

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'enseignement Supérieur et de la Recherche Scientifique

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 : NEZAR Mohamed Dhia Eddine

THEME

Prédiction et classification des défauts des aubes d'une turbine à gaz en se basant sur l'Intelligence Artificielle : l'apprentissage profond

Devant le jury :

	Nom et Prénom	Grade	Université/Affiliation
Président de jury	Pr. BENBRIK .A	Professeur	Université de Boumerdes/FHC
Examineur	Dr. SAHNOUNE. Kh	Maitre de conférence	Université de Boumerdes/FHC
Examineur	Dr. SABRI. Kh	Maitre de conférence	Université de Boumerdes/FHC
Encadreur	Dr. HARHOUT .R	Maitre de conférence	Université de Boumerdes/FHC

Dédicace

“

Dédié à ma famille,

Votre soutien indéfectible et votre compréhension ont été les fondements sur lesquels j'ai construit mes rêves et mes aspirations. Vous avez été ma source de force, d'encouragement et d'amour à travers chaque défi et chaque victoire.

À ma chère mère et mon cher père, votre guidance et vos sacrifices m'ont façonné en la personne que je suis aujourd'hui. Votre sagesse et votre foi inébranlable en moi ont été ma lumière guide.

À mes sœurs et à mon frère, vos rires, votre compagnie et votre amour inconditionnel ont apporté une immense joie et chaleur à ma vie. Votre présence a rendu chaque voyage plus significatif et chaque étape plus mémorable.

”

Cette thèse est le reflet de nous

REMERCIEMENTS

Avant tout, louange et remerciements à ALLAH le sacré et le puissant pour m'avoir donné la capacité et m'avoir aidé à accomplir cette thèse.

Ensuite, je tiens à exprimer ma sincère gratitude à mon superviseur M. HARHOUT Riad pour son soutien continu, son aide, son guidage, sa motivation et sa patience tout au long de cette thèse.

Aux membres du jury, j'exprime ma sincère gratitude pour l'honneur qu'ils me font en prenant le temps de lire et d'évaluer ce travail.

Je tiens également à remercier l'équipe académique et administrative de FHC pour leurs efforts dans la fourniture d'une excellente formation. Enfin, je tiens à remercier tous ceux qui ont contribué, directement ou indirectement, à l'achèvement de ce travail.

Et enfin, je suis reconnaissant envers tous les professeurs du Département Transport et Équipements des Hydrocarbures.

RÉSUMÉ

Les défauts des aubes de turbine à gaz peuvent avoir un impact significatif sur l'efficacité et la sécurité des turbines à gaz. Les méthodes traditionnelles de détection et de classification de ces défauts reposent sur une inspection visuelle à l'aide de moyens classiques, qui peut être longue, coûteuse et sujette aux erreurs humaines. Dans ce mémoire, nous proposons une approche basée sur l'intelligence artificielle : l'apprentissage profond pour la reconnaissance et la classification des défauts des aubes de turbine à gaz.

L'objectif de cette étude est de construire un modèle d'apprentissage profond à l'aide de données expérimental pour prédire les défauts réels des aubes de turbine à gaz. Nous avons créé un ensemble de données d'images synthétiques en utilisant Blender, un logiciel 3D, pour simuler différents types de défauts rencontrés dans des scénarios réels, et pour cela nous avons mis en œuvre un modèle d'apprentissage profond basé sur l'architecture VGG16 pour classifier les défauts. La méthode proposée a aussi le potentiel d'être mise en œuvre dans l'Inspection par Boroscope c.à.d. s'intégration dans l'instrument Boroscope, ce qui peut améliorer l'interprétation, la précision et l'efficacité de l'inspection des aubes de turbine à gaz.

Nos résultats montrent que le modèle d'apprentissage profond formé sur des données synthétiques peut prédire avec précision les défauts avec des images réelles dans les aubes de la turbine, atteignant une haute précision de classification. Cette approche présente plusieurs avantages par rapport aux méthodes traditionnelles, notamment une réduction des coûts et du temps, une précision accrue, et la capacité à détecter des défauts qui peuvent ne pas être visibles à l'œil nu.

Mots-clés : Défauts des aubes de Turbine à Gaz, Apprentissage Profond, Données Synthétiques, VGG16, Blender, Prédiction, Classification, Inspection par Boroscope.

Abstract

The defects in gas turbine blades can have a significant impact on the efficiency and safety of gas turbine engines. Traditional methods for detecting and classifying these defects rely on visual inspection using conventional means, which can be time-consuming, costly, and prone to human error. In this thesis, we propose an artificial intelligence-based approach: deep learning for the recognition and classification of defects in gas turbine blades.

The objective of this study is to construct a deep learning model using experimental data to predict real defects in gas turbine blades. We created a dataset of synthetic images using Blender, a 3D software, to simulate different types of defects encountered in real scenarios, and for this purpose, we implemented a deep learning model based on the VGG16 architecture to classify the defects. The proposed method also has the potential to be implemented in Borescope Inspection, i.e., integrated into the Borescope instrument, which can improve the interpretation, accuracy, and efficiency of gas turbine blade inspections.

Our results show that the deep learning model trained on synthetic data can accurately predict defects with real images in turbine blades, achieving high classification accuracy. This approach presents several advantages over traditional methods, including reduced costs and time, increased accuracy, and the ability to detect defects that may not be visible to the human eye.

Keywords: Gas Turbine Blade Defects, Deep Learning, Synthetic Data, VGG16, Blender, Prediction, Classification, Borescope Inspection.

ملخص

يمكن أن يكون للعيوب في شفرات التوربينات الغازية تأثير كبير على كفاءة وسلامة محركات التوربينات الغازية. تعتمد الطرق التقليدية للكشف عن هذه العيوب وتصنيفها على الفحص البصري باستخدام الوسائل التقليدية، والتي يمكن أن تكون مستهلكة للوقت، ومكلفة، وعرضة للأخطاء البشرية. في هذه الأطروحة، نقترح نهجًا قائمًا على الذكاء الاصطناعي: التعلم العميق للتعرف على عيوب شفرات التوربينات الغازية وتصنيفها.

هدف هذه الدراسة هو بناء نموذج للتعلم العميق باستخدام البيانات التجريبية للتعرف بالعيوب الفعلية في شفرات التوربينات الغازية. لقد أنشأنا مجموعة بيانات من الصور الاصطناعية باستخدام برنامج Blender ، وهو برنامج ثلاثي الأبعاد، لمحاكاة أنواع مختلفة من العيوب التي تواجهها في السيناريوهات الحقيقية، ولهذا الغرض قمنا بتنفيذ نموذج التعلم العميق استنادًا إلى بنية VGG16 لتصنيف العيوب. كما أن للطريقة المقترحة القدرة على التنفيذ في فحص المناظير، أي دمجها في أداة المنظار، مما يمكن أن يحسن من التفسير والدقة وكفاءة فحص شفرات التوربينات الغازية.

تُظهر نتائجنا أن نموذج التعلم العميق الذي تم تدريبه على البيانات الاصطناعية يمكن أن يتنبأ بدقة بالعيوب باستخدام الصور الفعلية في شفرات التوربينات، محققًا دقة تصنيف عالية. يقدم هذا النهج عدة مزايا مقارنة بالطرق التقليدية، بما في ذلك تقليل التكاليف والوقت، وزيادة الدقة، والقدرة على الكشف عن العيوب التي قد لا تكون مرئية للعين المجردة.

الكلمات الرئيسية: عيوب شفرات توربينات الغاز، التعلم العميق، بيانات اصطناعية، التصنيف، التفتيش بالمنظار الداخلي، الذكاء الاصطناعي.

TABLES DE MATIERE

DEDICACE

REMERCIEMENT

RESUME

TABES DES MATIERES

LISTES DES FIGURES

LISTES DES TABLEAUX

ACRONYMES

INTRODUCTION GENERALE 1

I. PRESENTATION ET HISTORIQUE DU CHAMP 3

I.1. Introduction 3

I.2. Presentation and historical of the field champ 3

I.2.1. Présentation..... 3

I.3. Situation Géographique 4

I.4. Historique de Production 6

I.5. HSE (Health, Safety, and Environment Plan) 6

I.5.1. Identification des dangers et évaluation des risques : 6

I.5.2. Formation et Sensibilisation 6

I.5.3. Préparation et Intervention en cas d'urgence 7

I.5.4. Protection de l'Environnement..... 7

I.5.5. Gestion des Sous-Traitants 7

I.5.6. Engagement Communautaire..... 7

I.5.7. Amélioration Continue..... 7

I.6. Conclusion 8

II. LES AUBES DE TURBINE À GAZ : PRINCIPES ESSENTIELS ET

APERÇU DE LA MAINTENANCE 9

II.1. Introduction 9

II.2. Rôle des aubes de turbine à gaz dans la compression et la génération de poussée 9

II.3. Évolution historique de la conception des aubes de turbine à gaz 10

II.3.1. Développements initiaux 10

II.3.2. Innovations 10

II.3.3. Avancements	11
II.3.4. Techniques modernes	11
II.4. Classifications des aubes de turbine à gaz	11
II.4.1. Basé sur la fonction	11
II.4.2. Basé sur le matériau.....	11
II.4.3. Basé sur la méthode de refroidissement	11
II.4.4. Basé sur l'emplacement	12
II.4.5. Basé sur le profil d'aube	12
II.4.6. Basé sur le processus de fabrication	12
II.4.7. Basé sur le revêtement.....	12
II.5. Sélection des matériaux et propriétés pour les aubes de turbine à gaz	13
II.5.1. Superalliages à base de nickel	13
II.5.2. Composites à matrice céramique (CMCs).....	13
II.5.3. Alliages monocristalline	13
II.5.4. Alliages solidifiés dans une direction.....	13
II.6. Revêtement.....	13
II.6.1. Revêtements barrière thermique (TBC)	13
II.6.2. Revêtements de barrière environnementale (EBCs).....	14
II.7. Tests et caractérisation des matériaux.....	15
II.8. Tendances futures.....	15
II.9. Importance des aubes de turbine à gaz.....	15
II.9.1. Température de surface des aubes	17
II.10. Facteurs conduisant aux dommages des aubes de turbine à gaz	18
II.10.1. Corrosion	18
II.10.2. Fissures	18
II.10.3. Rayures	18
II.10.4. Fractures	18
II.11. Aperçu des protocoles d'inspection et de maintenance	19
II.11.1. Maintenance préventive.....	19
II.11.2. Maintenance déficiente (planifiée)	19
II.11.3. Maintenance corrective.....	20
II.11.4. Inspection de la section de combustion	20
II.11.5. Enregistrement et analyse réguliers des données	20
II.11.6. Gestion des pièces de rechange	20
II.11.7. Procédures d'inspection spéciales.....	20
II.11.8. Actions de réparation.....	20

II.12. Introduction aux méthodes de contrôle non destructif (CND).....	21
II.13. Test visuel pour les aubes de turbine à gaz	21
II.14. Inspection par Boroscope	22
II.15. Contexte d'inspection pour la turbine à gaz Taurus 60	23
II.15.1. Méthodologie d'inspection.....	24
II.15.2. Préparation de l'opération	24
II.15.3. Inspection approfondie	24
II.15.4. Plan d'inspection	25
II.15.5. Analyse des résultats	25
II.16. Technologies des aubes intelligentes et adaptatives	25
II.16.1. Technologies des aubes intelligentes.....	26
II.16.2. Technologies des aubes adaptatives	26
II.16.3. Avantages et applications	26
II.16.4. Défis et orientations futures.....	27
II.16.5. Conclusion	27
III. GÉNÉRATION DES DONNÉES SYNTHÉTIQUES ET	
APPRENTISSAGE PROFOND	28
III.1. Introduction.....	28
III.2. Introduction sur la génération de données synthétiques avec Blender	29
III.3. Importance des données synthétiques dans l'analyse des aubes de turbine à gaz.....	29
III.3.1. Disponibilité limitée des données réelles	29
III.3.2. Préoccupations concernant la confidentialité.....	29
III.3.3. Détection et segmentation des défauts	29
III.3.4. Efficacité en termes de coûts et de temps	30
III.4. Création de modèle 3D des aubes de turbine à gaz dans Blender	30
III.4.1. Méthodologie	30
III.5. Procédé de génération d'images synthétiques des aubes de turbine à gaz (défectueuses) avec Blender	31
III.5.1. Méthodologie	31
III.6. Résultats de modélisation	32
III.7. Contexte sur l'apprentissage profond	33
III.7.1. Introduction	33
III.7.2. Qu'est-ce qu'une image ?.....	33
III.7.3. Traitement d'images	33
III.7.4. Vision par ordinateur.....	34

III.7.5. Applications de la vision par ordinateur	35
III.7.5.1. Détection d'objets	35
III.7.5.2. Segmentation sémantique.....	35
III.7.5.3. Classification d'images.....	36
III.7.6. Réseau de neurones	36
III.7.7. Architecture du réseau de neurones	37
III.7.7.1. Réseau de neurones simple	37
III.7.7.2. Architecture des réseaux de neurones profonds.....	38
III.8. Apprentissage profond.....	39
III.9. Réseau de neurones convolutionnels (CNN)	40
III.10. Architecture du réseau neuronal convolutif.....	41
III.10.1. Couche de convolution.....	41
III.10.2. Couche de Pooling	43
III.10.3. Rectified Linear Units layer (ReLU).....	44
III.10.4. La couche entièrement connectée (FC Layer).....	44
III.11. Modèles d'apprentissage profond pour l'analyse des aubes de turbine à gaz.....	45
III.11.1. Introduction	45
III.11.2. Méthode proposée	46
III.11.2.1. Entraînement	46
III.11.2.2. Entraînement avec augmentation des données.....	46
III.11.2.3. Modèle VGG16.....	47
III.11.2.4. Apprentissage par transfert	48
III.12. Conclusion	48
IV. RESULTATS ET INTERPRETATION.....	49
IV.1. Introduction	49
IV.2. Protocole de modélisation	49
IV.2.1. Présentation des données	49
IV.2.2. Métriques de performance	50
IV.3. Résultats.....	51
IV.3.1. Premier cas : Modèle utilisé (CNN) avec architecture simple.....	51
IV.3.2. Deuxième cas : Utilisation du modèle CNN simple et de l'augmentation des données	52
IV.3.3. Troisième cas : Utilisation du modèle VGG16 sans l'augmentation des données	55
IV.3.3.1. Précision	56
IV.3.3.2. Temps d'entraînement.....	57

IV.3.3.3.	Comportement de convergence	57
IV.3.3.4.	Remarque	57
IV.3.4.	Test du modèle	58
IV.3.4.1.	Méthodologie	58
IV.3.4.2.	Résultats de données réelles.....	59
IV.3.4.3.	Précision.....	59
IV.3.4.4.	Matrice de confusion (Confusion Matrix).....	60
IV.3.4.5.	Points Clés.....	61
IV.3.4.6.	Précision et Rappel.....	62
IV.3.4.7.	F1 Score.....	63
IV.4.	Conclusion	64
CONCLUSION GENERALE		64
ANNEXE I.....		65
BIBLIOGRAPHIE		66

