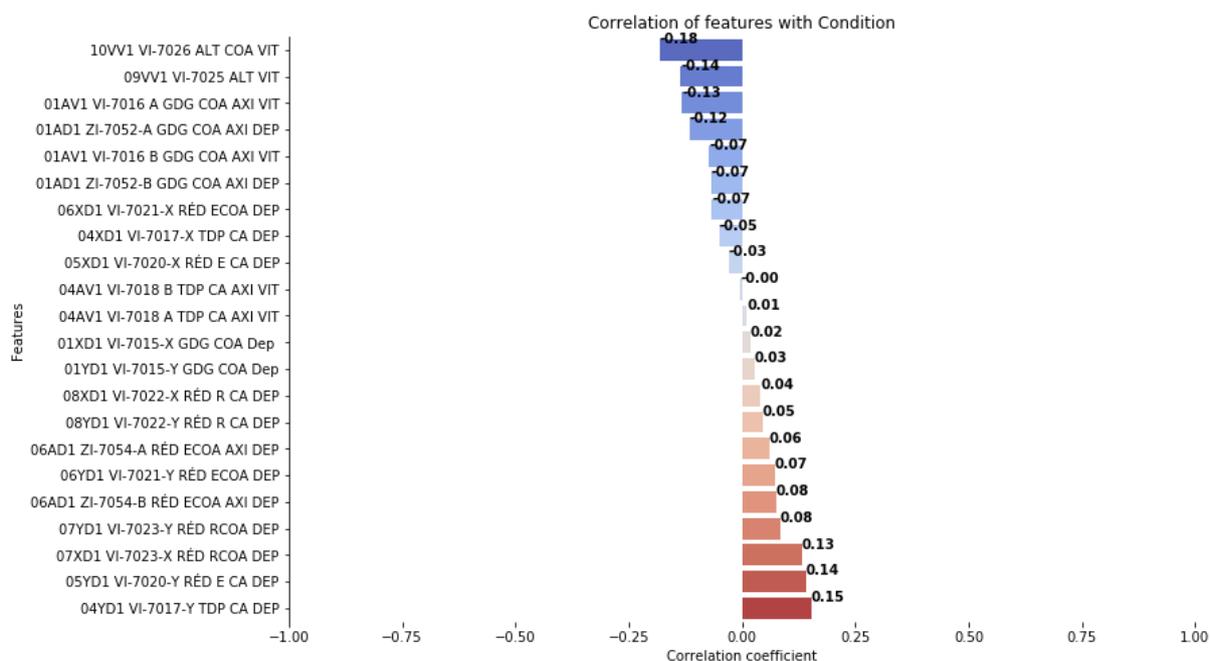


Figure 4-18: diagramme de corrélation des caractéristiques avec la condition

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

---

L'interprétation du diagramme de corrélation des caractéristiques avec la condition met en évidence des résultats intéressants. Les caractéristiques qui semblent avoir une corrélation significative avec l'état de la turbine sont : le déplacement en premier degré, la Velocity et l'accélération. Ces trois paramètres jouent un rôle important dans l'évaluation de la condition de la machine.

Le déplacement est une mesure du déplacement physique d'une partie de la machine. Une corrélation élevée entre le déplacement et l'état de la machine suggère que des mouvements anormaux ou excessifs peuvent indiquer un problème potentiel. Il peut être utilisé pour détecter des défauts tels que des désalignements ou des jeux excessifs.

La Velocity, qui représente la vitesse de déplacement, est également une caractéristique significative. Une corrélation élevée entre la Velocity et l'état de la machine suggère que des variations importantes de vitesse peuvent être associées à des dysfonctionnements ou à des conditions anormales de fonctionnement. La Velocity peut être utilisée pour détecter des vibrations excessives ou des changements de régime indésirables.

L'accélération mesure la variation de la vitesse au fil du temps. Une corrélation élevée entre l'accélération et l'état de la machine indique que des changements rapides ou brusques de vitesse peuvent être liés à des défaillances ou à des situations anormales. L'accélération peut être utilisée pour détecter des chocs, des impacts ou des vibrations intenses.

En revanche, les températures et les pressions semblent ne pas présenter de corrélation significative avec l'état de la machine dans ce contexte. Cela ne signifie pas nécessairement que ces paramètres ne sont pas importants, mais simplement que dans cette étude particulière, ils n'ont pas démontré une forte association avec la condition de la machine. Il est toujours recommandé de prendre en compte ces paramètres et de les surveiller, car ils peuvent être pertinents dans d'autres contextes ou pour d'autres types de machines.

En conclusion, les résultats de l'interprétation du diagramme de corrélation mettent en évidence les déplacements, la Velocity et l'accélération comme les caractéristiques les plus significatives pour évaluer l'état de la turbine. Cela peut fournir des indications précieuses pour la maintenance préventive et la détection précoce des défaillances, permettant ainsi d'améliorer la fiabilité et la durée de vie des turbines.

### 4.6. La Construction des modèles d'intelligence artificielle (AI)

Il existe de nombreux algorithmes de Machine Learning (ML) et différentes architectures de réseaux de neurones artificiels (ANN), chacun étant caractérisé par ses propres paramètres et offrant une précision (**Accuracy**) qui nous intéresse.

La performance d'un modèle est évaluée en utilisant la mesure de précision (Accuracy), qui représente simplement le rapport entre les prédictions correctes et le nombre total de prédictions effectuées par le modèle. Une précision élevée indique que le modèle est capable de produire des prédictions correctes de manière fiable. Cependant, la précision seule ne suffit pas pour évaluer entièrement les performances d'un modèle.

---

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

En plus de l'Accuracy, l'évolution de la fonction de coût (**Loss Function**) est également un aspect crucial pour évaluer les modèles. La fonction de coût mesure la différence entre les prédictions du modèle et les valeurs réelles des données d'entraînement. L'objectif est de minimiser cette fonction de coût, ce qui signifie que le modèle est capable de s'ajuster aux données et de fournir des prédictions de plus en plus précises au fil de l'apprentissage.

Ainsi, lors de la sélection d'un algorithme de ML ou d'une architecture de réseau de neurones, il est essentiel de prendre en compte à la fois la précision (Accuracy) et l'évolution de la fonction de coût (Loss Function) pour garantir des performances optimales du modèle. Des mesures supplémentaires telles que la précision par classe, la sensibilité et la spécificité peuvent également être utilisées pour évaluer les performances dans des tâches de classification plus complexes.

### 4.7. Les algorithmes de Machine Learning

Une fois que les données ont été filtrés et que de nouvelles caractéristiques ont été créées, il est temps de sélectionner le modèle qui sera utilisé pour effectuer des prédictions. Cette étape est cruciale car le modèle que nous choisissons peut avoir un impact significatif sur les performances globales et la capacité prédictive de notre modèle. La chose à garder à l'esprit est qu'il n'existe pas de modèle unique pour tous les problèmes, ce qui signifie que nous devons généralement expérimenter avec un ensemble polyvalent d'algorithmes pour découvrir celui qui donne les meilleures performances.

