



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET
POPULAIRE



MINISTRE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE

Université Echahid Hamma Lakhdar EL-Oued

Faculté des Sciences Exactes

Mémoire de fin d'étude

Présenté pour l'obtention du diplôme de

MASTER ACADEMIQUE

Domaine : Mathématique et Informatique

Filière : Informatique

Spécialité : Systèmes Distribués et
Intelligence Artificielle

Thème

**Contribution des paradigmes de l'intelligence
artificielle pour la détection d'éventuels
dommages au niveau des moteurs d'avion**

Présenté par : *Selmi Nadine*

Soutenu le 24 /06/2024, devant le jury composé de :

M . LADJDEL Ibrahim	MCA	Université d'EL-Oued	Présidente
M . SASI Amina	MAA	Université d'EL-Oued	Rapporteur
M. ZEGHIDI Zoubir	MAA	Université d'EL-Oued	Rapporteur
Mme. Hamoud Mereim	MCB	Université d'EL-Oued	Encadreur

Année Universitaire 2023-2024

REMERCIEMENT

Tout d'abord, je voudrais dire "Alhamdulillah" et remercier Dieu Tout-Puissant pour Sa grâce et Son soutien constant dans tous les aspects de ma vie. Il a exaucé mes prières et m'a donné la force de surmonter les défis que je croyais insurmontables. J'exprime ma plus profonde gratitude à la doctoresse Meriem Hamoude pour avoir accepté de diriger ce travail que certains jugent impossible. Son soutien indéfectible, ses conseils avisés, son encouragement constant et sa confiance en mes capacités m'ont motivée à dépasser les difficultés et à atteindre mon objectif. Je tiens à remercier vivement les membres du jury pour avoir accepté de participer à ce jury et d'avoir consacré une partie de leur temps précieux à cette mission.

À tous mes professeurs qui ont partagé leurs connaissances et leur sagesse tout au long de mon parcours académique, votre dévouement à l'enseignement et votre passion pour l'éducation ont joué un rôle crucial dans mon développement intellectuel. Je vous adresse mes sincères remerciements.

Je tiens également à exprimer ma gratitude à Air Algérie, en particulier à l'équipe de la base de maintenance de Dar El Beïda à Alger. Je remercie spécialement Mme Leïla Abane ainsi que M. Azeddine Ghrib, M. Abdelaziz Boatoma, M. Abdelkrim Kïsarli, M. Ammar Grira, et d'autres, pour leur soutien et leurs conseils précieux. Un merci spécial au pilote Nasim pour tout, Un grand merci à Kabir Musa.

Je souhaite également remercier ma famille, en particulier mes chers parents, pour leur soutien indéfectible, leur amour et leurs orientations constantes. Votre présence dans ma vie a toujours été une source de force, et je suis éternellement reconnaissante pour vos sacrifices et votre foi en mes capacités.

Enfin, je ne peux que remercier chaleureusement toutes les personnes qui ont contribué, de quelque manière que ce soit, à la réalisation de cette thèse. Merci d'avoir fait partie de mon parcours académique et pour votre foi inébranlable en mes capacités. Merci à vous tous pour votre confiance indéfectible et d'être une partie intégrante de mon succès. "Baraka ALLAHO fikom et merci".

Dédicace

Quand je serai plus grand, je veux être pilote. Ces mots ont toujours résonné en moi depuis mon enfance. C'était un beau rêve d'enfant. Je n'aurais jamais imaginé un jour explorer le monde aéronautique et vivre cette aventure formidable. En effet, j'ai touché deux oiseaux d'un coup : mon rêve d'enfance et ma passion pour l'intelligence artificielle.

"Le moteur est le cœur de l'avion, tandis que le pilote en est l'âme." Cette citation a profondément affecté mon esprit, m'incitant à entreprendre cette merveilleuse aventure. Cette thèse n'est pas seulement un accomplissement personnel, mais un engagement envers le service de l'humanité. C'est un rappel du plus grand objectif derrière les efforts académiques : contribuer à l'amélioration de l'aviation et avoir un impact positif sur elle, ainsi que protéger l'humanité elle-même.