LISTES DES FIGURES

Figure I-1: Localisation Géographique du Champ de Hassi Tidjerane	5
Figure I-2: plan de construction.....	5
Figure I-3: Le cheminement du gaz à Hassi Tidjerane.....	6
Figure I-4: Le schéma organisationnel du « chantier de construction ».....	8
Figure II-1: Différents types des aubes.....	12
Figure II-2:TBC et les couches associées.....	14
Figure II-3: EBC et couches associées	14
Figure II-4: Une représentation schématique d'aube de turbine à gaz typique.....	15
Figure II-5: Les développements en matière de refroidissement des turbines qui ont eu lieu au cours des dernières décennies.....	16
Figure II-6:Profil de température d'aube.....	17
Figure II-7: Tous les défauts sur les aubes de turbine à gaz qui peuvent être détectés lors d'une inspection visuelle seulement, « Taurus 60 turbine à gaz »	19
Figure II-8: (a) Les aubes de turbine présentant différents niveaux d'usure et de dommages. (b) Vue de la caméra d'une pose de mesure exemplaire	22
Figure II-9: Image représentant un boroscope.....	23
Figure II-10: Vue interne du composant de la turbine.....	23
Figure II-11: Configuration de l'espace de travail pour la préparation de l'inspection par Boroscope.	24
Figure II-12: Vue interne du composant de la turbine à travers le boroscope.....	25
Figure II-13: Inspection interne des aubes de turbine à gaz Taurus 60 via une caméra de boroscope.....	25
Figure III-1:Organigramme d'obtention de dataset.....	28
Figure III-2: Visualisation d'aube de turbine à gaz non défectueuses réalisée par Blender.	30
Figure III-3: Modèles générés avec Blender montrant différentes conditions d'éclairage pour mettre en évidence les défauts	32
Figure III-4: La détection des contours	34
Figure III-5: Un exemple de détection d'objet.....	35
Figure III-6: Un exemple de segmentation.....	35
Figure III-7: Un réseau de neurones simple	38
Figure III-8: Un réseau de neurones profond	39
Figure III-9: Apprentissage automatique vs Apprentissage profond	39
Figure III-10: Relation entre l'IA, le ML et le DL.....	40
Figure III-11: L'opération de convolution	41
Figure III-12: Opération de convolution à plus grande échelle.....	42
Figure III-13: Un exemple de carte des caractéristiques	43
Figure III-14: Opération de max pooling	43
Figure III-15: ReLU fonction d'activation	44
Figure III-16: Couche entièrement connecté	45
Figure III-17: CNN architecture	45
Figure III-18: Échantillons d'augmentation de données	46
Figure III-19 : VGG16 architecture.....	47
Figure III-20: Le processus VGG16.....	47
Figure IV-1: Aubes avec des fissures	49
Figure IV-2: Aubes avec des rayures	49
Figure IV-3: Aubes avec corrosion	50

Figure IV-4: Aubes avec fractures.....	50
Figure IV-5 : Organigramme étape d'application de l'apprentissage profond.....	51
Figure IV-6: Performance du modèle CNN simple.....	52
Figure IV-7: Performance du modèle CNN simple avec augmentation des données	53
Figure IV-8: Un échantillon des résultats de visualisation de la deuxième expérience	54
Figure IV-9: Performances du modèle VGG16 pré-entraîné sur 850 époques	55
Figure IV-10: Performances du modèle VGG16 pré-entraîné sur les 50 dernières époques	56
Figure IV-11: Image provenant du notebook Jupyter montrant les résultats de performance par le modèle VGG16.....	57
Figure IV-12: Explication visuelle du surajustement pour les cas de classification	57
Figure IV-13: Explication visuelle des différents cas du taux d'apprentissage	58
Figure IV-14: Échantillons d'images non vues par le modèle	59
Figure IV-15: La précision du modèle pour la prédiction de 15 images sur lesquelles il n'a pas été entraîné.	60
Figure IV-16: Matrice de confusion visualisant la distribution des classes prédites par rapport aux classes réelles.....	60
Figure IV-17: Distribution du score F1 pour chaque classe	64

LISTES DES TABLEAUX

Table IV-1: Résultats du modèle simple	52
Table IV-2: Résultats du modèle CNN simple avec augmentation des données	53
Table IV-3: Résultats du modèle VGG16 pré-entraîné	55
Table IV-4: Tableau représentant la précision et le rappel par classe	62

ACRONYMES

NDT: Non-Destructive Testing

ITT: Infrared Thermography Testing

UT: Ultrasonic Testing

MPT: Magnetic Particle Testing

DL: Deep Learning

SHM: Structural Health Monitoring

EPC: Engineering, Procurement, and Construction

LTHE: Larsen & Toubro Hydrocarbon Engineering Limited

CPF: Central Processing Facility

HSE: Health, Safety, and Environment

FPI: Fluorescent Penetrant Inspection

ECI: Eddy Current Inspection

F-CNN: Fully Convolutional Neural Network

CNN: Convolutional Neural Network

R-CNN: Region Convolutional Neural Network

SSD: Single Shot MultiBox Detector

Mask R-CNN: A Fully Convolutional Network for Object Detection and Instance Segmentation

ReLU: Rectified Linear Unit

VGG: Visual Geometry Group

ResNet : Residual Network

INTRODUCTION GENERALE

La sécurité des opérations des turbines à gaz revêt une importance primordiale, influençant divers secteurs tels que la production industrielle, la génération d'énergie et l'efficacité des transports. Garantir la fiabilité et la longévité des turbines à gaz nécessite des protocoles complets d'inspection et de maintenance. Les chercheurs se sont penchés sur des domaines tels que la surveillance de l'état structurel et la détection de défauts spécifiques aux aubes des turbines à gaz.

Au sein des turbines à gaz, les aubes jouent un rôle critique dans la compression de l'air et la génération de poussée. Cependant, les conditions de fonctionnement difficiles soumettent ces aubes à diverses formes de dommages, notamment des fissures, des déformations et des fractures. Ces dommages sont souvent exacerbés par des facteurs tels que les forces centrifuges dues à la rotation à grande vitesse, les forces aérodynamiques du flux de gaz et l'impact d'objets étrangers.

Diverses méthodes de test non destructif (NDT) ont été explorées pour l'inspection des aubes de turbine à gaz, notamment des technologies telles que les tests par thermographie infrarouge (ITT), les tests ultrasonores (UT) et les tests par particules magnétiques (MPT). Bien que chaque méthode offre des avantages uniques, des défis tels que la détection de défauts aux bords et les limitations matérielles persistent. Des efforts ont été déployés pour améliorer la précision et l'efficacité de la détection grâce à des approches innovantes telles que la thermographie pour la détection des défauts aux bords. De plus, l'inspection par Boroscope émerge comme une méthode de NDT pratique in situ permettant une évaluation visuelle des conditions des aubes sans nécessiter de retrait ou de traitement approfondi.

Les chercheurs ont également exploré des techniques avancées telles que l'apprentissage profond (DL) pour la détection et la classification des dommages aux aubes de turbine à gaz, exploitant sa capacité à extraire des caractéristiques et à reconnaître des objets. De telles méthodes promettent des améliorations significatives dans l'identification et l'atténuation des dommages aux aubes, contribuant à la sécurité et à la fiabilité globales des opérations de turbines à gaz. Les données synthétiques utilisées dans cette étude ont été générées dans Blender, exploitant ses capacités avancées de rendu un objet en 3D en image 2D. Grâce à des techniques précises de texturation, de rendu et de sculpture, divers défauts des aubes de turbine à gaz, tels que des fissures, de la corrosion et des déformations, ont été simulés avec précision. Cette approche de simulation a facilité la création d'un ensemble de données important et réaliste qui sera utilisé ensuite pour l'entraînement de modèles d'apprentissage profond visant à la classification des défauts des aubes de turbine à gaz.

Les contributions de cette étude peuvent être résumées comme suit :

- Modélisation et simulation de divers défauts des aubes de turbine à gaz en utilisant Blender pour générer des données synthétiques.
- Évaluation du réseau profond VGG16 pour la classification des défauts des aubes de turbine à gaz.
- Analyse de l'impact de l'augmentation des données sur les performances de modèle de CNN avec architecture simple.
- Test de modèle sur des images réelles des aubes défectueuses de turbine à gaz pour une évaluation de son application pratique.

CHAPITRE I :
PRESENTATION ET
HISTORIQUE DU CHAMP

I.PRESENTATION ET HISTORIQUE DU CHAMP

I.1.Introduction

Souvent considéré comme le combustible fossile le plus propre, le gaz naturel est un élément vital du paysage énergétique mondial. Principalement composé de méthane, le gaz naturel se forme en profondeur dans la croûte terrestre par la décomposition de matière organique sur des millions d'années. Sa disponibilité, sa polyvalence et ses émissions de carbone relativement faibles par rapport à d'autres combustibles fossiles en font un choix privilégié pour répondre aux divers besoins énergétiques à travers le monde.

Cependant, avant que le gaz naturel puisse être utilisé à des fins résidentielles, commerciales ou industrielles, il doit subir une série d'étapes de traitement pour garantir sa pureté, sa sécurité et ses performances optimales. C'est là que les installations de traitement du gaz naturel jouent un rôle crucial.

Les installations de traitement du gaz naturel sont des systèmes complexes conçus pour extraire, purifier et séparer les différents composants présents dans le gaz naturel brut. Ces installations sont généralement situées à proximité des sites de production de gaz, que ce soit sur terre ou en mer, et sont composées de plusieurs unités et processus interconnectés.

Le site de Hassi Tidjerane à Timimoun est un exemple parfait illustrant le traitement et la production de gaz naturel. Situé à Hassi Tidjerane, le site "Timimoun" est une installation de compression importante pour l'Algérie.

I.2.Presentation and historical of the field champ

I.2.1.Présentation

The Le Groupe Sonatrach et la société indienne Larsen & Toubro Hydrocarbon Engineering Limited India (LTHE) ont signé un contrat lundi à Alger pour le développement des champs de gaz du sud-ouest de l'Algérie. Ce contrat d'Ingénierie, Approvisionnement et Construction (EPC) pour le développement des champs de gaz de Hassi Ba Hamou et Reg Mouaded, Hassi Tidjerane et Hassi Tidjerane ouest, Tinerkouk et Tinerkouk ouest a été signé par le Directeur Central de l'Ingénierie et de la Gestion de Projets (EPM) de Sonatrach, Faiz Zane, pour la partie algérienne, et le PDG de LTHE, Subramanian Sarma, pour la partie indienne, en présence du PDG du Groupe Sonatrach, Abdelmoumen Ould Kaddour. Ce projet de développement des champs de gaz dans le sud-ouest consiste en la construction de trois (3) nouvelles installations de traitement et de compression de gaz pour assurer une production quotidienne d'environ 11 millions de mètres cubes par jour (m3/jour) de gaz de vente, a expliqué M. Zane. Parlant de l'étendue des services et des fournitures du contrat EPC, M. Messaoud a expliqué qu'il comprend des études d'ingénierie détaillées, l'approvisionnement et la livraison

d'équipements, la construction et l'assemblage sur site. La production de ces futures installations sera injectée dans le futur pipeline GR7 du réseau TRC, a-t-il ajouté. Le périmètre inclura également les tests et la mise en service, la formation du personnel du propriétaire, et l'assistance à l'exploitation.

Selon le chef de projet, les installations à construire pour les unités de traitement sont des modules d'une capacité de deux (2) millions de m³/jour chacun. Le nombre de modules est de 3, 2 et 1 respectivement pour les CPF de Hassi Ba Hamou, Hassi Tidjerane et Tinerkouk. Ces installations comprennent, entre autres, une unité de réception de gaz brut, une unité de séparation d'entrée, et une unité de compression de gaz d'entrée. Elles incluent également une unité de dimérisation du gaz et une unité de déshydratation du gaz et de régénération du glycol. Ces champs sont situés dans le sud-ouest de l'Algérie, dans les trois provinces, à savoir Adrar, Ghardaïa et El Bayadh. Les futures installations de traitement et de compression de gaz seront situées dans la province d'Adrar en raison de la concentration des réserves trouvées là-bas. Ce projet s'inscrit dans la stratégie du groupe (SH 2030) visant à atteindre le top 5 des plus grandes compagnies pétrolières mondiales, a-t-il ajouté.

➤ SONATRACH

SO : SOCIETE / NA : NATIONALE / TRA : TRANSPORT

C : COMMERCIALISATION / H : HYDROCARBURES

SONATRACH est la société algérienne chargée de l'exploration, de l'exploitation, du transport par pipeline, du traitement et de la commercialisation des hydrocarbures et de leurs dérivés. Elle opère également dans d'autres secteurs tels que la production d'électricité, les énergies nouvelles et renouvelables, et la désalinisation de l'eau de mer. La société mène ses activités en Algérie et partout où des opportunités se présentent dans le monde.

La société nationale des hydrocarbures SONATRACH a été créée en 1963. Aujourd'hui, elle emploie plus de 35 000 personnes et joue un rôle important dans l'économie nationale. Cela lui a permis de se classer au 11e rang parmi les principales compagnies pétrolières internationales.

I.3.Situation Géographique

La localisation des champs de Hassi Tidjerane (HTJ & HTJW) : Le champ de Hassi Tidjerane couvre une superficie de 611,17 km² et est situé dans la partie nord du bassin de Gourara dans le désert du Sahara algérien. Il occupe les approches occidentales du plateau de M'Zab, les marges occidentales et méridionales du plateau sud de Tademaït, et les approches orientales de la rivière Saoura. Hassi Tidjerane se trouve à environ 300 km au sud-ouest du champ de Hassi R'Mel et à environ 160 km au nord-ouest du champ de Krechba. Il s'étend sur deux provinces : Adrar et El Bayadh. Figure I.1

CHAPITRE I : PRESENTATION ET HISTORIQUE DU CHAMP

Les coordonnées géographiques de Hassi Tidjerane sont les suivantes :

- Latitude : 30,866667° N (30° 52' 00" N) ou 30,8667° N en degrés décimaux
- Longitude : 0,5° E (0° 30' 0" E) ou 0,5° E en degrés décimaux
- Système de référence de grille militaire (MGRS) : 31RBQ6096717502
- Référence graphique des opérations conjointes : NH31-05
- Coordonnées UTM : BQ61 (non complètes, seules les deux premières lettres sont fournies)
- Altitude : environ 574 mètres au-dessus du niveau de la mer




Figure I-1: Localisation Géographique du Champ de Hassi Tidjerane




Figure I-2: plan de construction

I.4. Historique de Production

Le potentiel maximum actuel du champ est de 11 millions de mètres cubes par jour de gaz avec condensat.

Puits Producteurs : Actuellement, le champ de Hassi Tidjerane ne contient que 11 puits en production. La profondeur moyenne des puits est de 3000 mètres, permettant l'exploitation d'un réservoir composite. Le gaz brut produit est transporté des puits jusqu'au collecteur, pour atteindre l'Installation de Traitement Centrale (CPF) où les produits gazeux et liquides sont séparés et livrés aux lignes d'exportation. Un produit pré-raffiné peut ainsi être transporté jusqu'au point de livraison final dans la partie nord du pays.




Figure I-3: Le cheminement du gaz à Hassi Tidjerane

I.5. HSE (Health, Safety, and Environment Plan)

I.5.1. Identification des dangers et évaluation des risques :

Effectuer une identification approfondie des dangers et une évaluation des risques pour tous les aspects du projet, y compris les phases de construction, d'exploitation et de maintenance.

Mettre en œuvre des mesures pour atténuer les risques identifiés afin d'assurer la sécurité du personnel et la protection de l'environnement.

I.5.2. Formation et Sensibilisation

Fournir une formation complète à tout le personnel impliqué dans le projet, y compris les entrepreneurs et les sous-traitants, sur les protocoles et les procédures de santé, de sécurité et d'environnement pertinents.

Sensibiliser le personnel aux dangers potentiels et à l'importance du respect des réglementations en matière de sécurité.

I.5.3.Préparation et Intervention en cas d'urgence

Élaborer et mettre en œuvre des plans d'intervention d'urgence adaptés aux risques spécifiques associés au projet, y compris des procédures pour répondre à des incidents tels que les incendies, les fuites de gaz et les urgences médicales.

Organiser régulièrement des exercices et des simulations pour tester l'efficacité des protocoles d'intervention d'urgence et garantir que le personnel est prêt à réagir efficacement en cas d'urgence.