La précision des algorithmes (modèles) de ML pour La surveillance automatique de l'état de Turbine à Gaz MP 5001 est résumée au graphe suivant :

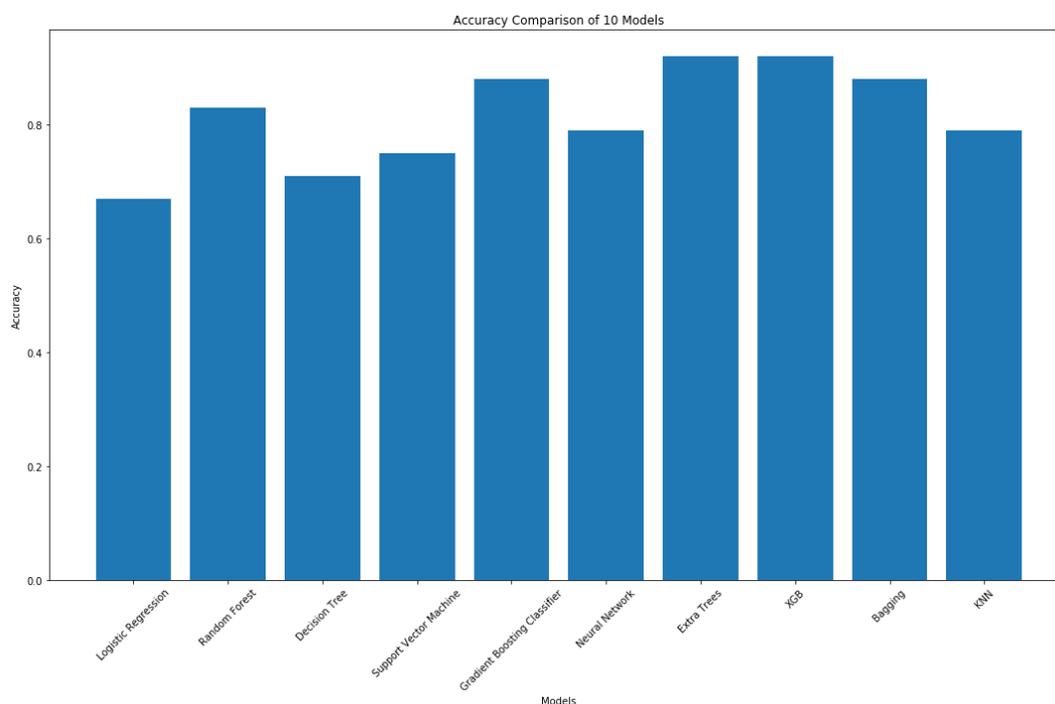


Figure 4-19: La précision des algorithmes de ML expérimentés

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

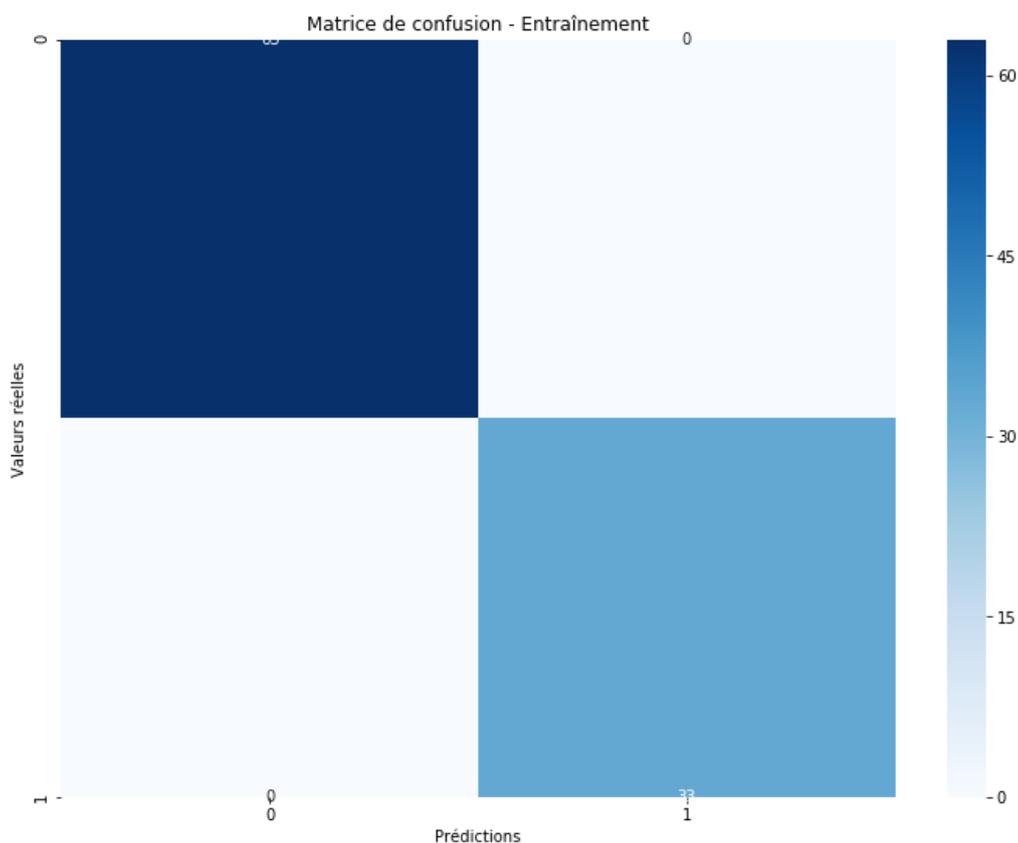
On remarque qu'il y a cinq (05) algorithmes qui possèdent des précisions satisfaites (plus de 80%), dans la suite de notre étude en choisissant les trois (03) algorithmes plus performants pour l'appliquer et qui sont les suivants : XGBoost Classificateur, Bagging, et Extra Trees.

### 4.8.L'ensemble d'entraînement des trois modèles

```
accuracy_train = accuracy_score(y_train, y_pred_train)
print("Précision sur l'ensemble d'entraînement:", accuracy_train)
Précision sur l'ensemble d'entraînement: 1.0
```

**Figure 4-20:** Précision sur l'ensemble d'entraînement des trois modèles

La précision de 1.0 sur l'ensemble d'entraînement indique que les trois modèles ont réussi à prédire avec une exactitude de 100% les conditions des données d'entraînement. Cela signifie que chaque instance dans l'ensemble d'entraînement a été correctement classée par le modèle. Une précision de 1.0 suggère une très bonne adéquation du modèle aux données d'entraînement et une capacité à capturer les relations et les motifs présents dans ces données.