Aujourd'hui, j'écris ces mots pour exprimer ma gratitude envers mes guides dans cette vie, mes chers parents. Leur soutien, leur amour et leurs conseils inestimables ont été un puissant moteur de mon succès. Votre foi en mes capacités et vos sacrifices ont jeté les bases de mes réalisations. Cette thèse est une reconnaissance de votre encouragement infini et de l'impact profond que vous avez eu dans ma vie.

À ma sœur Rayan et mon frère Ibrahim, qui ont été à mes côtés tout au long de ce voyage. Votre soutien, vos encouragements et votre compréhension sont inestimables pour moi. À ma professeure Meriem Hamoud, je vous envoie mes sincères remerciements et ma gratitude pour votre soutien constant et votre position dans surmontant ce défi et en atteignant l'objectif avec excellence.

À mes professeurs qui ont cru en moi et en mes capacités, et qui ont été une source de soutien constant. Et à mes amis votre soutien, votre amitié et vos encouragements ont rendu ce voyage plus agréable et inoubliable. Je suis reconnaissant pour les discussions, la coopération et les moments de rire innombrables que nous avons partagés.

Je dédie cette thèse à moi-même, à travers ma persévérance qui a surmonté les obstacles et a atteint cette étape importante dans mon parcours académique.

Nadine

Abstract

The health condition of an aero-engines is pivotal to the safe flight mission of an aircraft. Indeed, with the increase of service time, the engine internal components will be affected by threats coming from different sources. Hence, it is necessary to detect the damage inside the engine regularly to decrease maintenance costs. Borescope inspection technology can successfully diagnose the fault and provide a strong guarantee for the maintenance work; however, its grade of automation and intelligence is clearly low. In this sense, we have proposed a more automated aero-engine defect detection framework based on the current research hot spot: deep learning for aero engine defect detection through a local dataset. The proposed YOLOv8 framework is 3-phases covering: data acquisition, model training and model evaluation. Indeed, the proposed system can accurately and efficiently detect seven types of damages from borescope images including: Crack, Nick, Overheated, Tip curl, Corrosion, Burned and Broken by reaching high accuracy. Furthermore, it gains the ability to output both the regions and the types of damages within input images. Finally, we validated our framework on downloaded engineering data and achieved successful damage detection. Hence, we overcome the challenges. The developed deep learning framework provides dual benefits of reducing the time required to perform otherwise manual aero-engine borescope inspection and improving the overall safety relative to the aerospace industry free from human error. Applying deep learning in the field of aero-engine defect detection is still in its infancy.

Keywords

Aero-engine, defect detection, deep learning, Borescope images, YOLOv8, segmentation, classification.

Résumé

L'état de santé des moteurs d'avion est essentiel à la sécurité de la mission de vol d'un avion. En effet, avec l'augmentation du temps de service, les composants internes du moteur seront affectés par des menaces provenant de différentes sources. Par conséquent, il est nécessaire de détecter régulièrement les dommages à l'intérieur du moteur pour réduire les coûts de maintenance. La technologie d'inspection par borescope peut diagnostiquer avec succès le défaut et fournir une solide garantie pour les travaux de maintenance ; cependant, son degré d'automatisation et d'intelligence est clairement faible. Dans ce sens, nous avons proposé un système plus automatisé de détection des dommages des moteurs d'avion, basé sur le point essentiel de la recherche actuelle : l'apprentissage profond pour la détection des défauts des moteurs d'avion via un ensemble de données locales. Le modèle YOLOv8 proposé comprend 3 phases couvrant : l'acquisition de données, l'apprentissage du modèle et l'évaluation du modèle. En effet, le système proposé peut détecter avec précision et efficacité sept types de dommages à partir d'images d'endoscope, notamment : fissure, entaille, surchauffe, courbure de la pointe, corrosion, brûlé et cassé en atteignant une grande précision. De plus, il acquiert la capacité d'afficher à la fois les régions et les types de dommages dans les images d'entrée. Par la fin, nous avons validé notre système sur les données d'ingénierie téléchargées et avons réussi à détecter les dommages. Ainsi, nous surmontons les défis. Le système d'apprentissage en profondeur développé offre le double avantage de réduire le temps nécessaire pour effectuer une inspection par borescope de moteurs d'avion, autrement manuelle, et d'améliorer la sécurité globale par rapport à l'industrie aérospatiale sans erreur humaine. L'application de l'apprentissage profond dans le domaine de la détection des dommages des moteurs d'avion en est encore à ses balbutiements.