I.5.4.Protection de l'Environnement

Mettre en œuvre des mesures pour minimiser l'impact environnemental tout au long du cycle de vie du projet, y compris pendant les phases de construction, d'exploitation et de déclassement.

Respecter toutes les réglementations et normes environnementales applicables, notamment celles liées à la qualité de l'air et de l'eau, à la gestion des déchets et à la conservation de la biodiversité.

I.5.5.Gestion des Sous-Traitants

Veiller à ce que tous les entrepreneurs et sous-traitants travaillant sur le projet respectent les politiques et procédures établies en matière de santé, de sécurité et d'environnement.

Effectuer des inspections et des audits réguliers pour vérifier la conformité aux réglementations de sécurité et traiter rapidement tout problème de non-conformité.

I.5.6.Engagement Communautaire

Engager les communautés locales pour leur fournir des informations sur le projet et répondre à toute préoccupation ou plainte qu'elles pourraient avoir.

Mettre en œuvre des mesures pour minimiser les perturbations pour les communautés locales et veiller à ce que le projet bénéficie économiquement et socialement à la région environnante.

I.5.7.Amélioration Continue

Établir des mécanismes de suivi et d'évaluation de la performance SSE tout au long du cycle de vie du projet.

Revoir et mettre à jour régulièrement les politiques et procédures SSE en fonction des enseignements tirés et des retours des parties prenantes pour améliorer continuellement la sécurité et la performance environnementale.

I.6.Conclusion

Le champ de gaz de Hassi Tidjerane, fruit de l'ingéniosité humaine et de l'ingénierie, constitue une contribution significative au secteur énergétique de l'Algérie. Sous la direction de Sonatrach, l'usine de traitement de gaz du projet a débuté ses opérations en 2023, renforçant la capacité de production de gaz de l'Algérie.




Figure I-4: Le schéma organisationnel du « chantier de construction »

**CHAPITRE II : LES AUBES
DE TURBINE À GAZ :
PRINCIPES ESSENTIELS
ET APERÇU DE LA
MAINTENANCE**

II. LES AUBES DE TURBINE À GAZ : PRINCIPES ESSENTIELS ET APERÇU DE LA MAINTENANCE

II.1. Introduction

Dans le contexte de la génération d'énergie et de la propulsion, les turbines à gaz occupent une position significative en tant que systèmes d'ingénierie avancés qui convertissent efficacement le carburant en énergie mécanique. Les aubes au sein de ces turbines sont un composant crucial, responsables du processus de conversion dans des conditions de fonctionnement extrêmes. Pour assurer des performances optimales et une longévité des turbines à gaz, il est essentiel de comprendre les aspects fondamentaux de leurs aubes et de mettre en œuvre des pratiques de maintenance efficaces.

Ce chapitre offre une exploration approfondie des aubes de turbine à gaz, en se concentrant sur leur conception de base, leurs matériaux et leurs principes opérationnels. En plongeant dans ces aspects, nous visons à fournir une compréhension globale des exigences de maintenance pour les aubes de turbine à gaz. De plus, nous mettons l'accent sur l'importance des stratégies de maintenance proactive dans la prévention de la dégradation des aubes et l'amélioration des performances globales de la turbine.

Tout au long de ce chapitre, nous abordons des concepts clés, de la composition structurelle des aubes de turbine à gaz aux subtilités des différentes techniques de maintenance. En fournissant un aperçu des pratiques de maintenance essentielles, nous visons à équiper les ingénieurs, les techniciens et les passionnés des connaissances nécessaires pour maintenir la fiabilité et l'efficacité des systèmes de turbines à gaz. Cela comprend la compréhension de l'inspection des dommages, l'optimisation des mécanismes de refroidissement et la mise en œuvre de technologies d'inspection avancées.

II.2. Rôle des aubes de turbine à gaz dans la compression et la génération de poussée

Les turbines à gaz sont des composants essentiels dans diverses industries, notamment la génération d'énergie, les transports et les processus industriels. Elles sont renommées pour leurs rapports puissance-poids exceptionnels, ce qui en fait le système de propulsion privilégié pour les avions et efficaces dans la production d'électricité et les applications industrielles. Les principaux composants d'une turbine à gaz comprennent un compresseur d'air, une chambre de combustion et une turbine, tous montés sur un arbre commun.

Le compresseur d'air aspire et comprime l'air, élevant sa pression. Les compresseurs de conception axiale avec plusieurs étages sont préférés pour les turbines à gaz avancées et de grande taille. L'air comprimé se mélange ensuite au carburant dans la chambre de combustion, subissant une combustion pour produire des gaz à haute température. Ces gaz sont dirigés dans la

turbine à gaz, où leur énergie cinétique est convertie en puissance de l'arbre. L'arbre de la turbine est connecté à un générateur, convertissant l'énergie mécanique en électricité.

Les turbines à gaz fonctionnent sur la base des principes thermodynamiques du cycle de Brayton, qui se compose de deux transferts de travail adiabatiques et de deux processus de transfert de chaleur à pression constante. L'énergie chimique du gaz combustible est convertie en énergie mécanique de rotation de l'arbre de la turbine.

Le fonctionnement fondamental de la turbine à gaz peut être comparé à celui d'un moteur-fusée. Lorsque le carburant brûle dans une fusée, un gaz d'échappement haute pression est généré, ce qui convertit l'énergie chimique du carburant en énergie mécanique. Dans une turbine à gaz, l'énergie mécanique libérée est efficacement transformée en mouvement de rotation de l'arbre de la turbine.

Les avantages des turbines à gaz comprennent leurs rapports puissance-poids élevés, leur efficacité et leur fiabilité. Elles sont également respectueuses de l'environnement, avec des émissions plus faibles par rapport aux méthodes traditionnelles de génération d'électricité. Cependant, elles présentent également des limitations, telles que des coûts initiaux élevés, des exigences de maintenance complexes et une efficacité limitée à faibles puissances.[1]

II.3.Évolution historique de la conception des aubes de turbine à gaz

L'évolution historique de la conception des aubes de turbine à gaz a été un aspect significatif du développement de la technologie des turbines à gaz. Au fil des ans, diverses innovations et avancées ont façonné la conception des aubes de turbine pour améliorer les performances et l'efficacité. Voici un résumé de l'évolution de la conception des aubes de turbine à gaz basé sur les sources fournies :

II.3.1.Développements initiaux

En 1791, John Barber a breveté le premier design de moteur à turbine à gaz, qui comprenait un compresseur à gaz alternatif, une chambre de combustion et une turbine. En 1872, Franz Stolze a conçu un moteur avec un compresseur axial, une turbine axiale, un échangeur de chaleur, un producteur de gaz et une chambre de combustion, dans le but de produire 200 chevaux-vapeur mais n'a réussi à produire que 20 chevaux-vapeur.

II.3.2.Innovations

En 1906, des ingénieurs français ont construit une turbine à gaz avec un compresseur centrifuge à 2 étages et des aubes de turbine à buse refroidies à l'eau, atteignant une puissance de 400 chevaux. General Electric a créé une division de turbines à gaz en 1918, développant le turbocompresseur GE pendant la Première Guerre mondiale, qui utilisait les gaz d'échappement des moteurs à piston pour entraîner une roue de turbine pour la suralimentation.

II.3.3. Avancements

Dans les années 1930, Frank Whittle a déposé une demande de brevet pour une turbine à gaz destinée à la propulsion par réaction, testant avec succès son moteur sur banc d'essai en 1937 et obtenant ultérieurement un contrat pour concevoir un moteur de vol en 1939. Depuis les années 1960, les fabricants de turbines à gaz ont amélioré les systèmes de refroidissement internes des aubes de turbine pour résister aux températures élevées, améliorant ainsi l'efficacité et les performances.

II.3.4. Techniques modernes

Le refroidissement des aubes de turbine à gaz est une caractéristique cruciale dans la conception des turbines à gaz, permettant au moteur de fonctionner à des températures supérieures aux points de fusion des matériaux utilisés dans les aubes. Les turbines à gaz modernes intègrent des systèmes de refroidissement avancés tels que le refroidissement par film, le refroidissement par transpiration et les revêtements barrière thermique pour gérer les températures élevées et améliorer l'efficacité. [2]

II.4. Classifications des aubes de turbine à gaz

II.4.1. Basé sur la fonction

- Aubes de compresseur : Ces aubes sont situées dans la section du compresseur de la turbine à gaz et sont responsables de la compression de l'air entrant.
- Aubes de turbine : Situées dans la section de la turbine, ces aubes extraient l'énergie du flux de gaz chaud et haute pression produit par la combustion du carburant et de l'air.

II.4.2. Basé sur le matériau

- Aubes en métal : Traditionnellement fabriquées à partir de matériaux tels que les superalliages à base de nickel en raison de leur résistance à haute température et à la déformation.
- Aubes en céramique : Des matériaux avancés tels que les composites à matrice céramique (CMC) sont de plus en plus utilisés pour leur capacité à supporter des températures plus élevées et à réduire les besoins en refroidissement.

II.4.3. Basé sur la méthode de refroidissement

- Aubes non refroidies : Certaines aubes de turbine comptent uniquement sur le flux d'air provenant du compresseur pour le refroidissement.

- Aubes refroidies : De nombreuses aubes de turbine sont activement refroidies en utilisant des passages internes à travers lesquels de l'air de refroidissement est circulé pour éviter la surchauffe.

II.4.4.Basé sur l'emplacement

- Aubes fixes (stators) : Ces aubes sont fixées en place et guident le flux d'air à travers le compresseur ou la turbine.
- Aubes mobiles (rotors) : Ces aubes tournent avec l'arbre du rotor et extraient de l'énergie du flux d'air.

II.4.5.Basé sur le profil d'aube

- Aubes axiales : Le flux d'air passe parallèlement à l'axe de rotation.
- Aubes radiales : Le flux d'air se déplace perpendiculairement à l'axe de rotation.
- Aubes à flux mixte : Combinaison d'éléments des conceptions des aubes axiales et radiales.

II.4.6.Basé sur le processus de fabrication

- Aubes moulées sous pression : Couramment utilisées pour des formes complexes et des applications hautes performance.
- Aubes monocristallines : Fabriquées à l'aide de processus spécialisés pour éliminer les limites de grains, améliorant ainsi les performances à haute température.

II.4.7.Basé sur le revêtement

- Aubes revêtues de barrière thermique (TBC) : Revêtues de matériaux céramiques pour fournir une isolation thermique et protéger contre les hautes températures.
- Aubes revêtues de barrière environnementale (EBC) : Offrent une protection contre la dégradation environnementale causée par des facteurs tels que l'oxydation et la corrosion.[3]



Figure II-1: Différents types des aubes

II.5.Sélection des matériaux et propriétés pour les aubes de turbine à gaz

Le choix des matériaux pour ces aubes est primordial pour garantir qu'elles puissent supporter les hautes températures, les contraintes et les environnements corrosifs tout en maintenant leur intégrité structurale sur de longues périodes d'exploitation. Voici un aperçu de la sélection des matériaux et des propriétés clés pour les aubes de turbine à gaz :

II.5.1.Superalliages à base de nickel

- Propriétés : Résistance à haute température, résistance au fluage et excellentes propriétés mécaniques à températures élevées.
- Applications : Principalement utilisés dans les aubes de compresseur et de turbine en raison de leur capacité à supporter les conditions de fonctionnement difficiles des turbines à gaz.

II.5.2.Composites à matrice céramique (CMCs)

- Propriétés : Propriétés thermiques et mécaniques exceptionnelles, y compris une résistance à haute température et une faible densité.
- Applications : De plus en plus utilisés dans les aubes de turbine pour permettre des températures de fonctionnement plus élevées et améliorer l'efficacité du moteur.

II.5.3.Alliages monocrystalline

- Propriétés : L'élimination des limites de grains améliore la résistance à la déformation à haute température et prolonge la durée de vie des composants.
- Applications : Couramment utilisés dans les sections à haute température des moteurs à turbine à gaz où la résistance au fluage est critique.

II.5.4.Alliages solidifiés dans une direction

- Propriétés : Résistance améliorée à la corrosion à haute température et résistance accrue au fluage par rapport aux grains équiaxes.
- Applications : Adaptés aux aubes de turbine soumises à des gradients de température élevés et à des contraintes mécaniques.[4]

II.6.Revêtement

II.6.1.Revêtements barrière thermique (TBC)

- Propriétés : Fournissent une isolation thermique, réduisent le transfert de chaleur vers le substrat de la lame et protègent contre les cycles thermiques.

- Applications : Appliqués sur les aubes de turbine pour améliorer leur résistance thermique et prolonger leur durée de vie. Figure II.2




Figure II-2:TBC et les couches associées

II.6.2. Revêtements de barrière environnementale (EBCs)

- Propriétés : Protéger contre la dégradation environnementale causée par des facteurs tels que l'oxydation et la corrosion, améliorant la durabilité des composants. Figure II.3
- Applications : Appliqué sur les aubes de turbine exposées à des environnements de combustion agressifs. [5]




Figure II-3: EBC et couches associées

II.7.Tests et caractérisation des matériaux

- Performance à haute température : Évaluation des propriétés des matériaux dans des conditions de fonctionnement, y compris le fluage, la fatigue et la stabilité thermique.
- Résistance à la corrosion : Évaluation de la résistance à l'oxydation, à la sulfuration et à d'autres formes de corrosion dans les environnements de turbines à gaz.
- Contrôle non destructif (CND) : Utilisation de techniques telles que le contrôle ultrasonore et la diffraction des rayons X pour détecter les défauts et assurer l'intégrité des composants.

II.8.Tendances futures

- Matériaux avancés : Poursuite de la recherche sur des matériaux novateurs tels que les métaux réfractaires, les intermétalliques et les nanocomposites afin de repousser les limites des performances des turbines à gaz.
- Fabrication additive : Utilisation des techniques de fabrication additive pour fabriquer des géométries des aubes complexes et adapter les propriétés des matériaux à des applications spécifiques.

II.9.Importance des aubes de turbine à gaz

Les aubes de turbine à gaz sont des composants cruciaux des moteurs à turbine à gaz, largement utilisés dans la production d'électricité, l'aviation et diverses applications industrielles. Figure II.4.

Les aubes sont responsables de la compression de l'air entrant et de l'expansion des gaz chauds générés par la combustion du carburant, ce qui entraîne la rotation de la turbine et produit de l'énergie mécanique.

L'importance des aubes de turbine à gaz réside dans leur capacité à supporter des températures et des pressions élevées tout en maintenant leur intégrité structurelle.




Figure II-4: Une représentation schématique d'aube de turbine à gaz typique

Les aubes sont soumises à des conditions extrêmes en raison des gaz à haute température générés par le processus de combustion. Pour garantir des performances optimales et une longévité, les aubes sont conçues avec des matériaux avancés et des systèmes de refroidissement.

Un des aspects critiques de la conception des aubes de turbine à gaz est le refroidissement. Les aubes sont exposées à des températures élevées, ce qui peut entraîner une déformation, des fissures et d'autres formes de dommages avec le temps. Pour atténuer ces problèmes, les fabricants de turbines à gaz ont développé des systèmes de refroidissement internes pour les aubes. Ces systèmes de refroidissement aident à dissiper la chaleur générée par les gaz chauds, permettant aux aubes de fonctionner à des températures plus élevées et améliorant l'efficacité globale du moteur de la turbine à gaz.