**Figure 4-21:** Matrice de confusion – Entraînement des trois modèles

Une matrice de confusion est une méthode permettant d'évaluer le bon fonctionnement d'un modèle de catégorisation. Elle montre les différences entre les prévisions du modèle et

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

les valeurs réelles. Dans votre cas, le modèle a correctement prédit chaque occurrence des deux classes. Lorsque les prévisions concordent parfaitement avec les valeurs réelles, la matrice de confusion affiche des valeurs élevées le long de la diagonale principale. En termes de précision, cela témoigne de la performance remarquable du modèle.

Cependant, il est important de noter que cette précision élevée sur l'ensemble d'entraînement ne garantit pas nécessairement une performance similaire sur de nouvelles données. Il est possible que le modèle soit devenu trop spécifique aux données d'entraînement et qu'il ait mémorisé les exemples plutôt que de généraliser les schémas sous-jacents. Par conséquent, il est crucial d'évaluer également les performances du modèle sur un ensemble de données de test indépendant pour obtenir une estimation plus fiable de sa capacité à généraliser et à prédire avec précision les nouvelles données.

En résumé, une précision de 1.0 sur l'ensemble d'entraînement est encourageante, mais il est essentiel de poursuivre l'évaluation du modèle sur l'ensemble de test pour obtenir une évaluation complète de sa performance.

### 4.9.L'ensemble de Test des trois Modèles

#### 4.9.1. Test de Validation de XGBoost Classificateur

La figure IV-23 illustre la comparaison entre les valeurs réelles et prédites par le modèle XGBoost. Elle montre bien que l'ensemble des états prédites sont en concordance avec celle réelles. Les résultats de ce modèle présentent des performances élevées dans la plupart des mesures. On a obtenu une précision optimale de **92%** comme il montre le tableau IV-2. C'est à dire que 0.08 des données qui ne réponds pas au modèle établer par XGBoost.

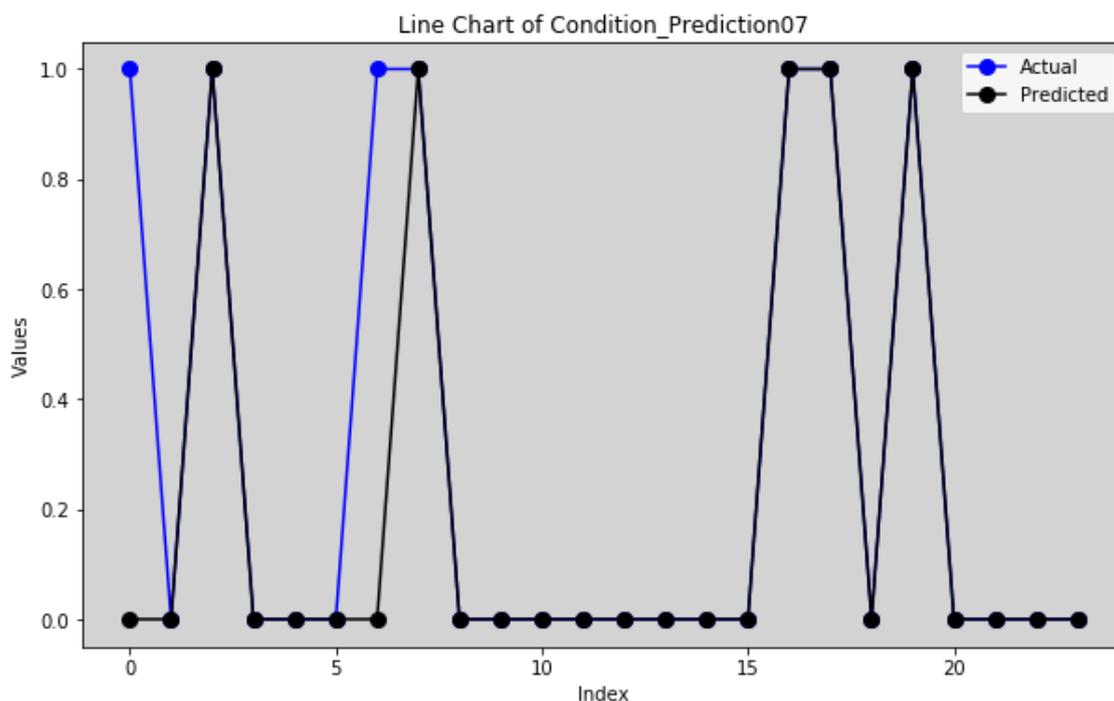


Figure 4-22: Comparaison entre les valeurs réelles et prédites par le XG Boost

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

Table 4-2 : Indicateurs supplémentaires sur de modèle XGB

	precision	recall	f1-score	support
0	0.89	1.00	0.94	17
1	1.00	0.71	0.83	7
Accuracy			0.92	24
Macro avg	0.95	0.86	0.89	24
Weighted avg	0.93	0.92	0.91	24

Une autre façon pour exprimer le résultat de la performance du modèle XGBoost est la matrice de confusion, La matrice de confusion fournie présente les résultats des prédictions du modèle pour deux classes : 0 et 1. Elle montre la précision, le rappel (recall) et le score F1 pour chaque classe, ainsi que le support qui représente le nombre d'instances de chaque classe dans l'ensemble de données.