Mots-clés

Moteur d'avion, détection de dommages, apprentissage profond, images de borescope, YOLOv8, segmentation, classification.

ملخص

تعتبر الحالة الصحية لمحركات الطائرات ضرورية لضمان سلامة الرحلات الجوية. في الواقع، مع زيادة وقت الخدمة، تتعرض المكونات الداخلية للمحرك لتهديدات من مصادر مختلفة. لذلك، من الضروري اكتشاف الأضرار داخل المحرك بانتظام لتقليل تكاليف الصيانة. يمكن لتقنية التفيتيش بالمنظار أن تشخص العيوب بنجاح وتوفر ضماناً قوياً لأعمال الصيانة؛ ومع ذلك، فإن درجة الأتمتة والذكاء فيها منخفضة بشكل واضح. في هذا السياق، قمنا باقتراح إطار عمل أكثر تلقائية لاكتشاف عيوب محركات الطائرات بناءً على أحدث الأبحاث الحالية: التعلم العميق لاكتشاف عيوب محركات الطائرات من خلال مجموعة بيانات محلية. يتكون إطار العمل المقترح (YOLOv8) من ثلاث مراحل تغطي: جمع البيانات، تدريب النموذج، وتقييم النموذج. في الواقع، يمكن للنظام المقترح اكتشاف سبعة أنواع من الأضرار بدقة وكفاءة من صور المنظار الداخلي بما في ذلك: الشقوق، النقر، ارتفاع درجة الحرارة، تجعد الأطراف، التآكل، الاحتراق، والكسر بتحقيق دقة عالية. علاوة على ذلك، يكتسب القدرة على إخراج كل من المناطق وأنواع الأضرار داخل الصور المدخلة. أخيراً، قمنا بالتحقق من صحة إطار العمل الخاص بنا على بيانات هندسية تم تنزيلها وحققتنا نجاحاً في اكتشاف الأضرار. وبالتالي، تغلبنا على التحديات. يوفر إطار العمل المطور للتعلم العميق فائدتين مزدوجتين: تقليل الوقت المطلوب لأداء فحص المنظار الداخلي اليدوي لمحركات الطائرات وتحسين السلامة العامة بالنسبة لصناعة الطيران بعيداً عن الأخطاء البشرية. لا يزال تطبيق التعلم العميق في مجال اكتشاف عيوب محركات الطائرات في مراحله الأولى.

الكلمات المفتاحية

محرك طائرة ، اكتشاف العيوب ، التعلم العميق ، صور المنظار الداخلي ، (YOLOv8) ، التجزئة ، التصنيف .

TABLE DES MATIÈRES

Table des matières	i
Table des figures	iv
Liste des tableaux	vii
Introduction générale	1
I Les paradigmes de l'intelligence artificielle : l'apprentissage automatique ainsi que l'apprentissage profond	5
I.1 Introduction	6
I.2 La vision par ordinateur	7
I.3 L'analyse d'image	7
I.4 Aperçu sur les paradigmes de l'IA : l'apprentissage automatique et l'apprentissage profond	8
I.4.1 L'apprentissage automatique	9
I.4.2 L'apprentissage profond	11
I.5 Vocation de quelques modèles des réseaux de neurones convolutif	17
I.5.1 U-NET	17
I.5.2 VGG-16	18
I.5.3 ResNet	19
I.5.4 R-CNN	20
I.5.5 Fast R-CNN	22
I.5.6 Faster R-CNN	22