Il existe plusieurs types de systèmes de refroidissement utilisés dans la conception des aubes de turbine à gaz, notamment le refroidissement par convection, le refroidissement par impact, le refroidissement par film et le refroidissement par transpiration. Chacun de ces systèmes de refroidissement a ses avantages et ses inconvénients, et le choix du système de refroidissement dépend des exigences spécifiques du moteur de turbine à gaz. Figure II.5

- Le refroidissement par convection implique l'utilisation d'air ou d'un autre fluide pour éliminer la chaleur de la surface de l'aube.
- Le refroidissement par impact implique l'utilisation de jets d'air ou de fluide à haute vitesse pour impacter la surface de l'aube, ce qui aide à éliminer la chaleur de manière plus efficace.
- Le refroidissement par film implique l'utilisation d'un mince film d'air ou de fluide pour circuler sur la surface de l'aube, créant une barrière entre la surface de l'aube et les gaz chauds.
- Le refroidissement par transpiration implique l'utilisation de matériaux poreux pour permettre à l'air ou au fluide de traverser l'aube, ce qui aide à éliminer la chaleur de manière plus efficace.[6]




Figure II-5: Les développements en matière de refroidissement des turbines qui ont eu lieu au cours des dernières décennies

II.9.1.Température de surface des aubes

La température de surface des aubes est la température ressentie par l'aube en raison de l'écoulement des gaz de combustion chauds sur celle-ci. La température de surface de l'aube est inférieure à celle des gaz de combustion car ces derniers s'écoulent au-dessus des aubes à des vitesses très élevées. La température de surface de l'aube est la moyenne des températures d'entrée et de sortie des gaz chauds moins la tête cinétique rotative.

Elle est exprimée comme suit :

$$T_{o-bl} = (T_{01} + T_{02}) / 2 - U^2 / 2c_p \text{-gas} (1 - 2DR) ; \text{Formule II.10.1}$$

Ou **To-bl** La température de surface de l'aube,

T01 La température d'entrée,

T02 la température de sortie,

U le coefficient global de transfert de chaleur,

DR le facteur de réaction de l'aube.

En raison de la forme caractéristique de l'aube et du motif d'écoulement des gaz de combustion sur celle-ci, la température n'est pas uniforme sur l'aube mais répartie avec différentes zones de température. La figure 2 montre comment la température est distribuée sur une aube régulière. Le point au niveau du bord d'attaque où les gaz d'admission chauds tombent presque perpendiculairement est appelé zone de stagnation car la vitesse en ce point est presque nulle. Figure II.6. En raison de cela, cette portion connaît une température très élevée car la température est la température statique des gaz d'admission. De même, la partie vers les bords de fuite souffre de températures plus élevées en raison du point d'écoulement statique. La surface concave de l'aube présente un important gradient de température en raison du changement du motif d'écoulement de la zone laminaire à la zone turbulente et donc du coefficient de transfert de chaleur.[7]




Figure II-6: Profil de température d'aube

II.10. Facteurs conduisant aux dommages des aubes de turbine à gaz

Les facteurs conduisant aux dommages des aubes de turbine à gaz comprennent une combinaison de problèmes environnementaux, opérationnels et liés aux matériaux. Ces facteurs peuvent avoir un impact significatif sur les performances et la longévité des aubes de turbine à gaz. Voici quelques causes courantes de dommages aux aubes de turbine à gaz :

II.10.1. Corrosion

La corrosion, y compris la corrosion à haute température, peut résulter de la réaction entre les composants internes et des contaminants tels que les sels, les acides ou les gaz réactifs. Cela peut entraîner une perte de matériau et l'adhérence de matériaux corrosifs aux aubes, les affaiblissant avec le temps.

II.10.2. Fissures

Les aubes de turbine à gaz peuvent développer des fissures en raison de facteurs tels que la fatigue induite par le frottement, l'érosion et les contraintes thermiques. Les fissures peuvent entraîner des faiblesses structurelles et une défaillance potentielle des aubes. La détection des fissures est cruciale pour prévenir les défaillances catastrophiques et garantir la sécurité et l'efficacité des opérations des turbines à gaz.

II.10.3. Rayures

Les revêtements protecteurs sur les aubes de turbine à gaz peuvent développer des rayures qui favorisent la corrosion, surtout sur les bords d'attaque des aubes. Ces rayures peuvent compromettre l'intégrité du revêtement et exposer le matériau sous-jacent aux éléments corrosifs, entraînant une dégradation et des dommages potentiels.

II.10.4. Fractures

Les entailles sur les aubes de turbine à gaz peuvent résulter de l'ingestion d'objets étrangers, de l'érosion ou de dommages mécaniques. Ces entailles peuvent affaiblir la structure de l'aube et affecter son efficacité aérodynamique, entraînant potentiellement des problèmes de performances et la nécessité d'entretien ou de réparation.




Figure II-7: Tous les défauts sur les aubes de turbine à gaz qui peuvent être détectés lors d'une inspection visuelle seulement, « Taurus 60 turbine à gaz »

II.11.Aperçu des protocoles d'inspection et de maintenance

L'inspection et la maintenance des turbines à gaz sont cruciales pour maintenir la fiabilité et la longévité de ces machines complexes. Voici les principaux aspects des protocoles d'inspection et de maintenance pour les turbines à gaz :

II.11.1.Maintenance préventive

Cette approche proactive consiste à identifier les modes de défaillance et à mettre en œuvre des mesures d'atténuation des risques grâce à des remplacements et des inspections proactifs. L'objectif est de minimiser l'ampleur du programme de maintenance corrective sur les turbomachines.

II.11.2.Maintenance déficiente (planifiée)

Ce programme basé sur l'évitement des défaillances consiste à identifier et à planifier des remèdes pour les réparations ou les déficiences lors de la prochaine opportunité, par exemple lors d'une interruption planifiée.

II.11.3.Maintenance corrective

Cette approche réactive, basée sur les défaillances, consiste à réparer les composants après une défaillance, ce qui entraîne souvent une interruption forcée et des travaux de réparation ultérieurs.

II.11.4.Inspection de la section de combustion

L'inspection régulière et le nettoyage de la section de combustion chaude, qui comprend les doublures de combustion et les boîtes, les capuchons d'extrémité, les ensembles de buses de carburant, les tubes de tir croisé et les pièces de transition, sont essentiels pour maintenir la durée de vie utile d'un moteur de turbine à gaz.

II.11.5.Enregistrement et analyse réguliers des données

L'enregistrement et l'analyse des données opérationnelles sont essentiels pour la maintenance préventive et planifiée. Ces données peuvent aider à identifier les tendances et les problèmes potentiels avant qu'ils ne deviennent critiques.

II.11.6.Gestion des pièces de rechange

La gestion des pièces de rechange pour un remplacement immédiat est cruciale pour atteindre la disponibilité maximale de la turbine à gaz. Cela inclut les pièces de rechange pour les tubes de tir croisé, les manchons de débit, les vannes de purge, les clapets de non-retour, les bougies d'allumage, les détecteurs de flamme, les flexibles, les corps étrangers, l'usure anormale, les fissures, le bouchage des trous de refroidissement de la doublure, l'état du revêtement TBC, l'oxydation/corrosion/érosion, les points chauds/brûlure, les fixations manquantes, les limites de jeu, et les actions potentielles de l'endoscope pour le compresseur et la turbine.

II.11.7.Procédures d'inspection spéciales

Des procédures d'inspection spéciales peuvent s'appliquer à des composants spécifiques pour garantir que les pièces atteignent leur durée de vie prévue. Ces inspections peuvent inclure des inspections dimensionnelles, une inspection par ressuage fluorescent (FPI), une inspection par courants de Foucault (ECI), et d'autres formes de contrôle non destructif (CND).

II.11.8.Actions de réparation

Les actions de réparation sont entreprises sur la base du numéro de pièce, de l'historique opérationnel de l'unité et de l'état de la pièce. Les réparations peuvent inclure le démontage, le nettoyage chimique, le pressage isostatique à chaud (HIP), le traitement thermique, le revernissage et la réparation par soudage.

II.12.Introduction aux méthodes de contrôle non destructif (CND)

Le contrôle non destructif (CND) englobe un ensemble de techniques d'analyse utilisées dans diverses industries pour évaluer les propriétés des matériaux, des composants ou des assemblages sans causer de dommages. Largement utilisées dans la fabrication, l'évaluation des produits et l'analyse des défaillances, les méthodes de CND sont essentielles pour garantir la conformité aux spécifications et identifier les défauts des pièces sans compromettre leur intégrité. Ces méthodes exploitent toute une gamme de signaux, allant des inspections visuelles conformes aux normes établies à l'utilisation d'ondes sonores, de champs magnétiques, de rayons X, de neutrons ou de colorants pour détecter les discontinuités, les fissures ou les défauts.

Parmi les six méthodes de CND les plus couramment utilisées :

- Test visuel
- Courants de Foucault
- Particules magnétiques
- Ressuage
- Radiographies
- Ultrasonore

Chacune trouve des applications dans plusieurs secteurs, couvrant le génie mécanique, le génie pétrolier, le génie civil...etc. Ces techniques sont fondamentales pour garantir la sécurité et la fiabilité des matériaux et des structures, détecter les soudures incomplètes, les défauts de surface ou les inclusions, évaluer l'intégrité des soudures et évaluer la qualité des joints adhésifs, notamment dans les applications aérospatiales. La certification des opérateurs de CND, souvent réalisée en interne ou par le biais d'organismes externes, souligne le rôle crucial des inspecteurs qualifiés dans le respect des normes d'inspection et garantit l'efficacité des processus de CND. De plus, l'évolution du paysage du CND continue de façonner des domaines au-delà de l'industrie, influençant les technologies d'imagerie médicale telles que l'échocardiographie, l'échographie médicale et la radiographie numérique, soulignant l'importance des avancées en matière de CND à portée étendue.

II.13.Test visuel pour les aubes de turbine à gaz

Une méthode fondamentale de contrôle non destructif (CND) qui implique l'observation visuelle de la surface des aubes pour détecter les anomalies et les défauts. Cette méthode est couramment utilisée dans l'inspection des aubes de turbine à gaz, les colorants fluorescents étant souvent recommandés pour l'inspection, notamment pour détecter les fissures en surface. L'inspection visuelle est cruciale pour identifier l'usure, l'érosion et les défauts visibles à la surface des aubes, figure II.8(a), fournissant une étape initiale simple dans le processus d'inspection.

Dans le contexte de l'inspection des aubes de turbine à gaz, le test visuel sert de méthode principale pour détecter les défauts de surface et l'usure, permettant aux inspecteurs d'identifier rapidement les problèmes visibles qui peuvent nécessiter une évaluation ou une maintenance ultérieure. Bien que le test visuel soit efficace pour les anomalies de surface, il est important de noter que cette méthode est limitée à la détection des défauts visibles à l'œil nu et peut ne pas être en mesure d'identifier les défauts ou les fissures en sous-surface.




Figure II-8: (a) Les aubes de turbine présentant différents niveaux d'usure et de dommages. (b) Vue de la caméra d'une pose de mesure exemplaire

II.14. Inspection par Boroscope

La méthodologie d'inspection par boroscope pour les aubes de turbine à gaz est un processus essentiel pour garantir la sécurité et l'efficacité des opérations des turbines à gaz. Les boroscopes offrent une méthode économique et non destructive pour inspecter visuellement les parties les plus internes d'une turbine, telles que le chemin des gaz, le rotor ou les aubes de l'impulseur, qui seraient sinon pratiquement impossibles à atteindre et à visualiser physiquement sans de longs arrêts système ou d'usine.

Les boroscopes existent en versions rigides et flexibles, équipés d'un système d'éclairage et optique, ainsi que d'un oculaire ou d'un écran numérique pour visualiser le chemin d'inspection. Ils peuvent mesurer jusqu'à 30 pieds (9 mètres) de long, offrant une couverture suffisante pour de telles inspections. Figure II.9. L'utilisation d'un Boroscope vidéo flexible et articulé pour les inspections nécessaires élimine des impacts significatifs en termes de ressources, notamment les coûts de main-d'œuvre, de gréement et de maintenance qui seraient autrement nécessaires pour démonter des équipements de cette taille.



Figure II-9: Image représentant un boroscope

L'inspection par boroscope permet de détecter les fissures en surface, l'usure excessive ou d'autres défauts sur les conduits de sortie de la chambre de combustion, les couvercles, la buse de carburant de la turbine, ainsi que sur les aubes de la première étape de la turbine et les aubes de guidage de la buse. Cette méthode est cruciale pour détecter la déformation, les fissures ou les dommages causés par des corps étrangers sur ces composants.

II.15.Contexte d'inspection pour la turbine à gaz Taurus 60

Le Taurus 60 est une turbine à gaz développée par Solar Turbines, offrant des fonctionnalités avancées et disponible dans des configurations de génération d'électricité et d'entraînement mécanique. La configuration de génération d'électricité a une puissance de sortie de 5,670 Mw, un rendement de 31,5 % et un taux de chaleur de 11,430 KJ/Kwh. La configuration d'entraînement mécanique a une puissance de sortie de 5,740 MW et un taux de chaleur de 11,265 kJ/kWh. Le moteur est conçu pour une haute efficacité et de faibles émissions, présentant un moteur à arbre unique avec 12 étages de compresseur axial, une chambre de combustion annulaire et 3 étages de turbine de puissance à réaction. Le poids approximatif de la configuration de génération d'électricité est de 37,920 kg, et les dimensions approximatives sont de 9,8x2,6x3,2 m3.[8]




Figure II-10: Vue interne du composant de la turbine.

La configuration d'entraînement mécanique pèse environ 15 420 kg et a des dimensions de 6,0x2, 5x2, 7 m³. Le Taurus 60 est utilisé pour la production d'électricité dans le champ de Hassi Tidjerane (HTJ & HTJW). Cependant, pour garantir son bon fonctionnement à long terme, des inspections régulières sont impératives. L'inspection de 4000 heures s'est avérée être une étape essentielle pour évaluer l'usure, détecter d'éventuels défauts et garantir le respect des normes de sécurité.

II.15.1.Méthodologie d'inspection

L'outil principal utilisé lors de cette opération était le boroscope, un dispositif optique permettant l'inspection visuelle interne des composants de la turbine. L'utilisation du boroscope offre une approche non destructive, permettant une évaluation détaillée sans démontage significatif de l'équipement. Cela s'avère crucial pour minimiser les temps d'arrêt et optimiser la planification de la maintenance.

II.15.2.Préparation de l'opération

Avant de commencer l'inspection, une préparation minutieuse a été entreprise. Cela impliquait la mise en place de l'espace de travail, l'étalonnage du boroscope et la coordination avec les équipes opérationnelles pour garantir la sécurité et l'efficacité. Un strict respect des procédures de sécurité a été maintenu pour minimiser les risques potentiels. Figure II.11



Figure II-11: Configuration de l'espace de travail pour la préparation de l'inspection par Boroscope.

II.15.3.Inspection approfondie

L'utilisation du Boroscope a facilité l'exploration des zones critiques à l'intérieur de la turbine, y compris les aubes, les conduits et les composants internes. Figure II.12. Les images et vidéos capturées ont fourni une vue détaillée de l'état actuel de la turbine, permettant aux ingénieurs de détecter tout signe d'usure, de corrosion ou d'autres problèmes potentiels. Les résultats de l'inspection ont été soigneusement documentés pour guider les actions de maintenance futures.




Figure II-12: Vue interne du composant de la turbine à travers le boroscope.

II.15.4. Plan d'inspection

L'inspection couvre les composants suivants :

- Diffuseur d'entrée du compresseur axial : VIG (Van d'Inlet Guide)
- Diffuseur de sortie du compresseur axial : VEG (Van d'Exit Guide)
- Injecteurs et chambre de combustion
- Rotors et stators
- Conduit d'échappement et diffuseur

II.15.5. Analyse des résultats

Après l'inspection, une analyse approfondie des résultats. Figure II.13. est indispensable dont les données collectées seront comparées aux normes de performance et aux spécifications du fabricant.