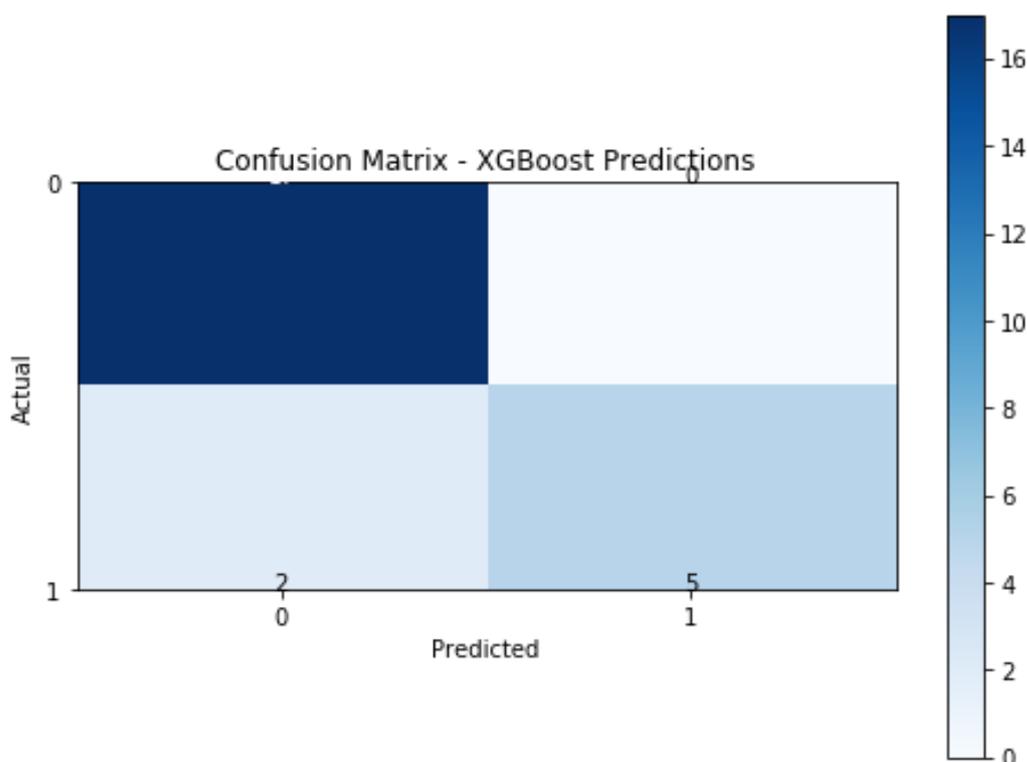


Figure 4-23: La matrice de confusion de la performance du modèle XGB

Pour la classe 0, le modèle a une précision de 0,89, ce qui signifie que parmi les instances prédites comme étant de la classe 0, 89 % étaient réellement de la classe 0. Le rappel de 1,00 indique que toutes les instances réelles de la classe 0 ont été correctement identifiées. Le score F1 de 0,94, qui est la moyenne harmonique de la précision et du rappel, indique un bon équilibre entre la précision et le rappel pour la classe 0. Ces mesures indiquent

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

---

que le modèle a une très bonne capacité à prédire et à identifier correctement les instances de la classe 0. De plus, le support de 17 indique qu'il y avait 17 instances de la classe 0 dans l'ensemble de données.

Pour la classe 1, le modèle présente une précision parfaite de 1,00, ce qui indique que toutes les instances prédites comme étant de la classe 1 étaient effectivement de la classe 1. Cependant, le rappel de 0,71 montre que parmi toutes les instances réelles de la classe 1, seulement 71 % ont été correctement identifiées par le modèle. Le score F1 de 0,83 indique une performance solide mais légèrement inférieure à celle de la classe 0. Ces résultats suggèrent que le modèle a une précision parfaite pour la classe 1, mais peut manquer certaines instances réelles de cette classe.

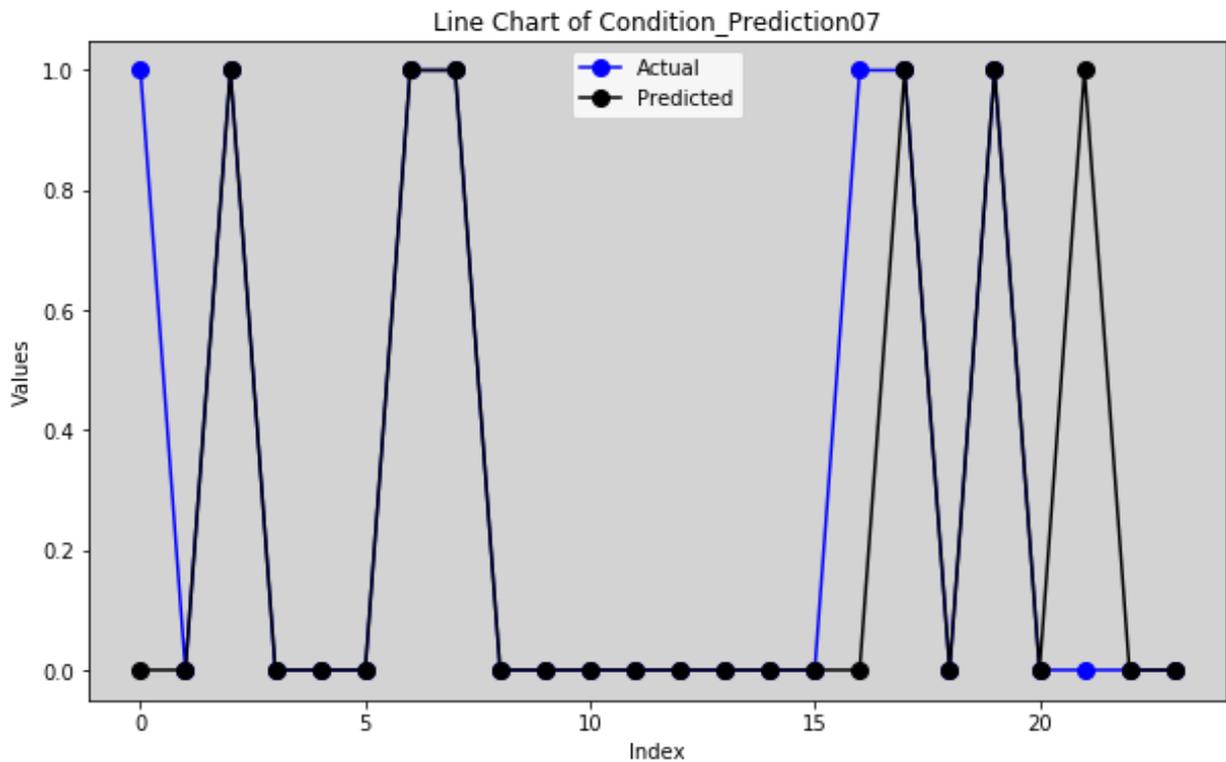
En ce qui concerne la précision globale, le modèle atteint une précision de 0,92, ce qui signifie qu'il a correctement prédit l'état pour 92 % des instances dans l'ensemble de données. La moyenne macro des mesures (précision, rappel et score F1) pour les deux classes est de 0,95 pour la précision, 0,86 pour le rappel et 0,89 pour le score F1. La moyenne pondérée, qui tient compte du nombre d'instances dans chaque classe, est de 0,93 pour la précision, 0,92 pour le rappel et 0,91 pour le score F1. Ces résultats indiquent une performance globale solide du modèle dans la classification des instances pour les deux classes.

En conclusion, le modèle XGB présente des performances élevées avec une très bonne précision et un rappel parfait pour la classe 0. Bien que la précision pour la classe 1 soit également parfaite, le rappel est légèrement inférieur, ce qui suggère que certaines instances de la classe 1 peuvent être manquées. Néanmoins, l'exactitude globale de 92 % indique une capacité satisfaisante du modèle à prédire les étiquettes de classe dans l'ensemble de données à prédire.

### 4.9.2. Test de validation de Bagging

La figure IV-2 illustre la comparaison entre les valeurs réelles et prédites par le modèle Bagging. Elle montre bien que l'ensemble des états prédites sont en accord avec celle réelles. Les résultats de ce modèle présentent des performances globalement solides, mais légèrement inférieures à celles du modèle XGB. On a obtenu une précision optimale de **88%** comme il montre le tableau IV-3. C'est à dire que 0.12 des données qui ne réponds pas au modèle établir par Bagging.