I.5.7	Mask R-CNN	23
I.5.8	YOLO	25
I.6	Conclusion	32
II	Detection automatique des dommages surgissant au niveau du moteur aérien basée sur les paradigmes de l'intelligence artificielle : problématique et état de l'art	33
II.1	Introduction	34
II.2	Aperçu sur le moteur aérien	35
II.3	Types de dommages du moteur aérien	37
II.4	Inspections visuelles du moteur d'avion	38
II.4.1	Les tests non destructifs	38
II.4.2	La détection des dommages du moteur d'avion par borescope	41
II.4.3	La détection des dommages du moteur d'avion par la vision par ordinateur	45
II.5	Problématique	46
II.6	État de l'art sur la détection automatique des dommages surgissant au niveau du moteur aérien basée machine learning et deep learning	50
II.7	Conclusion	54
III	Approche proposée pour la détection automatique des dommages surgissant au niveau du moteur aérien	55
III.1	Introduction	56
III.2	Plan d'action	57
III.3	Méthodologie proposée pour la détection automatique des dommages surgissant au niveau du moteur aérien	58
III.4	Segmentation et reconnaissance des dommages au moteur d'avion basées YOLOv8	59
III.4.1	Datasets utilisée	59
III.4.2	Prétraitements appliqués à la datasets	61
III.4.3	Implémentation de YOLOv8 pour la segmentation et la reconnaissance des dommages au sein du moteur aérien	68
III.5	Conclusion	73
IV	Evaluation des performances de l'approche proposée	74
IV.1	Introduction	75
IV.2	Environnement de développement et outils utilisés	76

IV.2.1 Matériel utilisé	76
IV.2.2 Google Colab	76
IV.2.3 Nécessité de travailler avec un GPU	77
IV.2.4 Le langage Python	78
IV.2.5 Bibliothèques utilisées	78
IV.3 Métriques d'évaluation des performances utilisées	79
IV.4 Expérimentations	81
IV.5 Evaluation des performances de l'approche proposée de détection automatique des dommages du moteur aérien	82
IV.5.1 Evaluation des performances des premières expérimentations	82
IV.5.2 Evaluation des performances des secondes expérimentations en vue de l'amélioration du modèle obtenu durant les premières expérimentations	84
IV.6 Evaluation des performances de l'approche proposée sur des donnée de test pour confirmer sa généralisabilité	93
IV.7 Présentation de quelques vue de l'interface de notre approche	100
IV.8 Conclusion	103
Conclusion générale	104
Bibliographie	106

TABLE DES FIGURES

I.1	Architecture générale d'un réseau de neurones convolutif. Source [14].	13
I.2	Convolution avec un noyau de taille 3*3.Source [16].	14
I.3	Fonction d'activation (ReLU).	15
I.4	Exemples du max pooling et de l' average pooling.	16
I.5	Architecture du modèle U-NET. [17].	18
I.6	Architecture de VGG-16. Source [18].	19
I.7	Architecture ResNet. Source [20].	20
I.8	Architecture de RCNN. Source [22].	21
I.9	Architecture de Fast R-CNN. Source [21].	22
I.10	Architecture de Faster R-CNN. Source [23].	23
I.11	L'architecture de Mask R-CNN avec (a) : un diagramme de structure mettant en évidence le réseau de base, le RPN, les branches de détection de boîtes englobantes et de prédiction de masques , et en (b) : une vue détaillée du réseau de proposition de régions (RPN) [24].	24
I.12	Une chronologie des versions de YOLO. Source [27].	26
I.13	Architecture de YOLO . Source [26].	27
I.14	Exemple de fonctionnement de YOLO. Source [28].	28
I.15	comparaison de YOLOv8 par rapport aux modèles précédents. Source [29].	30
II.1	Coupe transversale d'un moteur d'avion. Source [30].	35
II.2	Cas de panne de moteur d'avion. en (a) : Boeing 777-200 avec moteur droit en feu , en (b) : Perspective agrandie, moteur droit en feu , en (c) : Enquêteurs vérifient l'avion , et en (d) : Deux pales cassées. Source [6].	36