Figure II-13: Inspection interne des aubes de turbine à gaz Taurus 60 via une caméra de

II.16. Technologies des aubes intelligentes et adaptatives

Les technologies des aubes intelligentes et adaptatives représentent des innovations de pointe dans le domaine de l'ingénierie des turbines à gaz, offrant des solutions dynamiques pour améliorer les performances, l'efficacité et la flexibilité opérationnelle. Voici une exploration de ces technologies et de leur impact sur les systèmes de turbines à gaz :

II.16.1. Technologies des aubes intelligentes

- Systèmes de détection : Intégration de capteurs, tels que des jauges de contrainte, des capteurs de température et des accéléromètres, directement dans les aubes de turbine pour surveiller les conditions de fonctionnement et la santé structurelle en temps réel.
- Surveillance de l'état : Utilisation des données provenant des capteurs intégrés pour effectuer une maintenance basée sur l'état, permettant l'identification proactive de problèmes potentiels et l'optimisation des programmes de maintenance.
- Systèmes de contrôle actif : Mise en œuvre d'actionneurs et de mécanismes de contrôle à l'intérieur des aubes de turbine pour ajuster dynamiquement la géométrie des aubes ou le flux d'air, maximisant ainsi l'efficacité dans des conditions de fonctionnement variables.

II.16.2. Technologies des aubes adaptatives

- Aubes à géométrie variable : Incorporation de mécanismes pour ajuster dynamiquement les angles des aubes, la torsion ou la forme en réponse aux conditions de fonctionnement changeantes, optimisant ainsi les performances aérodynamiques et l'efficacité.
- Systèmes de refroidissement actif : Intégration de technologies de refroidissement actif, telles que le refroidissement par film et les revêtements thermiques, pour réguler les températures des aubes et améliorer la gestion thermique lors d'opérations transitoires ou de conditions de charge thermique élevée.
- Alliages à mémoire de forme (SMAs) : Utilisation de SMAs dans la construction des aubes pour permettre des effets de mémoire de forme, permettant aux aubes de changer de forme ou de rigidité en réponse aux variations de température ou aux charges mécaniques.

II.16.3. Avantages et applications

- Efficacité améliorée : Les technologies des aubes intelligentes et adaptatives permettent aux turbines à gaz de fonctionner plus près de leurs limites de conception, optimisant ainsi l'efficacité de conversion de l'énergie et réduisant la consommation de carburant.
- Fiabilité accrue : La surveillance en temps réel et les capacités de contrôle adaptatif améliorent la fiabilité de la turbine en détectant et en atténuant les problèmes potentiels avant qu'ils ne deviennent critiques, minimisant ainsi les temps d'arrêt et les coûts de maintenance.
- Flexibilité et résilience : Les technologies des aubes adaptatives offrent la flexibilité nécessaire pour s'adapter aux exigences opérationnelles changeantes, telles que les fluctuations de charge ou les conditions ambiantes, garantissant ainsi des performances optimales dans divers scénarios d'exploitation.
- Durabilité environnementale : En optimisant l'efficacité de la turbine et en réduisant les émissions grâce à un fonctionnement et un contrôle plus intelligent, ces technologies contribuent aux objectifs de durabilité environnementale.

II.16.4.Défis et orientations futures

- Complexité de l'intégration : La mise en œuvre des technologies des aubes intelligentes et adaptatives nécessite de surmonter les défis liés à l'intégration avec les systèmes de turbines existants, en garantissant la compatibilité et la fiabilité.
- Considérations matérielles et structurelles : Développement de matériaux avancés et de conceptions structurales capables de résister aux conditions de charge dynamique et de prolonger la durée de vie opérationnelle.
- Analyse des données et optimisation : Exploitation des techniques d'analyse de données et d'apprentissage approfondi pour extraire des informations exploitables des données des capteurs et optimiser les stratégies de contrôle pour une performance et une efficacité maximale. [9]

II.16.5.Conclusion

Ce chapitre a fourni une vue d'ensemble complète des aubes de turbine à gaz, couvrant leur conception, matériaux, et principes de fonctionnement. Nous avons examiné leur évolution historique, les différentes classifications, ainsi que les techniques de sélection des matériaux et de revêtement. Les protocoles d'inspection et de maintenance ont également été abordés, soulignant l'importance des stratégies de maintenance proactive. Enfin, nous avons exploré les technologies avancées pour l'inspection et l'amélioration des performances des aubes.

CHAPITRE III :
GÉNÉRATION DES
DONNÉES SYNTHÉTIQUES
ET APPRENTISSAGE
PROFOND

III. GÉNÉRATION DES DONNÉES SYNTHÉTIQUES ET APPRENTISSAGE PROFOND

III.1. Introduction

Ce chapitre explore l'utilisation de Blender pour la génération de données synthétiques, soulignant l'importance de ces données dans l'analyse des aubes de turbine à gaz. Nous discutons les défis liés à la disponibilité limitée des données réelles et aux préoccupations de confidentialité, ainsi que des avantages en termes de détection et segmentation des défauts, et de l'efficacité en termes de coûts et de temps. Le recours à l'utilisation de Blender pour la création de modèles 3D et la génération d'images synthétiques s'est révélé efficace et indispensable. Ensuite, nous détaillons la méthodologie de création de modèles 3D et de génération d'images synthétiques de ces aubes dans Blender, ainsi que les résultats obtenus, figure III.1. Enfin, nous fournissons un contexte plus large en abordant des concepts clés tels que le traitement d'images, la vision par ordinateur, les réseaux de neurones et les architectures de réseaux neuronaux convolutifs (CNN), et nous présentons les modèles d'apprentissage profond appliqués à l'analyse des aubes de turbine à gaz.




Figure III-1: Organigramme d'obtention de dataset

III.2.Introduction sur la génération de données synthétiques avec Blender

Blender est une technique puissante pour créer des données destinées à soutenir des projets de vision par ordinateur. Blender, une bibliothèque d'animation open-source, permet aux ingénieurs de concevoir et de générer efficacement des données synthétiques pour des tâches de vision par ordinateur. En tirant parti des capacités de Blender, les ingénieurs peuvent prototyper rapidement des algorithmes, réduire considérablement les coûts de collecte de données et générer des images 3D réalistes pour l'entraînement des modèles d'IA. Cette méthode est particulièrement précieuse dans les scénarios où la création de jeux de données d'images annotées est chronophage ou coûteuse. La création de données synthétiques dans Blender implique le rendu d'images 3D réalistes, en abordant l'accessibilité, l'annotation, l'automatisation et la scalabilité, et en utilisant les capacités procédurales de Blender pour entraîner des modèles de vision robustes avec peu ou pas besoin d'annotations humaines. Le processus implique la configuration de Blender sur des machines locales ou des instances cloud, l'installation d'outils nécessaires comme ZPY, et l'utilisation des fonctionnalités de Blender pour générer des données synthétiques pour diverses tâches en aval dans la vision par ordinateur.

III.3.Importance des données synthétiques dans l'analyse des aubes de turbine à gaz

Dans le contexte de l'analyse des aubes de turbine à gaz, la génération de données synthétiques utilisant un rendu basé sur la physique offre une solution précieuse pour l'entraînement de modèles et la détection d'anomalies. Voici les points clés qui mettent en évidence l'importance des données synthétiques dans l'analyse des aubes de turbine à gaz :

III.3.1.Disponibilité limitée des données réelles

Les inspections des aubes de turbine à gaz ne fournissent pas toujours une quantité suffisante de données réelles en raison de facteurs tels que l'unicité des aubes, le manque de méthodes d'inspection normalisées et la rareté des inspections. Les données synthétiques peuvent combler cette lacune en fournissant des points de données supplémentaires pour l'entraînement et l'analyse.

III.3.2.Préoccupations concernant la confidentialité

Les données réelles dans des industries comme la fabrication de turbines à gaz peuvent être sensibles, ce qui rend difficile le partage ou l'utilisation pour l'entraînement de modèles. Les données synthétiques avec des garanties de confidentialité peuvent être une alternative viable pour répondre à ces préoccupations tout en permettant une analyse et un entraînement de modèles efficaces.

III.3.3.Détection et segmentation des défauts

La génération de données synthétiques permet la création de divers scénarios de défauts dans un environnement contrôlé, aidant ainsi dans les tâches de détection et de segmentation des

défauts. Cela est particulièrement utile dans les usines intelligentes où les défauts sont rares et où la collecte d'un ensemble de données suffisant de défauts pour l'apprentissage supervisé est peu pratique.

III.3.4.Efficacité en termes de coûts et de temps

La génération de données synthétiques peut réduire de manière significative les coûts et le temps associés aux méthodes traditionnelles de collecte de données, notamment dans les scénarios où la collecte de données réelles est intensive en main-d'œuvre ou en ressources.[10]

III.4.Création de modèle 3D des aubes de turbine à gaz dans Blender

Des recherches antérieures ont exploré différentes approches pour créer des modèles 3D des aubes de turbine à gaz, notamment des logiciels de CAO, des simulations de dynamique des fluides computationnelle (CFD) et des techniques de sculpture manuelle. Bien que ces méthodes présentent des avantages, elles nécessitent souvent une expertise spécialisée, sont chronophages ou manquent de flexibilité pour générer des géométries des aubes réalistes. En revanche, Blender offre une suite complète d'outils et de fonctionnalités qui permettent une modélisation 3D efficace et précise figure III.2, en faisant un choix attractif pour la représentation des aubes de turbine à gaz.



Figure III-2: Visualisation d'aube de turbine à gaz non défectueuses réalisée par Blender.

III.4.1.Méthodologie

La méthodologie de création de modèles 3D des aubes de turbine à gaz dans Blender comprend plusieurs étapes séquentielles :

- **Collecte de références** : Rassembler des images de référence, des schémas et des spécifications techniques des aubes de turbine à gaz pour garantir l'exactitude et la fidélité du modèle 3D.

- **Configuration des plans** : Importer des images de référence ou des plans dans Blender et les configurer dans la vue arrière-plan pour servir de guide pour la modélisation.
- **Création du profil d'aube** : Créer le profil de base de l'aube de turbine à gaz en utilisant les outils de modélisation de Blender tels que l'extrusion, le redimensionnement et la manipulation des sommets.
- **Extrusion et déroulement** : Extruder et dérouler le profil de l'aube le long d'un chemin pour créer la géométrie 3D de l'aube, en utilisant les modificateurs de Blender pour une modélisation efficace.
- **Détails et sculpture** : Ajouter des détails de surface et affiner la géométrie de l'aube en utilisant les outils de sculpture de Blender pour obtenir un cas réel avec précision.
- **Optimisation de la topologie** : Optimiser la topologie du modèle d'aube pour un rendu et une animation efficace, en assurant un flux de bord et une topologie appropriée.
- **Dépliage UV et texturation** : Déplier les UV du modèle d'aube et créer des textures pour les propriétés de surface telles que la rugosité et l'usure.
- **Rendu et visualisation** : Configurer les matériaux, l'éclairage et les angles de caméra pour rendre le modèle 3D final de l'aube de turbine à gaz en utilisant le moteur de rendu de Blender.

III.5.Procédé de génération d'images synthétiques des aubes de turbine à gaz (défectueuses) avec Blender

III.5.1.Méthodologie

La génération procédurale d'images synthétiques des aubes de turbine à gaz avec Blender comprend les étapes suivantes :

- **Configuration de la scène** :

Création d'un environnement de scène Blender avec un éclairage approprié, des paramètres de caméra et des éléments d'arrière-plan pour simuler des conditions réalistes.

- **Paramétrisation de l'aube** :

Définition des paramètres tels que la géométrie de l'aube, la texture de surface et les propriétés des matériaux en utilisant les outils de modélisation procédurale et les modificateurs de Blender.

- **Contrôle des variations** :

Introduction de variations contrôlées dans la géométrie de l'aube, telles que la torsion de l'aube, la longueur de la corde et le profil aérodynamique, pour simuler différentes configurations de conception.

- **Mappage de texture :**

Application de cartes de texture et de shaders (éclairage) de matériau aux surfaces de l'aube pour simuler des propriétés de surface telles que la rugosité, la corrosion et la décoloration due à la chaleur.

- **Rendu :**

Rendu d'images synthétiques d'aube en utilisant le moteur de rendu intégré de Blender ou des moteurs de rendu externes, ajustement des paramètres de rendu pour une qualité d'image et une fidélité optimale.

- **Génération des données :**

Génération des données d'images synthétiques des aubes en variant systématiquement les paramètres d'entrée et en rendant plusieurs images pour chaque configuration.

III.6.Résultats de modélisation

Cette méthodologie a été mise en œuvre et évaluée sur un jeu de données d'images synthétiques des aubes de turbine à gaz. Les images résultantes présentaient des géométries d'aube diverses, des textures de surface et des conditions d'éclairage, ressemblant étroitement aux images des aubes du monde réel. Et voici quelques exemples :



Figure III-3: Modèles générés avec Blender montrant différentes conditions d'éclairage pour mettre en évidence les défauts

III.7.Contexte sur l'apprentissage profond

III.7.1. Introduction

Au cours des dernières années, il y a eu d'énormes avancées dans la technologie et les capacités des ordinateurs ont atteint un nouveau niveau. Cela a permis aux scientifiques de tenter ce qu'ils ne pouvaient pas faire auparavant, notamment dans le domaine de l'intelligence artificielle qui demande d'énormes puissances de calcul. Dans ce chapitre, nous présenterons le contexte principal de notre travail, y compris des détails sur le traitement d'images, les applications de vision par ordinateur. Nous introduirons également les réseaux neuronaux et leurs composants, ainsi qu'un aperçu de l'apprentissage profond.

III.7.2.Qu'est-ce qu'une image ?

En se référant au livre de Gonzelez et Woods [11], nous pouvons citer la définition suivante pour l'image numérique :

« Une image peut être définie comme une fonction bidimensionnelle, $f(x, y)$, où x et y sont des coordonnées spatiales (plan) et l'amplitude de chaque paire de coordonnées (x, y) est appelée l'intensité ou le niveau de gris de l'image à ce point. Lorsque x , y et les valeurs d'amplitude de f sont toutes des quantités finies et discrètes, nous appelons l'image une image numérique ».

Les formats de fichier d'image courants en ligne comprennent :

JPEG (prononcé JAY-peg) est un fichier image graphique produit selon une norme du Joint Photographic Experts Group, un groupe d'experts de l'ISO/CEI qui développe et maintient des normes pour une suite d'algorithmes de compression pour les fichiers image informatiques. Les fichiers JPEG ont généralement l'extension .jpg.

GIF (prononcé JIF par beaucoup, y compris son concepteur ; prononcé GIF avec un G dur par beaucoup d'autres) signifie Graphics Interchange Format. Le GIF utilise le type de données raster 2D et est encodé en binaire. Les fichiers GIF ont généralement l'extension .gif.

PNG (prononcé ping) est un format de fichier pour la compression d'image qui a été conçu pour fournir un certain nombre d'améliorations par rapport au format GIF. Comme un GIF, un fichier PNG est compressé de manière sans perte (ce qui signifie que toutes les informations de l'image sont restaurées lorsque le fichier est décompressé lors de la visualisation). Les fichiers ont généralement l'extension .png.

III.7.3.Traitement d'images

Le traitement d'images consiste à effectuer des opérations sur une image afin de l'améliorer ou d'extraire des informations pertinentes. C'est une sorte de traitement du signal dans lequel l'entrée est une image et la sortie est soit cette image, soit ses caractéristiques ou propriétés. Le traitement d'images est l'une des technologies les plus rapidement évolutives

aujourd'hui. C'est également un domaine de recherche critique en ingénierie et en informatique. Le traitement d'images comprend essentiellement les trois étapes suivantes :

- Importation de l'image via des outils d'acquisition d'images.
- Analyse et manipulation de l'image.
- Sortie dans laquelle le résultat peut être une image modifiée ou un rapport basé sur l'analyse de l'image.

Nous pouvons manipuler et analyser des images en utilisant des algorithmes programmables sur ordinateur, tels que l'amélioration de la qualité de l'image (par exemple, augmentation du contraste de l'image), la détection des contours, la suppression du bruit, etc. Nous pouvons également convertir une image en un ensemble de valeurs numériques pouvant être utilisées ultérieurement pour d'autres tâches, par exemple la classification d'images.