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)



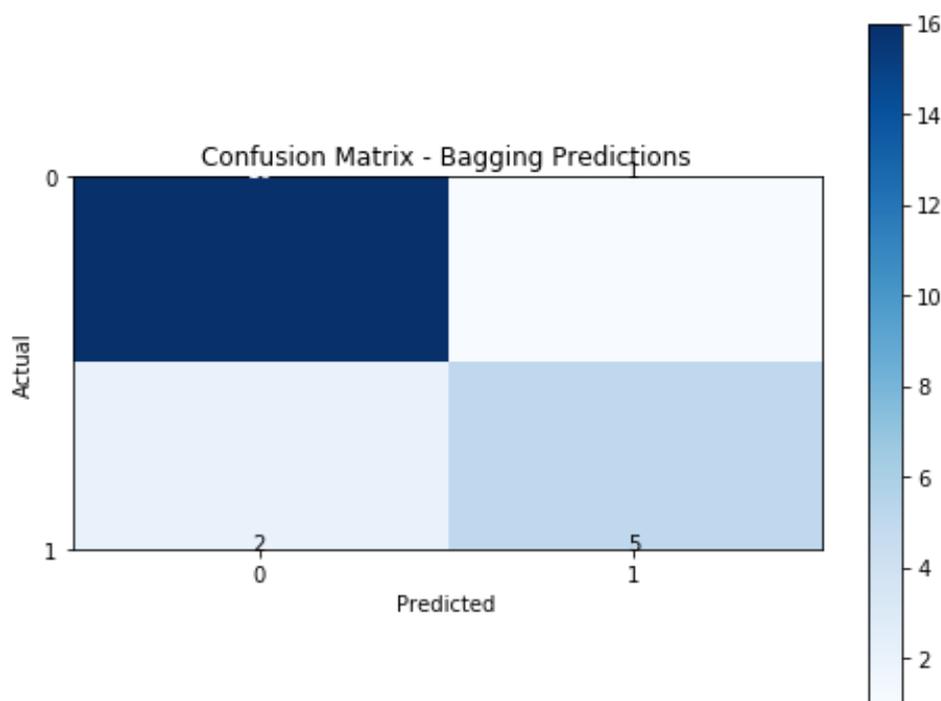
**Figure 4-24:** Comparaison entre les valeurs réelles et prédites par le Bagging

**Table 4-3:** Indicateurs supplémentaires sur de modèle Bagging

	precision	recall	f1-score	support
0	0.89	0.94	0.91	17
1	0.83	0.71	0.77	7
<b>Accuracy</b>			0.88	24
<b>Macro avg</b>	0.86	0.83	0.84	24
<b>Weighted avg</b>	0.87	0.88	0.87	24

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

La matrice de confusion présentée dans la figure suivante fournit les résultats des prédictions du modèle pour deux classes : 0 et 1.



**Figure 4-25:** La matrice de confusion la performance du modèle Bagging

Pour la classe 0, le modèle a une précision de 0,89, ce qui signifie que parmi les instances prédites comme étant de la classe 0, 89 % étaient réellement de la classe 0. Le rappel de 0,94 indique que parmi toutes les instances réelles de la classe 0, 94 % ont été correctement identifiées par le modèle. Le score F1 de 0,91, qui est la moyenne harmonique de la précision et du rappel, montre une performance équilibrée entre la précision et le rappel pour la classe 0. Ces mesures suggèrent que le modèle a une bonne capacité à prédire et à identifier les instances de la classe 0. Le support de 17 indique qu'il y avait 17 instances de la classe 0 dans l'ensemble de données.

Pour la classe 1, le modèle obtient une précision de 0,83, ce qui indique que parmi les instances prédites comme étant de la classe 1, 83 % étaient réellement de la classe 1. Le rappel de 0,71 montre que parmi toutes les instances réelles de la classe 1, seulement 71 % ont été correctement identifiées par le modèle. Le score F1 de 0,77 indique une performance solide, mais légèrement inférieure à celle de la classe 0. Ces résultats suggèrent que le modèle peut avoir des difficultés à identifier correctement les instances de la classe 1.

En ce qui concerne la précision globale, le modèle atteint une précision de 0,88, ce qui signifie qu'il a correctement prédit la classe pour 88 % des instances dans l'ensemble de données. La moyenne macro des mesures (précision, rappel et score F1) pour les deux classes est de 0,86 pour la précision, 0,83 pour le rappel et 0,84 pour le score F1. La moyenne

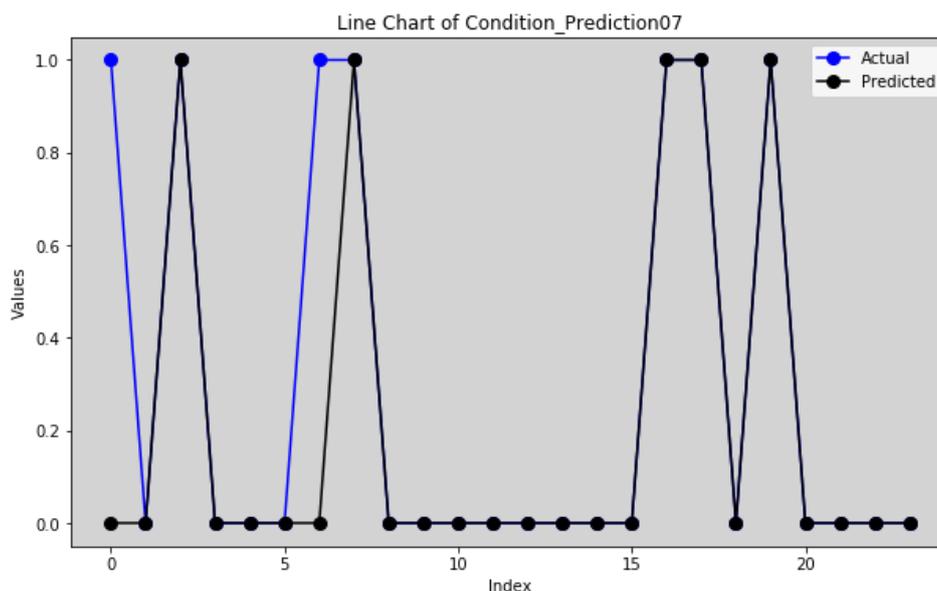
## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)

pondérée, qui tient compte du nombre d'instances dans chaque classe, est de 0,87 pour la précision, 0,88 pour le rappel et 0,87 pour le score F1.

En conclusion, le modèle Bagging présente des performances solides avec une bonne précision et un rappel élevé pour la classe 0. Cependant, pour la classe 1, le modèle montre une précision légèrement inférieure et un rappel plus faible, indiquant des difficultés à identifier correctement les instances de cette classe. Néanmoins, l'exactitude globale de 88 % indique une capacité acceptable du modèle à prédire les étiquettes de classe dans l'ensemble de données donné, bien qu'il puisse bénéficier d'améliorations pour une performance plus équilibrée entre les deux classes.