II.3	Radiographic Testing Diagram. Source [32].	39
II.4	Ultrasonic Testing Diagram. Source [32].	39
II.5	Magnetic Particle Testing Diagram. Source [32].	40
II.6	The Process of Penetrant Testing. Source [32].	40
II.7	Schematic Diagram of Eddy Current Testing. Source [32].	41
II.8	La détection par borescope. en (a) : L'ingénieur aéronautique effectue l'inspection à l'aide de borescope , en (b) : Ce que l'écran de l'borescope affiche. Source [36].	42
II.9	Diagramme schématique de l'inspection par borescope. en (a) : Les inspecteurs inspectent les pales du moteur , en (b) : Judas sur le moteur d'avion , en (c) : Agrandir l'écran du borescope , et en (d) : Trois types de dommages classiques aux pales. Source [6].	42
II.10	Processus inspection in-situ par borescope. Source [33].	44
III.1	Architecture générale du système proposé de détection automatique des dommages du moteur aérien.	59
III.2	Exemples d'images de dommages surgissant au moteur d'avion.	60
III.3	Exemple de détection de dommages à l'aide d'un borescope en (a) : le borescope en question et en (b) : l'image acquise avec un dommage à la pale.	61
III.4	Exemple de la conversion d'une vidéo en un grand ensemble d'images.	62
III.5	Exemple de l'application de l'augmentation des données.	63
III.6	Exemple de génération de labelling des dommages par Roboflow.	68
III.7	Exemples de méthodes utilisées par les inspecteurs de borescope pour la détection des dommages au sein de la base de maintenance d'Air Algérie.	69
III.8	Exemples de la méthode que nous avons adoptée pour la segmentation d'instance.	70
III.9	La structure du modèle YOLOv8-seg.	71
IV.1	Environnement de Google Colab.	77
IV.2	Les détails de l'apprentissage des modèles YOLOv8n-seg et YOLOv8s-seg.	83
IV.3	Exemple données ajoutées pour la classe "crack" obtenues à partir des panneaux et des murs.	85
IV.4	Distribution des instances selon les sept classes.	86
IV.5	La matrice de confusion de YOLOv8 pour la détection des dommages du moteur aérien.	88
IV.6	Courbes loss de la phase d'apprentissage.	89
IV.7	Courbes loss de la phase de validation.	89
IV.8	Progression des mesures d'évaluation des performances au long de l'apprentissage.	90

IV.9 Exemples de résultats de détection par l'approche proposée (partie 1).	90
IV.10 Exemples de résultats de détection par l'approche proposée (partie 2).	91
IV.11 Exemples de résultats de détection de dommages du moteur aérien sur des images de test.	99
IV.12 Interface de notre Système.	100
IV.13 Processus d'acquisition d'une image ou une vidéo prises par le borescope.	101
IV.14 Détection des dommages du moteur aérien et sauvegarde des résultats.	101
IV.15 Détection des dommages du moteur depuis la caméra.	102

LISTE DES TABLEAUX

I.1	Comparaison de YOLO avec d'autres modèles en temps réel.	26
II.1	Approches de détection automatique des dommages surgissant au niveau du moteur aérien.	51
III.1	Les différentes catégories de dommages couverts par notre système.	64
III.2	Les diverses spécifications du modèle YOLOv8.	72
IV.1	Les caractéristiques du matériel utilisé.	76
IV.2	Les hyperparamètres appliqués durant les premières expérimentations.	82
IV.3	Performances de segmentation d'instance pour l'ensemble de données de validation.	84
IV.4	Performances de segmentation d'instance pour l'ensemble de données de validation.	87
IV.5	Une nette amélioration des résultats de détection des cracks par le modèle YOLOv8s- seg amélioré (modèle final) : à gauche les résultats du premier modèle YOLOv8n- seg ensuite ceux du second modèle YOLOv8s-seg et à droite les résultats du modèle 2 amélioré, à savoir YOLOv8s-seg amélioré.	92
IV.6	Résultats obtenus de détection des dommages du moteur aérien sur des données de tests.	93

INTRODUCTION GÉNÉRALE

La sécurité aérienne est essentielle pour garantir les moyens de subsistance des populations, le développement économique ainsi que la sécurité militaire. L'aviation civile a récemment été très populaire avec l'avènement de la technologie, la volonté croissante de voyager en raison de la classe moyenne croissante de la population mondiale, l'émergence de compagnies aériennes à bas prix et enfin l'augmentation du transport de marchandises via les compagnies aériennes. En raison de ces facteurs, la taille de la flotte aérienne mondiale a atteint 25900 appareils en 2019 et devrait atteindre 470801 appareils en 2041.

En raison du grand nombre d'avions en vol, non seulement le trafic mais aussi le bien-être technique (navigabilité) de ces avions doivent être sous contrôle strict pour maintenir la sécurité aérienne [1]. L'Autorité de l'aviation civile (CAA) de chaque pays effectue des contrôles techniques et opérationnels annuels sur les exploitants de compagnies aériennes pour garantir une maintenance et un fonctionnement corrects des avions. De plus, les constructeurs, acteurs majeurs étant Boeing, Airbus, Embraer, Bombardier, sont dépendants des CAA des pays dans lesquels ils produisent leurs avions. Les principales CAA sont la «Federal Aviation Administration» (États-Unis), «l'Agence de la sécurité aérienne de l'Union européenne» (UE), «l'Agência Nacional de Aviação Civil» (Brésil) et «Transports Canada» (Canada).