Figure III-4: La détection des contours

III.7.4.Vision par ordinateur

La vision par ordinateur est la science de l'acquisition, du traitement et de l'analyse d'images numériques. La vision par ordinateur vise à imiter automatiquement et idéalement le système visuel humain de manière précise et efficace. Voici les trois niveaux de vision par ordinateur :

- **Vision de bas niveau :** processus d'extraction de caractéristiques de l'image (contours, coins, ou flux optique). Voir Figure III 4.
- **Vision de niveau intermédiaire :** reconnaissance d'objets, analyse du mouvement et reconstruction 3D à l'aide des caractéristiques obtenues à partir de la vision de bas niveau.
- **Vision de haut niveau :** interprétation des informations évolutives fournies par la vision de niveau intermédiaire ainsi que la direction des tâches de vision de niveau intermédiaire et de bas niveau qui doivent être effectuées. L'interprétation peut inclure la description conceptuelle d'une scène comme l'activité, l'intention et le comportement.

III.7.5.Applications de la vision par ordinateur

La vision par ordinateur trouve des applications variées et puissantes dans de nombreux domaines, révolutionnant la manière dont les machines interagissent avec le monde visuel. Voici quelques-unes des principales applications [18] :

III.7.5.1. Détection d'objets

La détection des défauts sur les aubes de turbines à gaz peut être effectuée en utilisant des modèles d'apprentissage profond sur des images capturées par l'instrument de contrôle. Des approches telles que Faster R-CNN, YOLO ou SSD peuvent être utilisées pour une détection précise et en temps réel. Figure III 5.




Figure III-5: Un exemple de détection d'objet

III.7.5.2. Segmentation sémantique

Segmenter les images pour identifier les régions exactes des défauts sur les aubes de turbine à gaz. Des architectures d'apprentissage profond telles que U-Net ou Mask R-CNN peuvent être adaptées à cette tâche. Figure III.6.



Figure III-6: Un exemple de segmentation

III.7.5.3. Classification d'images

En utilisant des réseaux de neurones convolutionnels (CNN), il est possible de classifier les images des aubes de turbine à gaz en différentes catégories de défauts. Le transfert d'apprentissage peut être une approche bénéfique, où des modèles pré-entraînés comme VGG, ResNet ou Inception sont ajustés sur le jeu de données spécifique pour améliorer la classification.

III.7.6. Réseau de neurones

Un réseau de neurones est une technique d'intelligence artificielle qui permet aux ordinateurs de traiter les données de manière similaire au fonctionnement du cerveau humain. L'apprentissage profond, quant à lui, est une méthode spécifique d'apprentissage automatique qui implique l'utilisation de couches de neurones interconnectés pour créer une structure complexe, similaire à celle du cerveau humain. Il génère un système adaptatif que les ordinateurs peuvent utiliser pour apprendre de leurs erreurs et s'améliorer continuellement. Ainsi, les réseaux de neurones artificiels tentent de résoudre des problèmes complexes avec une précision accrue, tels que le résumé de documents ou la reconnaissance faciale.

Le cerveau humain est la source d'inspiration pour l'architecture des réseaux de neurones. Les neurones dans le cerveau humain forment un réseau complexe et hautement interconnecté et envoient des signaux électriques les uns aux autres pour aider les humains à traiter l'information. Un réseau de neurones artificiels, en revanche, est composé de neurones artificiels qui collaborent pour résoudre un problème. Les neurones artificiels sont des modules logiciels appelés nœuds, et les réseaux de neurones artificiels sont des programmes logiciels ou des algorithmes qui résolvent des calculs mathématiques à l'aide de systèmes informatiques.

Les réseaux de neurones peuvent aider les ordinateurs à prendre des décisions intelligentes avec une intervention humaine minimale. C'est parce qu'ils peuvent apprendre et modéliser des relations non linéaires et complexes entre les données d'entrée et de sortie.

Voici quelques exemples d'utilisation des NN :

- Diagnostic médical par classification d'images médicales.
- Marketing ciblé par filtrage des réseaux sociaux.
- Prévisions financières en traitant des données historiques d'instruments financiers.
- Prévision de la charge électrique et de la demande d'énergie
- Contrôle des processus et de la qualité.
- Identification de composés chimiques.

Quatre des applications les plus importantes des réseaux de neurones sont les suivantes :

- **Vision par ordinateur** : La capacité des ordinateurs à extraire des informations et des visions à partir d'images et de vidéos est connue sous le nom de vision par ordinateur. Les ordinateurs peuvent distinguer et reconnaître des images de la même manière que les humains le font.
- **Reconnaissance vocale** : Malgré les différences de modèles de parole, de hauteur, de tonalité, de langue et d'accent, les réseaux de neurones peuvent analyser la parole humaine.

La reconnaissance vocale est utilisée par des assistants virtuels tels qu'Amazon Alexa et des logiciels de transcription automatique pour effectuer des tâches telles que :

- Aider les agents de centres d'appels et classer automatiquement les appels.
 - Convertir les conversations cliniques en documentation en temps réel.
 - Sous-titrer précisément des vidéos et des enregistrements de réunions pour une diffusion de contenu plus large.
- **Traitement du langage naturel** : La capacité à traiter du texte naturel créé par des humains est appelée traitement du langage naturel (NLP). Les réseaux de neurones aident les ordinateurs à extraire du sens et des insights à partir de données textuelles et de documents. Le NLP a plusieurs applications, notamment les suivantes :
- Agents virtuels et chatbots automatisés.
 - Organisation et classification automatiques des données écrites.
 - Analyse de l'intelligence commerciale de documents longs tels que des e-mails et des formulaires.
 - Indexation des expressions clés indiquant le sentiment, comme les commentaires positifs et négatifs sur les réseaux sociaux.
 - Résumé de documents et génération d'articles sur un sujet donné.
- **Moteurs de recommandation** : Pour élaborer des recommandations personnalisées, les réseaux de neurones peuvent suivre l'activité des utilisateurs. Ils peuvent également analyser tous les comportements des utilisateurs pour découvrir de nouveaux produits ou services qui pourraient intéresser un utilisateur particulier. Par exemple, Curalate, une startup basée à Philadelphie, aide les marques à convertir les publications sur les réseaux sociaux en ventes. Le service d'étiquetage de produits intelligent (IPT) de Curalate est utilisé par les marques pour automatiser la collecte et la curation de contenu social généré par les utilisateurs. IPT utilise des réseaux de neurones pour trouver et recommander des produits en fonction de l'activité des utilisateurs sur les réseaux sociaux. Les consommateurs n'ont plus besoin de parcourir des catalogues en ligne pour trouver un produit spécifique basé sur une image sur les réseaux sociaux. Au lieu de cela, ils peuvent utiliser l'étiquetage automatique de produits de Curalate pour acheter rapidement le produit. [12]

III.7.7. Architecture du réseau de neurones

III.7.7.1. Réseau de neurones simple

Un réseau de neurones de base est composé de neurones artificiels interconnectés en trois couches : Figure III.7

- **Couche d'entrée** : La couche d'entrée est l'endroit où les informations provenant du monde extérieur entrent dans le réseau de neurones artificiels. Les nœuds d'entrée traitent les données, les analysent ou les catégorisent, puis les transmettent à la couche suivante.

- **Couche cachée :** La couche d'entrée ou d'autres couches cachées fournissent des données aux couches cachées. Un grand nombre de couches cachées peuvent exister dans les réseaux de neurones artificiels. Chaque couche cachée analyse la sortie de la couche précédente, la traite davantage, puis la transmet à la couche suivante.
- **Couche de sortie :** La couche de sortie affiche le résultat final du traitement des données par le réseau de neurones artificiels. Elle peut comporter un ou plusieurs nœuds. Par exemple, si nous avons un problème de classification binaire (oui/non), la couche de sortie aura un nœud de sortie qui renverra une valeur de 1 ou 0. Dans le cas d'un problème de classification multi-classes, la couche de sortie peut inclure plus d'un nœud de sortie.[12]




Figure III-7: Un réseau de neurones simple

III.7.7.2. Architecture des réseaux de neurones profonds

Les réseaux de neurones profonds, également connus sous le nom de réseaux d'apprentissage profond, sont constitués de plusieurs couches cachées reliées entre elles par des millions de neurones artificiels. Figure III.8. Les connexions entre les nœuds sont représentées par un nombre appelé poids. Si un nœud excite un autre, le poids est positif ; si un nœud supprime un autre, le poids est négatif. Les nœuds avec des valeurs de poids plus élevées ont une plus grande influence sur les autres nœuds.

Les réseaux de neurones profonds peuvent théoriquement mapper n'importe quel type d'entrée vers n'importe quel type de sortie. Cependant, ils nécessitent significativement plus d'entraînement que d'autres méthodes d'apprentissage automatique. Ils nécessitent des millions d'exemples de données d'entraînement plutôt que les centaines ou milliers nécessaires par un réseau plus simple.




Figure III-8: Un réseau de neurones profond

III.8.Apprentissage profond

L'intelligence artificielle est une branche de l'informatique qui étudie comment donner aux machines la capacité d'effectuer des tâches qui nécessitent l'intelligence humaine. L'apprentissage automatique est une technique d'intelligence artificielle qui permet aux ordinateurs d'accéder à des ensembles de données massifs et de les entraîner à apprendre à partir d'eux. Les logiciels d'apprentissage automatique découvrent des motifs dans les données existantes et les appliquent à de nouvelles données pour prendre des décisions intelligentes. L'apprentissage profond est un sous-ensemble de l'apprentissage automatique qui traite les données à l'aide de réseaux d'apprentissage profond.




Figure III-9: Apprentissage automatique vs Apprentissage profond

Les méthodes traditionnelles d'apprentissage automatique nécessitent l'intervention humaine pour que le logiciel d'apprentissage automatique fonctionne correctement. Un data

scientist sélectionne manuellement l'ensemble des caractéristiques pertinentes à analyser par le logiciel. Cela limite les capacités du logiciel, rendant la création et la gestion difficiles. Figure III-10

En revanche, dans l'apprentissage profond, le data scientist ne fournit que des données brutes au logiciel. Le réseau d'apprentissage profond génère lui-même les caractéristiques et apprend de manière plus autonome. Il est capable d'analyser des ensembles de données non structurés tels que des documents textuels, de déterminer quels attributs de données prioritaires et de résoudre des problèmes plus complexes.[12]




Figure III-10: Relation entre l'IA, le ML et le DL

III.9.Réseau de neurones convolutionnels (CNN)

Le Réseau de neurones convolutionnels (CNN) est un type de modèle de réseau neuronal créé pour travailler avec des données d'images bidimensionnelles, bien qu'il puisse également être utilisé avec des données unidimensionnelles et tridimensionnelles.

La meilleure performance des réseaux neuronaux convolutionnels avec des entrées d'images, de voix ou de signaux audio les distingue des autres réseaux neuronaux. Ils sont divisés en trois types de couches :

- Couche convolutive
- Couche de pooling
- Couche entièrement connectée (FC)

Certains des modèles CNN les plus connus :

- **VGG16** : composé de 16 couches. (Le modèle pris dans notre étude)
- **ResNet50** : composé de 50 couches.
- **LeNet**: composé de 7 couches.
- **GoogleNet** : composé de 22 couches.
-

III.10. Architecture du réseau neuronal convolutif

Le CNN est composé de nombreuses couches empilées, les premières étant des couches de convolution et de pooling, suivies de couches entièrement connectées et de couches softmax. Chacune de ces couches est décrite en détail dans les sections suivantes.

III.10.1. Couche de convolution

La couche convolutive, qui donne son nom au réseau, est au cœur du réseau neuronal convolutif. Cette couche effectue un processus appelé "convolution".

Une convolution est un processus linéaire dans un réseau neuronal convolutif qui implique la multiplication d'un ensemble de poids avec l'entrée, similaire à un réseau neuronal standard. La multiplication se fait entre un tableau de données d'entrée et un tableau bidimensionnel de poids, appelé filtre ou noyau. Figure III-11




Figure III-11: L'opération de convolution

Le filtre est plus petit que les données d'entrée et le type de multiplication appliqué entre un patch de la taille du filtre de l'entrée et le filtre est appelé produit scalaire. Un produit scalaire est la multiplication élément par élément du patch de la taille du filtre de l'entrée et du filtre, puis leur somme, donnant toujours une seule valeur. L'opération est souvent appelée "produit scalaire" car elle produit une seule valeur.




Figure III-12: Opération de convolution à plus grande échelle

Il est intentionnel d'utiliser un filtre plus petit que l'entrée car cela permet au même filtre (ensemble de poids) d'être multiplié par le tableau d'entrée plusieurs fois à différents points de l'entrée. De gauche à droite, de haut en bas, le filtre est appliqué systématiquement à chaque section superposée ou patch de taille de filtre des données entrantes. Figure III-12

- Le résultat de la multiplication du filtre une fois avec le tableau d'entrée est une seule valeur. Lorsque le filtre est appliqué au tableau d'entrée plusieurs fois, le résultat est un tableau bidimensionnel de valeurs de sortie représentant le filtrage de l'entrée. Par conséquent, le tableau de sortie bidimensionnel de cette opération est appelé "carte des caractéristiques". Figure III-13. Cette couche possède certains paramètres à ajuster, qui sont :
- Le nombre de filtres affecte la profondeur de la sortie. Par exemple, trois filtres distincts produiraient trois cartes de caractéristiques différentes, créant une profondeur de trois.
- Le padding zéro est généralement utilisé lorsque les filtres ne correspondent pas à l'image d'entrée. Cela fixe tous les éléments qui se trouvent en dehors de la matrice d'entrée à zéro, produisant une sortie de taille égale ou supérieure. Il existe trois types de padding :
 - **Valid padding** : Aussi appelé pas de padding. Dans ce cas, la dernière convolution est abandonnée si les dimensions ne s'alignent pas.
 - **Same padding** : Ce padding garantit que la couche de sortie a la même taille que la couche d'entrée.
 - **Full padding** : Ce type de padding augmente la taille de la sortie en ajoutant des zéros au bord de l'entrée.

Le pas (stride) est la distance, ou le nombre de pixels, que le noyau parcourt sur la matrice d'entrée. Bien que des valeurs de pas de deux ou plus soient rares, un pas plus grand produit une sortie plus petite.




Figure III-13: Un exemple de carte des caractéristiques

Une fois qu'une carte des caractéristiques est créée, nous pouvons passer chaque valeur de la carte des caractéristiques à travers une non-linéarité, telle qu'une ReLU, tout comme nous le faisons pour les sorties d'une couche entièrement connectée. [13]

III.10.2.Couche de Pooling

La réduction de dimension, également appelée couches de pooling, est une technique de réduction de la dimensionnalité qui réduit le nombre de facteurs dans l'entrée. Le processus de pooling balaye un filtre sur l'ensemble de l'entrée, similaire à la couche de convolution, cependant ce filtre n'a pas de poids. Au lieu de cela, le noyau utilise une fonction d'agrégation pour remplir le tableau de sortie à partir des valeurs dans le champ récepteur. Le pooling peut être divisé en deux catégories :

- **Max pooling** : Lorsque le filtre se déplace à travers l'entrée, il sélectionne le pixel ayant la valeur maximale à envoyer dans le tableau de sortie. En passant, cette approche est généralement utilisée plus souvent par rapport au pooling moyen. Figure III-14
- **Average pooling** : Lorsque le filtre se déplace à travers l'entrée, il calcule la valeur moyenne dans le champ récepteur pour l'envoyer dans le tableau de sortie.