### 4.9.3. Test de Validation de Extra Trees

La figure IV-2 illustre la comparaison entre les valeurs réelles et prédites par le modèle Bagging. Elle montre bien que l'ensemble des états prédites sont en accord avec celle réelles. Les résultats de ce modèle présentent des performances très similaires à ceux du modèle XGB, avec une précision optimale de **92%** comme il montre le tableau IV-4. C'est à dire que 0.08 des données qui ne réponds pas au modèle établer par Extra Trees.

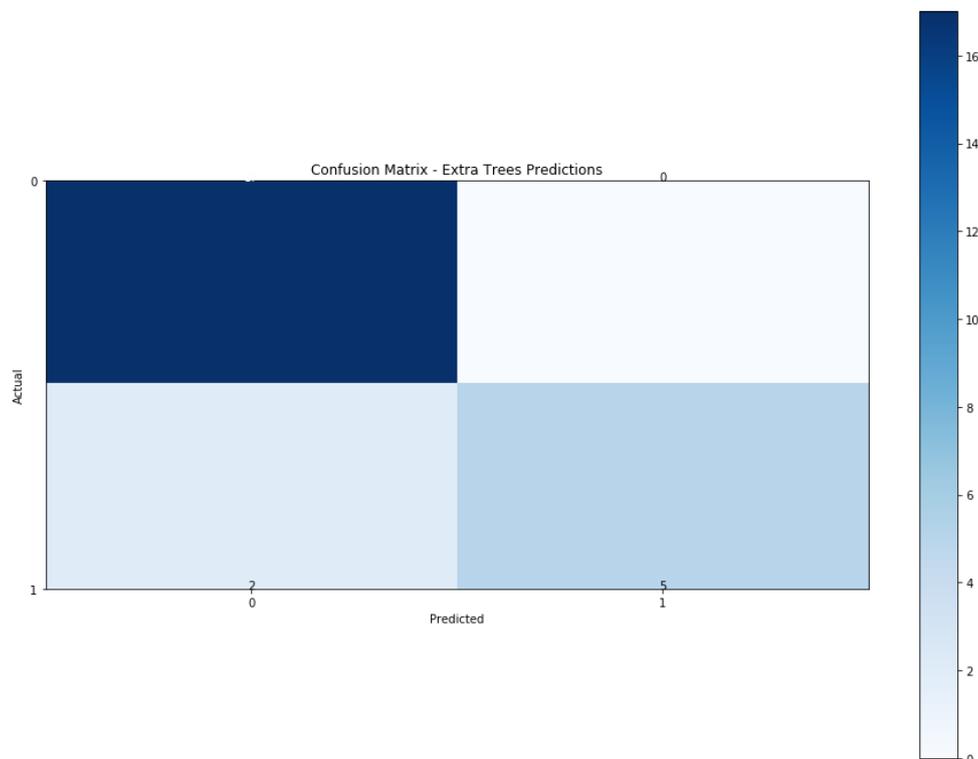


**Figure 4-26:** Comparaison entre les valeurs réelles et prédites par le Extra Trees

**Table 4-4:** Indicateurs supplémentaires sur de modèle Extra Trees

	precision	recall	f1-score	support
0	0.89	1.00	0.94	17
1	1.00	0.71	0.83	7
<b>Accuracy</b>			0.92	24
<b>Macro avg</b>	0.95	0.86	0.89	24
<b>Weighted avg</b>	0.93	0.92	0.91	24

## Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)



**Figure 4-27:** La matrice de confusion la performance du modèle Extra Trees

Pour la classe 0, le modèle présente une précision de 0,89, ce qui indique que parmi les instances prédites comme étant de la classe 0, 89 % étaient réellement de la classe 0. Le rappel de 1,00 indique que le modèle a correctement identifié toutes les instances réelles de la classe 0. Le score F1 de 0,94, qui est la moyenne harmonique de la précision et du rappel, montre une performance équilibrée entre la précision et le rappel pour la classe 0. Ces mesures suggèrent que le modèle a une excellente capacité à prédire et à identifier les instances de la classe 0. Le support de 17 indique qu'il y avait 17 instances de la classe 0 dans l'ensemble de données.

Pour la classe 1, le modèle atteint une précision de 1,00, ce qui signifie que parmi les instances prédites comme étant de la classe 1, 100 % étaient réellement de la classe 1. Cependant, le rappel de 0,71 indique que parmi toutes les instances réelles de la classe 1, seulement 71 % ont été correctement identifiées par le modèle. Le score F1 de 0,83 montre une performance solide, mais légèrement inférieure à celle de la classe 0. Bien que la précision soit parfaite pour la classe 1, le rappel indique qu'il y a des instances de la classe 1 qui n'ont pas été correctement identifiées par le modèle.

En termes de performance globale, le modèle atteint une précision de 0,92, ce qui signifie qu'il a correctement prédit la classe pour 92 % des instances dans l'ensemble de données. La moyenne macro des mesures (précision, rappel et score F1) pour les deux classes est de 0,95 pour la précision, 0,86 pour le rappel et 0,89 pour le score F1. La moyenne

## **Chapitre IV : La surveillance automatique de l'état de Turbine à Gaz MP 5001 par les modèles d'intelligence artificielle (IA)**

---

pondérée, qui tient compte du nombre d'instances dans chaque classe, est de 0,93 pour la précision, 0,92 pour le rappel et 0,91 pour le score F1.

En conclusion, le modèle Extra Trees présente des performances très similaires à celles du modèle XGB, avec une précision élevée et un rappel parfait pour la classe 0. Cependant, il montre également des résultats solides, mais légèrement inférieurs pour la classe 1, avec une précision parfaite mais un rappel plus faible. Dans l'ensemble, le modèle présente une bonne capacité à prédire les étiquettes de classe, avec une précision globale élevée et un équilibre entre la précision et le rappel pour les deux classes.

### **4.10. Conclusion**

Dans ce chapitre, dans le but de prédire l'état de la turbine et suivant une étude préliminaire, nous avons basé sur trois algorithmes d'apprentissage supervisé : XGB, Bagging et Extra Trees, qui présentent une très bonne précision par rapport à sept autres modèles. Nous avons effectué plusieurs étapes de prétraitement des données pour préparer les données brutes (sans traitement préalable) afin qu'elles puissent être utilisées par les modèles.

Dans notre étude, les paramètres clés liés à l'état de la turbine sont le déplacement, la Velocity et l'accélération, qui sont significativement corrélés. En revanche, les températures et les pressions ne semblent pas être des indicateurs pertinents pour évaluer l'état de la machine dans ce contexte spécifique.

Nous avons utilisé les résultats obtenus avec les paramètres optimaux de chaque classificateur pour comparer leurs performances. Les modèles XGB, Bagging et Extra Trees ont tous montré de bonnes performances.