En raison de la longue période de service d'un avion, celui-ci peut subir divers types de dommages au moteur, tels que les dommages aux pales causés par le frottement, la décoloration causée par une combustion à haute température et beaucoup d'autres [2]. Revenons sur le crash d'Iliouchine Il-76 des forces aériennes algériennes qui s'est déroulé le 11 avril 2018 aux environs de 06h50 où un Iliouchine Il-76TD appartenant au 347e escadron de transport stratégique des forces aériennes algériennes s'est écrasé peu après son décollage près de la base aérienne de

Boufarik se localisant au sud d'Alger. Malheureusement, il n'y avait aucun survivant parmi les 257 passagers et membres d'équipage de cet avion militaire de transport [3]. C'est l'accident aérien le plus meurtrier en Algérie et le quatrième plus meurtrier dans le monde depuis vingt ans. En effet, d'après les témoins de l'accident, l'aile gauche de l'appareil était en feu avant le crash. En conséquence, probablement un moteur ait pris feu, à priori, en raison d'une collision avec un oiseau.

La structure complexe et compact du moteur d'avion pose un défi important pour la détection des dommages. En tant que support d'informations de surface le plus intuitif, les images sont largement utilisées dans le domaine de détection et localisation des dommages [2]. Dans ce sens, les grandes compagnies aériennes utilisent généralement un borescope pour collecter des images internes du moteur, puis localisez et diagnostiquez les dommages par observation manuelle.

L'inspecteur peut observer visuellement la structure interne des moteurs d'avion, tels que les pales. L'imagerie par borescope est une technique populaire qui permet à un inspecteur de sonder l'intérieur d'un moteur ; le tube flexible du borescope est conçu pour s'insérer dans les ports d'accès du moteur, permettant d'effectuer l'inspection avec un démontage minimal [4]. Par exemple, des bouchons d'accès spéciaux ou le trou d'un allumeur retiré peuvent être utilisés pour accéder à la section chaude d'une turbine. Le flux vidéo capturé par les borescopes est analysé en temps réel par les inspecteurs pour identifier d'éventuelles anomalies. Une fois qu'un défaut grave est identifié, le moteur est envoyé à une installation de maintenance, de réparation et de révision où une inspection plus approfondie est effectuée par démontage du moteur. Il s'agit d'une procédure coûteuse qui représente une fraction considérable du prix catalogue du moteur. Cependant, l'application directe de ces méthodes à la détection de dommage pose plusieurs défis [4][5][6] : la procédure de borecopie prend plusieurs heures, nécessite plusieurs inspecteurs chevronnés pour vérifier s'il y a des dommages à la surface des pales par vision artificielle, cela demande beaucoup de travail, prend du temps et dépend de l'expérience, la petite taille des dommages, des conditions complexes à l'intérieur du moteur comme la complexité de l'arrière-plan et les diverses blessures, les exigences de précision élevées et les géométries complexes des pales. De plus, le processus d'inspection du moteur implique un investissement manuel important où les inspecteurs doivent suivre une formation rigoureuse et coûteuse et aussi les inspecteurs nouveaux et inexpérimentés peuvent ne pas avoir les connaissances et les compétences nécessaires pour identifier et signaler de manière fiable les pièces de moteur problématiques. Les facteurs humains représentent un défi important pour le processus de maintenance ; la décision de savoir si un défaut identifié est jugé suffisamment délétère pour justifier des opérations de réparation ou s'il est acceptable et simplement reporté à l'inspection suivante,

repose sur des mesures manuelles de l'emplacement et de la taille du dommage. Ces mesures sont comparées aux limites de tolérance basées sur des études de cas précédentes décrites dans les manuels de moteurs concernés. A cet effet, tous ces points problématiques affecteront la qualité de l'image et augmenteront la difficulté de reconnaissance.