Figure III-14: Opération de max pooling

Bien que beaucoup d'informations soient perdues dans la couche de pooling, elle présente également plusieurs avantages pour le CNN. Ils aident à réduire la complexité, à améliorer l'efficacité et à limiter le risque de surajustement.[13]

III.10.3.Rectified Linear Units layer (ReLU)

Dans cette couche, une fonction élémentaire basée sur zéro ($\max(0, x)$) est appliquée aux valeurs de seuil, préservant les valeurs positives tout en convertissant les valeurs négatives en zéro. Figure III-15




Figure III-15: ReLU fonction d'activation

III.10.4.La couche entièrement connectée (FC Layer)

Cette couche effectue des tâches de classification basées sur les caractéristiques récupérées par les couches précédentes et leurs différents filtres. Alors que les couches de convolution et de pooling utilisent souvent des fonctions ReLU pour catégoriser les entrées, les couches FC (Fully Connected) utilisent généralement une fonction d'activation SoftMax pour fournir une probabilité de 0 à 1. Figure III-16




Figure III-16: Couche entièrement connecté

L'architecture complète du CNN ressemble à ce qui suit. Figure III-17




Figure III-17: CNN architecture

III.11.Modèles d'apprentissage profond pour l'analyse des aubes de turbine à gaz

III.11.1.Introduction

Les réseaux neuronaux convolutionnels (CNN) ont démontré leur puissante capacité en reconnaissance et classification d'images.

Le but de cette partie du chapitre est de fournir un aperçu de notre méthode proposée, puis nous expliquerons chaque composant séparément.

III.11.2.Méthode proposée

La méthode proposée peut être divisée en cinq phases : l'entraînement, l'augmentation des données et le transfert d'apprentissage. Enfin, la manipulation de l'ensemble de données, Dans ce qui suit, nous présentons chaque étape.

III.11.2.1. Entraînement

Cette étape peut être résumée comme suit :

Utilisation du modèle pré-entraîné VGG16 avec les poids "ImageNet" et entraînement avec les images des aubes de turbine à gaz défectueuses.

III.11.2.2. Entraînement avec augmentation des données

Cette étape peut être résumée comme suit :

- Utilisation du module de prétraitement de Keras pour effectuer quatre fonctions sur nos images originales, voir Figure III-18 : Redimensionner, coupe, zoom, retournement horizontal
- Ré-entraînement de nos modèles avec les nouvelles données




Figure III-18: Échantillons d'augmentation de données

III.11.2.3. Modèle VGG16

VGG signifie Visual Geometry Group, c'est une architecture de réseau neuronal convolutionnels (CNN) multicouche profonde. Le terme "profond" fait référence au nombre de couches dans VGG-16, qui comporte respectivement 16 couches convolutionnelles. Voir l'architecture VGG16 sur la Figure III-20




Figure III-19 : VGG16 architecture

L'architecture VGG constitue la base des modèles de reconnaissance d'objets de pointe. VGGNet, conçu comme un réseau neuronal profond, dépasse les performances des modèles de référence sur diverses tâches et ensembles de données, y compris ImageNet. De plus, elle reste l'une des architectures de reconnaissance d'images les plus couramment utilisées aujourd'hui. Figure III-21




Figure III-20: Le processus VGG16

Le modèle VGG, ou VGGNet, qui comporte 16 couches, est également désigné sous le nom de VGG16. Il s'agit d'un modèle de réseau neuronal convolutif proposé par A. Zisserman et K. Simonyan de l'Université d'Oxford. [14].

Le modèle VGG16 atteint une précision de test top-5 de presque 92,7% sur ImageNet. **ImageNet** est un ensemble de données composé de plus de 14 millions d'images appartenant à près de 1000 classes.

De plus, c'est l'un des modèles les plus populaires. Il remplace les filtres de grande taille par plusieurs filtres de taille 3*3 l'un après l'autre. Comme mentionné précédemment, le VGGNet-16 comporte 16 couches et peut catégoriser les photos en 1000 catégories d'articles différentes, telles que les claviers, les animaux, les crayons et les souris. De plus, le modèle utilise une taille d'image d'entrée de 224 par 224.

III.11.2.4. Apprentissage par transfert

L'apprentissage par transfert est une technique d'apprentissage automatique où les connaissances acquises pour résoudre un problème sont appliquées à un autre problème différent mais connexe. C'est efficace, surtout avec l'apprentissage profond. Des modèles pré-entraînés sont utilisés pour résoudre de nouvelles tâches plus rapidement, et l'apprentissage par transfert est catégorisé en types inductif, transductif et non supervisé. Il offre des avantages tels qu'une efficacité accrue, une accessibilité accrue et des performances améliorées. L'apprentissage par transfert est appliqué dans divers domaines, tels que les sciences cognitives, la découverte des sous-types de cancer et la classification de texte.

III.12. Conclusion

En conclusion, ce chapitre a démontré l'importance des données synthétiques pour surmonter le manque et les limitations des données réelles et les préoccupations de confidentialité sur les rapports d'inspection et de diagnostic dans l'analyse des aubes de turbine à gaz. Le recours à l'utilisation de Blender pour la création de modèles 3D et la génération d'images synthétiques s'est révélé efficace et indispensable en termes de coûts et de temps. Nous avons également présenté les concepts et technologies clés, tels que la vision par ordinateur et les réseaux de neurones, qui soutiennent cette approche.

Les modèles d'apprentissage profond, notamment les CNN et le modèle VGG16, ont été discutés pour leur rôle crucial dans l'amélioration de la détection et de la classification des défauts des aubes de turbine à gaz.

CHAPITRE IV :

RESULTATS ET

INTERPRETATION

IV.RESULTATS ET INTERPRETATION

IV.1.Introduction

Ce chapitre est dédié à la présentation de nos résultats après avoir effectué toutes les étapes mentionnées ci-dessus au chapitre précédent. Nous commençons à présenter l'ensemble des données créées par simulation par le logiciel Blender sur lesquels l'application d'entraînement de nos modèles sont réalisées, puis nous rendons compte des résultats expérimentaux.

IV.2.Protocole de modélisation

IV.2.1.Présentation des données

Nous menons nos expériences sur le jeu de données des aubes défectueuses. Il est composé de 662 images des aubes défectueuses (199 rayures, 182 fractures, 178 fissures et 108 corrosions).

La Figure IV-1 illustre des échantillons de data des aubes avec des rayures, la Figure IV-2 illustre des échantillons des aubes avec des fractures, la Figure IV-4 illustre des échantillons des aubes avec des fissures et enfin la Figure IV-3 illustre des échantillons des aubes avec de la corrosion.



Figure IV-1: Aubes avec des fissures




Figure IV-2: Aubes avec des rayures




Figure IV-3: Aubes avec corrosion




Figure IV-4: Aubes avec fractures

IV.2.2.Métriques de performance

Pour mesurer la performance du système proposé, la métrique de précision (Accuracy) est adoptée. La précision est définie comme suit :

$$\frac{\text{Nombre d'échantillons correctement classifiés}}{\text{Nombre d'images}}$$

IV.3.Résultats

Dans cette partie de ce chapitre nous visons à fournir une analyse approfondie de la classification des défauts des aubes en utilisant des techniques d'apprentissage approfondies. Pour cela, nous allons suivre le plan des méthodes et des étapes suivantes. Figure IV-5.




Figure IV-5 : Organigramme étape d'application de l'apprentissage profond

IV.3.1.Premier cas : Modèle utilisé (CNN) avec architecture simple

Dans le cas de ce modèle, nous rapportons les résultats d'entraînement obtenus par le modèle CNN simple utilisant uniquement le jeu de données simulées (662 images). Le Tableau IV-1 montre les performances du modèle utilisé. La Figure IV-5 montre la tendance de la précision et de la perte tout au long de l'entraînement.

Table IV-1: Résultats du modèle simple

/	Modèle CNN simple
Précision	99.7%
Perte d'entraînement	0.69




Figure IV-6: Performance du modèle CNN simple

À partir des résultats figurés au tableau et des figures ci-dessus, nous observons ce qui suit :

- Notre modèle dans ce cas présente des valeurs de précision et de perte parfaite (99,7 %) et (0.69) respectivement, ce qui signifie que notre modèle est parfaitement entraîné.
- Le modèle a atteint 99,7 % de précision sur les données d'entraînement à partir de la 15^{ème} itération sur 30 époques.

IV.3.2. Deuxième cas : Utilisation du modèle CNN simple et de l'augmentation des données

Dans ce cas, nous rapportons les résultats obtenus en utilisant le même modèle (CNN). Nous augmentons le nombre d'images générées à 2648 images et cela par les opérations suivantes : redimensionnement ; cisaillement ; zoom et renversement) en se basant sur la bibliothèque KERAS. Le Tableau IV-2 montre les performances du modèle utilisé. La Figure IV-6 montre la tendance de la précision et de la perte lors de l'entraînement par VGG16.

Table IV-2: Résultats du modèle CNN simple avec augmentation des données

/	Modèle CNN simple avec augmentation des données
Précision	96.30%
Perte d'entraînement	0.1042




Figure IV-7: Performance du modèle CNN simple avec augmentation des

À partir du tableau et des figures ci-dessus, nous observons ce qui suit :

- La technique d'augmentation des données ici montre moins de précision des valeurs de performance d'entraînement, **96.30 %** et **0.1042** de précision et de perte respectivement, par rapport aux résultats obtenus par le modèle CNN sans augmentation de données.
- Le modèle a atteint **96.30 %** de précision sur les données d'entraînement à 30 époques.
- Cette technique a montré un comportement de convergence plus régulier et avantageux avec moins de fluctuation dans la perte et une amélioration plus rapide de la précision.




Figure IV-8: Un échantillon des résultats de visualisation de la deuxième expérience

Cette figure ci-dessus montre le résultat de prédiction utilisant le modèle CNN simple pour un cas d'aube choisi aléatoirement à partir des données de test. Le tableau en haut sous forme de matrice (1x4) représente la réponse de notre modèle de réseau neuronal pour une seule image d'entrée.

- La matrice a une forme (1x4), indiquant un échantillon avec quatre classes de 0 à 3.
- Chaque élément de la matrice représente la probabilité du modèle pour chaque classe.
- Les classes sont généralement disposées dans le même ordre que les étiquettes utilisées lors de l'entraînement.

Voici un décompte du tableau :

- Premier élément :
Probabilité que l'image appartienne à la classe 0 "corrosion" : environ 0,00007681
- Deuxième élément :
Probabilité que l'image appartienne à la classe 1 "fissure" : environ 0,7895
- Troisième élément :
Probabilité que l'image appartienne à la classe 2 "fracture" : environ 0,2104
- Quatrième élément :
Probabilité que l'image appartienne à la classe 3 "rayure" : environ 5,180e-11

Dans ce cas spécifique, le modèle a prédit que l'image d'entrée appartient à la classe 1 "fissure" avec la plus grande probabilité (0,7895).

IV.3.3.Troisième cas : Utilisation du modèle VGG16 sans l'augmentation des données

Dans le cas de ce modèle, nous rapportons les résultats d'entraînement obtenus en utilisant le modèle VGG16 pré-entraîné sans de l'augmentation des données avec les mêmes images de jeu de données pour le premier cas. Le Tableau IV-3 montre les valeurs de performance du modèle d'entraînement et de validation. Les Figures IV-8 et IV-9 montrent la tendance des performances du modèle utilisé lors de l'entraînement et de validation par ce modèle (VGG16 pré-entraîné).

Table IV-3: Résultats du modèle VGG16 pré-entraîné

/	Modèle CNN pré-entraîné
Précision d'entraînement	99.4%
Précision de validation	100%
Perte d'entraînement	0.0132
Perte de validation	0.0001




Figure IV-9: Performances du modèle VGG16 pré-entraîné sur 850 époques




Figure IV-10: Performances du modèle VGG16 pré-entraîné sur les 50 dernières époques
À partir du tableau et des figures ci-dessus, nous observons ce qui suit :

IV.3.3.1. Précision

- Nous pouvons également constater que la précision et la perte ont des valeurs parfaites, ce qui signifie que notre modèle classe parfaitement les données.
- Le modèle a atteint 99,4 % et 100 % de précision sur les données d'entraînement et de validation respectivement pendant 850 époques avec des pertes de **0.0132** et 0,0001 d'entraînement et de validation respectivement.
- Nous pouvons voir aussi que la perte chute presque jusqu'au zéro absolu, ce qui pourrait être dû au grand nombre d'époques, démontrant ainsi la puissance de VGG16 dans la classification et la généralisation des données.
- Le CNN fondé sur VGG16 dans ce cas a montré de meilleures performances que le CNN ajusté en termes de perte.

```
42/42 [=====] - 2s 55ms/step - loss: 0.0132 - accuracy: 0.9948
3/3 [=====] - 0s 8ms/step - loss: 1.1988e-04 - accuracy: 1.000
[INFO] accuracy: 100.00%
[INFO] Loss: 0.00011988357437076047
```

Figure IV-11: Image provenant du notebook Jupyter montrant les résultats de performance par le modèle VGG16

IV.3.3.2. Temps d'entraînement

- Cela a nécessité 50 minutes pour converger.

IV.3.3.3. Comportement de convergence

- Le CNN basé sur VGG16 a montré un comportement de convergence plus lisse avec moins de fluctuation dans la perte et une amélioration plus rapide de la précision.

IV.3.3.4. Remarque

Des baisses de précision après avoir atteint un pic, suivies de fluctuations lors des époques suivantes, peuvent être causées par divers facteurs liés à l'entraînement ou aux données. Voici trois raisons possibles pour ce comportement :

- **Surajustement**

Initialement, le modèle peut avoir appris à ajuster les données d'entraînement de manière extrêmement précise, ce qui entraîne une précision élevée. Cependant, à mesure que l'entraînement progresse, le modèle commence à mémoriser le bruit ou les caractéristiques spécifiques des données d'entraînement qui ne se généralisent pas bien aux données invisibles. Cela entraîne une diminution de la précision sur l'ensemble de validation/test, indiquant un surajustement. FigureIV-11




Figure IV-12: Explication visuelle du surajustement pour les cas de classification

- **Taux d'apprentissage**

Si le taux d'apprentissage est trop élevé, l'algorithme d'optimisation pourrait dépasser la solution optimale, entraînant des oscillations ou une instabilité dans le processus d'entraînement. Ajuster le calendrier des taux d'apprentissage ou utiliser des méthodes adaptatives de taux d'apprentissage comme Adam peut aider à stabiliser le processus d'entraînement.




Figure IV-13: Explication visuelle des différents cas du taux d'apprentissage

- **Complexité du modèle**

Le modèle peut être trop complexe pour le jeu de données donné, ce qui peut entraîner un surajustement. Simplifier l'architecture du modèle ou utiliser des techniques de régularisation telles que le dropout ou la décroissance des poids peut aider à atténuer le surajustement.[15]

IV.3.4. Test du modèle

Dans cette étape, nous visons à évaluer les capacités de généralisation et la puissance prédictive du modèle CNN basé sur VGG16 entraîné. La généralisation fait référence à la capacité du modèle à bien se comporter sur des données non vues par le modèle, ce qui est crucial pour son utilité pratique. En évaluant les performances du modèle sur un ensemble séparé d'images non pas été vues encore par le modèle, nous pouvons évaluer sa capacité à généraliser au-delà des données d'entraînement de simulation (données synthétiques) et à faire des prédictions précises dans des scénarios du monde réel.

IV.3.4.1. Méthodologie

Pour évaluer les performances de généralisation du modèle, nous utilisons le CNN basé sur VGG16 entraîné pour prédire des classes d'images non vues par le modèle (aubes de turbine avec des défauts de cas réels) qui n'ont pas été utilisées lors du processus d'entraînement. Ces images non vues par le modèle servent de représentation d'un échantillon de données du monde réel que le modèle rencontrera dans des applications pratiques. Nous analysons les performances du modèle en évaluant ses prédictions par rapport aux étiquettes de cas réel. Figure IV-13

Voilà quelques exemples d'images réelles non vues par le modèle de prédiction parmi l'ensemble des images de test (15 étiquettes).