En conclusion, Il est important de noter que le choix du modèle dépendra des besoins spécifiques de chaque problème et des caractéristiques des données. Dans notre étude, les deux modèles : XGB et Extra Trees semblent être un bon choix pour la classification de l'état de la machine.

## CONCLUSION GENERALE

L'industrie pétrolière est un secteur d'activité essentiel et compétitif, où les conséquences d'une mauvaise décision de maintenance peuvent entraîner des coûts d'arrêt élevés, compromettant la maintenabilité, la sécurité et l'environnement.

Pour que cette maintenance puisse atteindre correctement son objectif, de réduire les pannes, gagner du temps et améliorer la productivité et la rentabilité, une approche d'optimisation de cette dernière doit être appliquée.

Dans ce mémoire, une approche de maintenance prédictive aidée par l'intelligence artificielle était proposée. L'application des algorithmes d'IA utilisés pour la maintenance prédictive sur la turbine à gaz MS5001D ont démontré des performances satisfaisantes en assurant un contrôle automatique de l'état de santé de la turbine.

En premier lieu une étude préliminaire sur un ensemble de modèles a montré que trois algorithmes d'apprentissage supervisé : XGB, Bagging et Extra Trees, ont présenté une meilleure précision par rapport à sept autres modèles. Cette étude a montré aussi que les paramètres les plus significatifs sur l'état de la turbine sont le déplacement, la Velocity et l'accélération.

Les résultats de prédiction ont atteint une précision de 92% pour les deux modèles XGB et Extra Trees et 88% pour Bagging ce qui témoigne de l'efficacité de ces méthodes pour prédire les problèmes potentiels et prendre des mesures préventives en conséquence, afin de mieux planifier la maintenance et augmenter la durée de vie de la turbine.

Comme recommandation on suggère d'implémenter ce système de prédiction par l'IA dans les installations des turbines à gaz, où les données de surveillance sont riches grâce aux capteurs et à l'historique disponibles. Cela permettrait d'exploiter et d'utiliser ces données de manière efficace pour améliorer la maintenance prédictive et le contrôle de l'état de santé des turbines à gaz dans les plates-formes pétrolières.

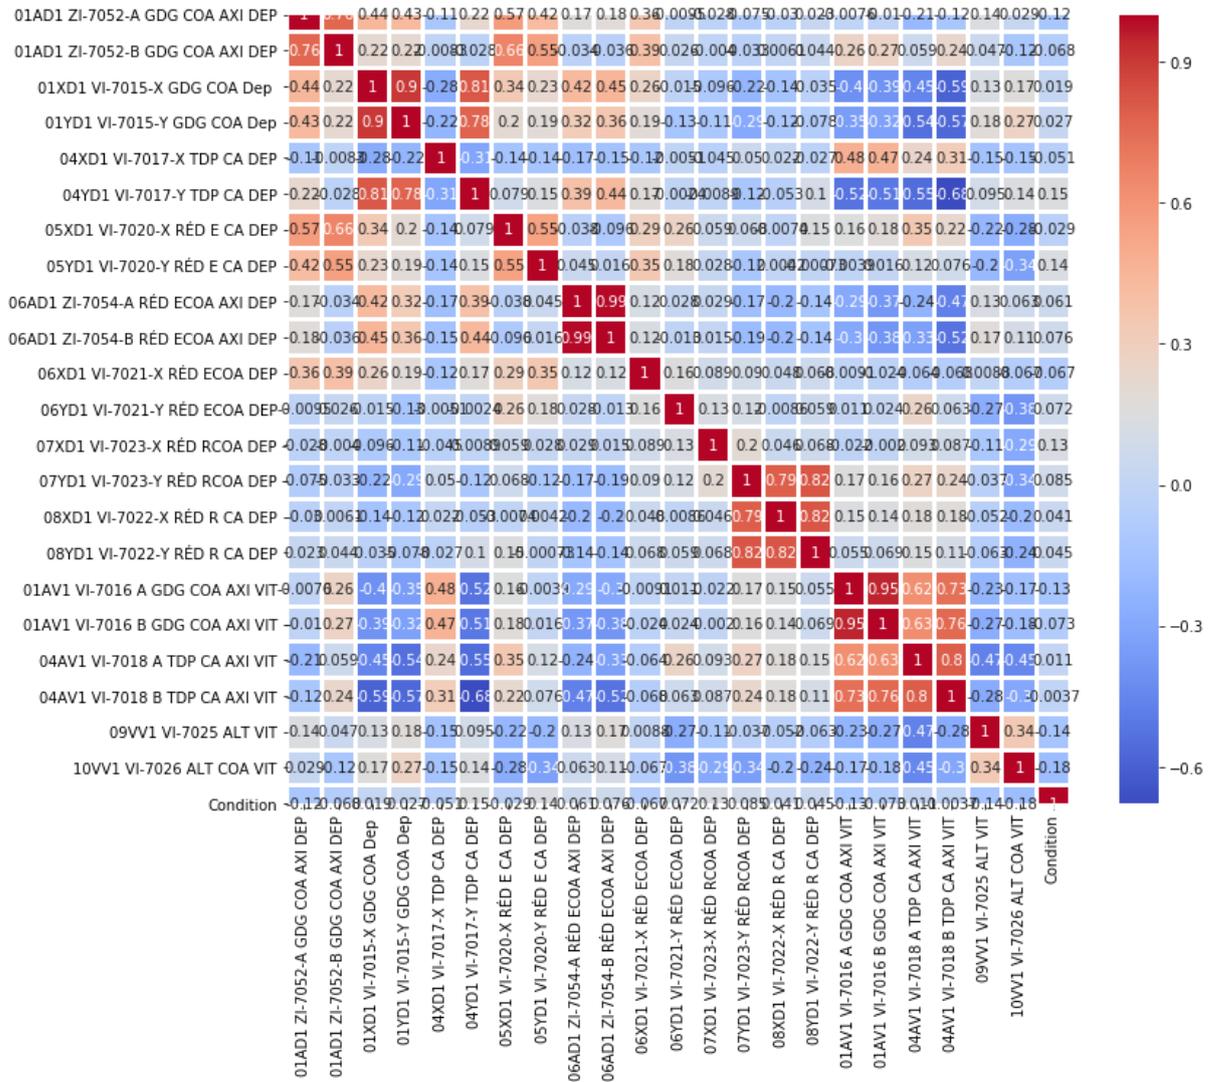
# ANNEXE I

## LES BIBLIOTHÈQUES PYTHON

```
import numpy as np
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
import plotly.express as px
import missingno as msno
%matplotlib inline
from sklearn.linear_model import LogisticRegression
from sklearn.ensemble import RandomForestClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.svm import SVC
from sklearn.ensemble import GradientBoostingClassifier
from sklearn.neural_network import MLPClassifier
from sklearn.ensemble import ExtraTreesClassifier
import xgboost as xgb
from sklearn.ensemble import BaggingClassifier
from sklearn.neighbors import KNeighborsClassifier
from sklearn import tree
from sklearn.metrics import confusion_matrix
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
import matplotlib.pyplot as plt
from sklearn.metrics import classification_report, confusion_matrix
```