Dans ce sens, les méthodes basées sur l'apprentissage profond offrent de remarquables pertinences pour la détection des dommages aux pales et autres composants du moteur d'avion en raison de leurs excellentes performances en matière d'extraction de caractéristiques et de reconnaissance d'objets. Nous proposons un système de détection de sept dommages surgissant au moteur d'avion dans ses trois composants : les pales du compresseur et de la turbine ainsi que la chambre de combustion. En effet, nous avons collecté une datasets d'image de dommages issues d'un borescope au près de la compagnie aérien d'air Algérie où YOLOv8 a été implémenté pour la détection des différents dommages en aboutissant à des taux de reconnaissance très satisfaisants.

Nous avons structuré ce mémoire comme suit :

***Chapitre I** : Les paradigmes de l'intelligence artificielle : l'apprentissage automatique ainsi que l'apprentissage profond*

Au long de ce chapitre, nous explorons diverses applications et modèles d'intelligence artificielle, en mettant l'accent sur la vision par ordinateur et l'analyse d'images.

***Chapitre II** : Détection automatique des dommages surgissant au niveau du moteur aérien basée sur les paradigmes de l'intelligence artificielle : problématique et état de l'art*

Nous présentons dans ce chapitre les paradigmes de base de l'intelligence artificielle en vue de les utiliser pour la détection automatique des dommages surgissant au niveau du moteur aérien et provoquant les craches d'avions. Evidemment la problématique tirée dans ce sens sera détaillée.

Chapitre III : Approche proposée pour la détection automatique des dommages surgissant au niveau du moteur aérien

Le chapitre III détaillera l'approche proposée faisant recours à la problématique.

Chapitre IV : Evaluation des performances de l'approche proposée

Le chapitre IV exposera une évaluation de pointe de l'approche proposée.

Ce mémoire s'achèvera par une conclusion générale ainsi que des perspectives.

CHAPITRE I

LES PARADIGMES DE L'INTELLIGENCE
ARTIFICIELLE : L'APPRENTISSAGE
AUTOMATIQUE AINSI QUE
L'APPRENTISSAGE PROFOND

I.1 Introduction

Au cours des dernières années, l'Intelligence Artificielle (IA) a captivé l'attention du public et des médias comme jamais auparavant, suscitant à la fois des espoirs et des inquiétudes. Ce nouvel engouement pour l'IA est largement attribuable aux avancées technologiques significatives qui ont considérablement amélioré les performances des ordinateurs dans des domaines tels que la reconnaissance vocale et la vision par ordinateur.

L'IA est sur le point de jouer un rôle de plus en plus prépondérant dans les organisations et les systèmes de production, avec des applications se multipliant à un rythme effréné, de l'automatisation des tâches à la relation client, en passant par la logistique, l'analyse prédictive et le diagnostic. Définie comme la capacité pour une machine de reproduire des comportements liés à l'intelligence humaine, l'IA permet à ces systèmes techniques de percevoir leur environnement, d'analyser ces perceptions, de résoudre des problèmes et d'entreprendre des actions dans le but d'atteindre des objectifs spécifiques. Les ordinateurs, équipés de capteurs tels que des caméras, recueillent des données à partir de leur environnement, qu'ils analysent ensuite à l'aide d'algorithmes et de modèles d'apprentissage pour prendre des décisions ou effectuer des actions en réponse aux informations traitées [7].

L'IA est devenue une force majeure dans la résolution de problèmes complexes dans plusieurs domaines. En particulier celui de l'aviation. La concurrence entre les géants de l'industrie aéronautique pour la conception, la fabrication et la maintenance des avions est devenue plus intense en raison de l'évolution rapide de l'IA. Ces défis ne se limitent pas seulement à la conception et à la fabrication, mais également aux opérations de maintenance et d'inspection visant à garantir la sécurité des vols et à prévenir les pannes imprévues. L'intelligence artificielle offre d'énormes opportunités pour révolutionner l'inspection des composants d'avions en automatisant les tâches ardues, en améliorant la précision et l'efficacité de l'inspection, en permettant la maintenance prédictive et en fournissant des capteurs modernes pour protéger l'âme de l'humanité et même maintenir la sécurité des avions.

Nous présentons dans ce chapitre les paradigmes de base de l'intelligence artificielle en vue de les utiliser pour la détection automatique des dommages surgissant au niveau du moteur aérien et provoquant les craches d'avions.