Figure IV-14: Échantillons d'images non vues par le modèle
IV.3.4.2. Résultats de données réelles

- **Généralisation du modèle**

Le CNN basé sur VGG16 a démontré des capacités de généralisation robustes, atteignant une précision élevée sur l'ensemble de test.

Cela indique que les caractéristiques prises par le modèle VGG16 sur ImageNet sont transférables et applicables à la tâche de classification des défauts des aubes.

L'évaluation de la puissance prédictive du modèle implique plusieurs métriques clés :

IV.3.4.3. Précision

Nous calculons la précision de la prédiction du modèle testé sur la base d'images non vues par le modèle, qui mesure la proportion d'images correctement classées par rapport au nombre total d'images. Dans ce cas, le résultat de précision du test est d'environ 73,33 %. Figure IV-14.

Interprétation :

- Ce comportement montre que ce modèle a réussi à distinguer efficacement entre les différentes classes de défauts des aubes et s'est bien généralisé aux données non vues. Sur les 15 prédictions faites par le modèle, environ 11 prédictions correspondent aux étiquettes réelles, c.à.d. classées correctement (y_{true})

```
print("Accuracy:", accuracy)
```

Accuracy: 0.7333333333333333

Figure IV-15: La précision du modèle pour la prédiction de 15 images sur lesquelles il n'a pas été entraîné.

IV.3.4.4. Matrice de confusion (Confusion Matrix)

Nous construisons une matrice de confusion pour visualiser la distribution des classes prédites par rapport aux classes réelles. Cette matrice fournit des informations sur les types d'erreurs commises par le modèle, telles que les mauvaises classifications ou les confusions entre certaines classes.[16]

Dans ce scénario, la matrice de confusion est générée en fonction des étiquettes réelles (y_{true}) et des étiquettes prédites (y_{pred}). Chaque ligne dans la matrice de confusion représente les instances des classes réelles, tandis que chaque colonne représente les instances des classes prédites. Figure IV-15




Figure IV-16: Matrice de confusion visualisant la distribution des classes prédites par rapport aux classes réelles.

L'interprétation de la matrice de confusion :

- **Corrosion (classe 0) :**

- Prédit comme corrosion : 3 fois (prédictions correctes)
- Prédit comme fissure : 0 fois
- Prédit comme fracture : 0 fois
- Prédit comme rayure : 0 fois

- **Fissure (classe 1) :**

- Prédit comme corrosion : 0 fois
- Prédit comme fissure : 0 fois
- Prédit comme fracture : 1 fois (mal classé)
- Prédit comme rayure : 0 fois

- **Fracture (classe 2) :**

- Prédit comme corrosion : 2 fois (mal classé)
- Prédit comme fissure : 0 fois
- Prédit comme fracture : 5 fois (prédictions correctes)
- Prédit comme rayure : 0 fois

- **Rayure (classe 3) :**

- Prédit comme corrosion : 0 fois
- Prédit comme fissure : 0 fois
- Prédit comme fracture : 1 fois (mal classé)
- Prédit comme rayure : 3 fois (prédictions correctes)

IV.3.4.5. Points Clés

- Éléments diagonaux (3, 0, 5, 3) représentent le nombre de prédictions correctes pour chaque classe.
- Éléments hors diagonale représentent les erreurs de classification.
 - Par exemple, le modèle a prédit "fracture" 1 fois au lieu de "fissure" et 1 fois au lieu de "rayure".
 - Le modèle a également prédit "corrosion" 2 fois au lieu de "fracture".

IV.3.4.6. Précision et Rappel

La précision mesure la proportion des prédictions vraies positives parmi toutes les prédictions positives, tandis que le rappel mesure la proportion des prédictions vraies positives parmi toutes les instances positives réelles. Ces métriques fournissent une compréhension plus détaillée de la performance du modèle pour chaque classe et peuvent aider à identifier les domaines à améliorer.

Précision = Vrais positifs / (Vrais positifs + Faux positifs)

Rappel = Vrais positifs / (Vrais positifs + Faux négatifs)

Table IV-4: Tableau représentant la précision et le rappel par classe

Classe	Précision	Rappel
Corrosion	0.60	1.00
Fissure	0.00	0.00
Fracture	0.71	0.71
Rayure	1.00	0.75

Voici une observation pour chaque classe basée sur les résultats de précision et de rappel :

- **Classe Corrosion :**

La précision est de 0.6 et le rappel est de 1. Cela signifie que lorsque le modèle prédit une corrosion, il est correct 60% de cas, et il parvient à saisir toutes les occurrences réelles de corrosion dans le jeu de données.

- Vrais Positifs (VP) : 3 (le modèle a prédit corrosion et c'était vraiment corrosion)
- Faux Positifs (FP) : 2 (le modèle a prédit corrosion alors que ce n'était pas le cas, par exemple, il y a eu 2 fractures prédites comme corrosion)
- Vrais Négatifs (VN) : Les images qui ne sont pas corrosion et que le modèle n'a pas prédites comme corrosion.
- Faux Négatifs (FN) : 0 (pas de cas où c'était vraiment corrosion mais le modèle n'a pas prédit corrosion)

- **Classe Fissure :**

La précision est de 0 et le rappel est de 0. Cela indique que le modèle n'a pas réussi à détecter correctement les fissures dans le jeu de données, ne prédisant aucune véritable occurrence de fissure.

- Vrais Positifs (VP) : 0 (le modèle n'a jamais prédit fissure correctement)
- Faux Positifs (FP) : 0 (le modèle n'a jamais prédit fissure incorrectement)

- Vrais Négatifs (VN) : Toutes les autres instances correctement prédites comme non fissure
- Faux Négatifs (FN) : 1 (il y a eu 1 fissure réelle qui a été prédite comme fracture)

- **Classe Fracture :**

La précision est de 0.71 et le rappel est de 0.71. Cela signifie que lorsque le modèle prédit une fracture, il est correct 71% de cas, et il est également capable de capturer 71% des vraies fractures présentes dans le jeu de données.

- Vrais Positifs (VP) : 5 (le modèle a prédit fracture et c'était vraiment fracture)
- Faux Positifs (FP) : 1 (il y a eu 1 rayure prédite comme fracture)
- Vrais Négatifs (VN) : Toutes les autres instances correctement prédites comme non fracture
- Faux Négatifs (FN) : 2 (il y a eu 2 fractures réelles prédites comme corrosion)

- **Classe Rayure :**

La précision est de 1 et le rappel est de 0.75. Cela indique que le modèle prédit correctement toutes les éraflures dans le jeu de données, avec une précision de 100%, mais il ne parvient à en capturer que 75%.

- Vrais Positifs (VP) : 3 (le modèle a prédit rayure et c'était vraiment rayure)
- Faux Positifs (FP) : 0 (le modèle n'a jamais prédit rayure incorrectement)
- Vrais Négatifs (VN) : Toutes les autres instances correctement prédites comme non rayure
- Faux Négatifs (FN) : 1 (il y a eu 1 rayure réelle prédite comme fracture)

IV.3.4.7. F1 Score

Le score F1 est la moyenne harmonique de la précision et du rappel de la formule ci-dessous, fournissant une seule métrique qui équilibre les deux aspects de la performance du modèle. Un score F1 plus élevé indique une meilleure performance globale en termes de précision et de rappel.

$$m = \frac{n}{\frac{1}{x_1} + \dots + \frac{1}{x_n}}$$

Avec :

m : moyenne harmonique

n = nbre de moyenne existant = 2

x₁ : rapport de précesion

x₂ : rapport du rappel




Figure IV-17: Distribution du score F1 pour chaque classe

Observation des résultats et de la figure :

La distribution des scores F1 pour chaque classe fournit des informations précieuses sur la performance du modèle dans différentes catégories. La figure représente visuellement les scores F1 pour chaque classe, avec des barres indiquant la valeur du score F1. Cette représentation visuelle permet une comparaison rapide de la performance entre les classes.

En observant les scores F1, nous remarquons que la classe 'Rayures' au score F1 le plus élevé, ce qui indique un excellent équilibre entre la précision et le rappel pour cette classe. En revanche, la classe 'fissure' a le score F1 le plus bas, suggérant une mauvaise performance du modèle dans la prédiction correcte des instances de 'fissure'.

L'analyse du score F1 met en évidence les domaines où le modèle se comporte bien (par exemple, la classe 'rayures') et les domaines qui nécessitent des améliorations (par exemple, la classe 'fissure'). Ces informations peuvent guider les efforts supplémentaires de raffinement et d'optimisation du modèle.[17]

IV.4.Conclusion

En conclusion, ce chapitre a fourni une analyse approfondie de la classification des défauts des aubes en utilisant des techniques d'apprentissage approfondies. Nous avons évalué à la fois les modèles de prédiction CNN simple (avec et sans data set augmentées) et le modèle VGG16 pré-entraînés sur les données d'aubes qui présentant des défauts.

Le modèle CNN simple sans data augmentation a atteint une précision exceptionnelle de 99,7 % sur les données d'entraînement dans le premier cas. Cependant, l'augmentation de données n'a pas amélioré de manière significative les performances. En revanche, le modèle VGG16 pré-

entraîné a donné des résultats impressionnants, atteignant une précision de 99,4 % sur 850 époques.

Une analyse supplémentaire a démontré les capacités de généralisation du modèle VGG16, avec une précision de validation de 73,33 % de test sur des images réelles. Bien que le modèle ait montré des performances globalement robustes, il y avait des domaines à améliorer, notamment dans la prédiction des instances de 'fissure'. Les évaluations de la précision, du rappel et du score F1 ont fourni des informations précieuses sur la performance du modèle dans différentes classes de défauts. Alors que la classification 'rayures' excédait, la prédiction des 'fissures' n'était pas bien prédite, indiquant la nécessité d'affiner le modèle.

Dans l'ensemble, ce chapitre montre l'efficacité de l'apprentissage profond dans la classification des défauts des aubes en mettant en évidence les domaines de recherche et d'optimisation supplémentaires dans des applications du monde réel.

CONCLUSION GENERALE

En conclusion, cette étude a abordé la question de l'inspection et de la maintenance des aubes de turbine à gaz à travers l'exploration de techniques avancées telles que l'apprentissage approfondi. La sécurité de fonctionnement des turbines à gaz est primordiale dans divers secteurs, et assurer leur fiabilité et leur longévité exige des protocoles d'inspection complets.

Tout au long de cette étude, différentes méthodes d'inspection des aubes de turbine à gaz ont été discutées, notamment les méthodes de contrôle non destructif (CND). Bien que ces méthodes offrent des avantages uniques, des défis tels que la détection des défauts au niveau des bords persiste. En réponse, des approches innovantes telles que la thermographie pour la détection des défauts au niveau des bords et l'Inspection par Boroscope ont été explorées.

L'étude s'est également penchée sur l'application des techniques d'apprentissage approfondi (DL) pour la détection et la classification des dommages aux aubes de turbine à gaz. En exploitant les capacités d'apprentissage approfondi en matière d'extraction de caractéristiques et de reconnaissance d'objets, l'étude a évalué les performances du réseau profond par CNN les réseaux de neurones convolutionnels et particulièrement le VGG16 pour la classification des défauts. De plus, l'impact de l'augmentation des données sur les performances du réseau a été analysé pour améliorer la précision et l'efficacité de la détection. Une des principales contributions de ce travail est la génération de données synthétiques à l'aide de Blender, simulant avec précision divers défauts des aubes de turbine à gaz.

De plus, les résultats de prédiction ont démontré l'efficacité des modèles d'apprentissage profond dans la classification des défauts des aubes. Le modèle CNN simple sans augmentation a atteint une précision exceptionnelle de 99,7 % sur les données d'entraînement, tandis que le modèle VGG16 pré-entraîné a présenté des performances impressionnantes avec une précision de 99,4 % sur 850 époques .

En exploitant des techniques avancées à la génération de données synthétiques, les opérateurs peuvent améliorer leur capacité à identifier et à atténuer les dommages aux aubes, contribuant ainsi à la sécurité et à la fiabilité des opérations de turbines à gaz.

Comme perspective et recommandation nous proposons de continuer dans ce travail et d'ajouter l'option segmentation qui permet de localiser et entourer les défaut en temps réel et d'intégrer ces algorithmes dans le Boroscope .

ANNEXE I

BIBLIOTHÈQUES PYTHON

```
import tensorflow as tf
import matplotlib.pyplot as plt
import glob
import os
import cv2
import math
from keras import applications
from keras.models import Sequential
from keras.layers import Conv2D, MaxPooling2D, Convolution2D, Activation,
Flatten, Dense, Dropout, MaxPool2D, BatchNormalization
from keras.utils import to_categorical
from keras.preprocessing.image import ImageDataGenerator
import numpy as np
import pandas as pd
from sklearn.metrics import accuracy_score, confusion_matrix, precision_score,
recall_score, f1_score
import seaborn as sns
```

ANNEXE II

VGG16 DEEP NETWORK

```
model = applications.VGG16(include_top=False, weights='imagenet')
model.summary()

Model: "vgg16"
```

BIBLIOGRAPHIE

- [1] Gas turbine blades - Grafiati. Mar 10, 2023. Repéré à : <https://www.grafiati.com/en/literature-selections/gas-turbine-blades/>
- [2] The Evolution of Gas Turbines from the First Designs to the Latest Environmentally Friendly Development Trends - Part 1-SoftInWay. April 19, 2022. Repéré à : <https://blog.softinway.com/the-evolution-of-gas-turbines-from-the-first-designs-to-the-latest-environmentally-friendly-development-trends-part-1/>
- [3] Gas Turbine Blade Design and Classification - Grafiati. Mar 15, 2023. Repéré à : <https://www.grafiati.com/en/literature-selections/gas-turbine-blade-design-classification/>
- [4] Reed, R. C. (2006). The Superalloys: Fundamentals and Applications. Cambridge University Press.
- [5] Clarke, D. R., & Levi, C. G. (2003). Materials Design for the Turbine Engine Thermal Barrier Coating System. MRS Bulletin, 28(5), 324–331.
- [6] Siegler, E. (2017). Gas Turbine Heat Transfer and Cooling Technology (2nd ed.). Cambridge University Press.
- [7] Saravanamuttoo, H. I. H., Rogers, G. F. C., Cohen, H., & Straznicky, P. V. (2014). Gas Turbine Theory (7th ed.). Pearson Education Limited.
- [8] Solar Turbines. (n.d.). Taurus 60 Gas Turbine. [Brochure]. Available at: https://www.solarturbines.com/en_US/products/gas-turbines/taurus-60.html
- [9] Sayehvand, K., & Ghoreyshi, M. (2019). Smart Sensing Technologies for Gas Turbine Engine Health Monitoring: A Review. Aerospace, 6(7), 75.
- [10] Schlegel, D., Drewitz, U., & Frey, C. (2019). Deep Learning for Anomaly Detection in Gas Turbine Blades: A Comparison of Synthetic and Real Data. Journal of Computational Design and Engineering, 6(2), 174–184.
- [11] Gonzalez, R. C., & Woods, R. E. (2008). Digital Image Processing (3rd ed.). Pearson Education.
- [12] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

- [13] Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61, 85–117.
- [14] Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- [15] Ruder, S. (2016). An Overview of Gradient Descent Optimization Algorithms. *arXiv preprint arXiv:1609.04747*.
- [16] Data Science. (2019). What is Confusion Matrix and Advanced Classification Metrics? Repéré à : <https://manisha-sirsat.blogspot.com/2019/04/confusion-matrix.html>
- [17] Van Rijsbergen, C. J. (1979). *Information Retrieval* (2nd ed.). Butterworths.
- [18] Goodfellow, Bengio, & Courville, 2016