# ANNEXE II

## HEATMAP



## BIBLIOGRAPHIE

- [1] « Manuel d'utilisation de la turbine à gaz MS 5001D ». Nouvo Pignone - Florence. Italie. 1999.
- [2] « Manuel de maintenance de la turbine à gaz MS 5001D ». Nuovo Pignone – Florence - 1999.
- [3] ML Guide Oil and Gas-Belyadi Haghghat.
- [4] Appen. (2021). What is Training Data? Repéré à <https://appen.com/blog/training-data/>
- [5] Data Science. (2019). What is Confusion Matrix and Advanced Classification Metrics? Repéré à <https://manisha-sirsat.blogspot.com/2019/04/confusion-matrix.html>
- [6] DataLogger Inc. (2016). Basic Techniques of Vibration Measurement and Diagnosis. Repéré à <https://www.dataloggerinc.com/resource-article/basic-techniques-of-vibrationmeasurement-and-diagnosis/>
- [7] Fan, C., Xiao, F., Yan, C., Liu, C., Li, Z., & Wang, J. (2019). A novel methodology to explain and evaluate data-driven building energy performance models based on interpretable machine learning. *Applied Energy*, 235, 1551 - 15601.
- [8] Deutsch, J., & He, D. (2018). Using Deep Learning-Based Approach to Predict Remaining Useful Life of Rotating Components. *EE Transactions on Systems, Man, and Cybernetics: Systems*.
- [9] Jie, B., Hou, L., & Yongguang, M. (2015). Machine fault diagnosis using industrial wireless sensor networks and support vector machine. *Proc. 12th IEEE Int. Conf. Electron. Meas. Instrum*, 1, 153-158.
- [10] Jin, C., Zhao, W., Liu, Z., Lee, J., & He, X. (2014). A vibration-based approach for diesel engine fault diagnosis. *Proc. Int. Conf. Prognostics Health Manage*, 1-9.
- [11] Alajmi A., Islam S., and Lee J. "A Review on Gas Turbine Health Monitoring and Remaining Useful Life Estimation." *Energies* 2021, 14, 5510. (DOI: 10.3390/en14195510)
- [12] Guo H., Chen Y., and Li G. "Fault Diagnosis of Gas Turbine Using Machine Learning Techniques: A Review." *Energies* 2020, 13, 1021. (DOI: 10.3390/en13041021)
- [13] Al-Timimy A., Ramachandran K.I., and Ahmed M.A. "Condition Monitoring and Fault Diagnosis of Gas Turbines: A Comprehensive Review." *Energies* 2015, 8, 4063-4104. (DOI: 10.3390/en8054063)
- [14] Tandon N., Choudhury A., and Pandey R.K. "A Review of Vibration
- [15] Kirasich, K., Smith, T., & Sadler, B. (2018). Random Forest vs Logistic Regression: Binary Classification for Heterogeneous Datasets. *SMU Data Science Review*, 1
- [16] ExxonMobil, Outlook for– Energy, 2018.
-

- [17] Yogendra. et al. (2020), Machine Learning in the Oil and Gas Industry, First edition.
- [18] Geİron, A. (2019). Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: concepts, tools, and techniques to build intelligent systems (2nd ed.) O'Reilly.
- [19] McKinney Wes. 2018. Python for data analysis (2st. ed.). O'Reilly Media, Inc.
- [20] Abdolhossein Hemmati-Sarapardeh, Aydin Larestani, Menad Nait Amar, Sassan Hajirezaie, Applications of Artificial Intelligence Techniques in the Petroleum Industry, Gulf Professional Publishing, 2020,
- [21] Barclay, John T., "Keep your uptime up: Condition Monitoring." Engineers Digest, March, 1991.
- [22] Barton, S.C., Carson, C.C., Gills, R.S., Ligon, W.V. Jr., Webb, J.L., Implementation of Pyrolysate Analysis of Materials Employing Tagging Compounds to Locate an Overheated Area in a Generator, IEEE PES Summer Meeting, Portland, Oregon, July 26-31, 1981.
- [23] Factory Mutual System, " Loss Prevention Data - Generator Protection." Doc 5-12 13-3, February, 1980.
- [24] Rosen, Jerome, "Prediction and Prevention." Technology Review, April, 1991.
- [25] Skala, George F, "The New Generator Condition Monitor and Its Application to the Protection of Turbine Generators," Proceedings of the First International Power Conference, Beijing, The People's Republic of China, 1986.
- [26] Westinghouse Electric Corporation, " On-Line Monitoring and Diagnostic Systems for Generators," NP-902 Research Project 970-1 Electric Power Research Institute.
- [27] Eriksen, Leif. The impact of Digital on unplanned Downtime. GE Digital, 25 Nov.2016.
- [28] Phillippi, Brian. "How predictive maintenance drives efficiency for modern plants." Flow Control Magazine, 5 Aug 2015. <https://www.flowcontrolnetwork.com/how-predictive-maintenance-drives-efficiency-for-modern-plants/>.
- [29] Sanghavi, Sundeep. " Why the Time is Right for Cognitive Predictive Maintenance in Oil, Gas." E&P Magazine, 4 Oct.2017. [www.epmag.com/blog/Why-Time-Right-Cognitive-Predictive-Maintenance-Oil-Gas-1661181](http://www.epmag.com/blog/Why-Time-Right-Cognitive-Predictive-Maintenance-Oil-Gas-1661181).
- [30] "The state of Data Engineering." Stitch Data, Mar.2016. <https://www.stitchdata.com/resources/reports/the-state-of-data-engineering/>.
- [31] Wuest et al., Détection des défauts Approche basée sur les données Techniques d'intelligence artificielle et apprentissage machine, 2016.
- [32] Canizo et al. Diagnostic et pronostic Approche hybride Digital Twin Techniques de contrôle statistique des processus et d'apprentissage automatique, 2017.
-

[33] Luo et al., 2020 Diagnostic et pronostic Approche basée sur les données Techniques de contrôle statistique des processus et d'apprentissage automatique.

[34] Hsu et al. Diagnostiquer les défaillances Approche basée sur les données SVM, KNN, DT, RF, 2020.

[35] Paudyal, Planification des horaires d'Approche basée sur les données Techniques de contrôle statistique des processus et d'apprentissage automatique, 2019.

[36] Canizo et al. Diagnostic des éoliennes Approche basée sur les données et RF, 2017

[37] Kusiak & Verma, approches basées sur les expériences, 2011.

[38] Wu et al. Prédiction de l'usure des outils Approche basée sur les données Signal vibratoire + signal acoustique + ANN, SVM et RF, 2017.