I.2 La vision par ordinateur

La vision par ordinateur est une discipline de l'informatique qui concerne le traitement automatique des images numériques et des vidéos. Elle vise à développer des algorithmes et des systèmes permettant aux ordinateurs de comprendre le contenu visuel de manière similaire à la façon dont les êtres humains le font. Cela comprend la capacité à extraire des informations significatives à partir d'images, telles que la détection et la reconnaissance d'objets, la compréhension de la scène, la reconstruction 3D, le suivi de mouvement, la segmentation d'image, et bien d'autres tâches liées à l'analyse des données visuelles [8]. La vision par ordinateur est présentée comme une branche de l'informatique qui s'attaque au traitement automatique des données visuelles. Elle englobe un large éventail de techniques et de tâches visant à permettre aux ordinateurs de comprendre et d'interpréter le contenu visuel, ce qui est essentiel pour de nombreuses applications pratiques telles que la robotique, la sécurité, la médecine, l'automobile, et plus encore. La vision par ordinateur repose sur plusieurs techniques et technologies, notamment la segmentation d'image, la détection d'objet, la reconnaissance de forme, la classification d'image et la localisation d'objet. Ces techniques sont souvent combinées pour résoudre des problèmes plus complexes. Par exemple, dans le domaine de la conduite autonome, un système de vision par ordinateur doit être capable de détecter les voitures, les piétons, les panneaux de signalisation et autres objets sur la route, puis de prendre des décisions en temps réel en fonction de ces informations. Bien que la vision par ordinateur ait réalisé d'énormes progrès au cours des dernières décennies, elle reste un domaine de recherche en constante évolution. Les défis persistent, notamment en ce qui concerne la précision de la reconnaissance dans des conditions variables, la robustesse aux perturbations et la compréhension du contexte visuel. Cependant, avec les avancées continues dans les technologies d'apprentissage automatique, de traitement d'image et de matériel informatique, la vision par ordinateur continue de repousser les limites de ce qui est possible, ouvrant la voie à de nouvelles applications et innovations passionnantes. C'est ce dont parlait Richard Szeliski selon son livre « Computer Vision : Algorithmes and Applications » [8].

I.3 L'analyse d'image

L'analyse d'images est un processus essentiel dans de nombreux domaines. Elle consiste à extraire des informations significatives à partir d'images numériques en utilisant des techniques telles que la segmentation, l'extraction de caractéristiques et la classification [9]. La première

étape de l'analyse d'images est souvent le prétraitement, qui vise à améliorer la qualité de l'image. Ensuite, la segmentation divise l'image en régions ou objets significatifs, tandis que l'extraction de caractéristiques identifie des attributs spécifiques dans ces régions. Enfin, la reconnaissance des formes consiste à interpréter ces caractéristiques pour extraire des informations plus complexes. L'analyse d'images peut être divisée en deux niveaux principaux : l'analyse de bas niveau et l'analyse de haut niveau. L'analyse de bas niveau se concentre sur les étapes initiales du traitement d'une image, telles que le filtrage, la segmentation et l'extraction de caractéristiques de base. Cette phase est cruciale car elle prépare l'image pour des analyses plus avancées. Elle est largement utilisée dans des applications telles que l'analyse médicale assistée par ordinateur, la télédétection et la vision par ordinateur. Les progrès réalisés lors du traitement de bas niveau sont essentiels pour garantir la précision et la performance des analyses de niveau supérieur. D'autre part, l'analyse de haut niveau implique l'utilisation d'algorithmes et de techniques avancés pour extraire des informations complexes de l'image. Cette phase va au-delà du traitement de base en exigeant une interprétation et une compréhension approfondies du contenu de l'image. Des techniques telles que la reconnaissance d'objets, l'interprétation de scènes et l'apprentissage en profondeur sont souvent utilisées dans cette phase pour identifier et comprendre des structures et des patterns plus complexes dans les images. En résumé, l'analyse d'images est un processus multidimensionnel qui comprend à la fois des étapes de traitement de base et des analyses plus avancées. Ces deux niveaux de traitement sont complémentaires et essentiels pour extraire des informations pertinentes et significatives des images numériques [9].

I.4 Aperçu sur les paradigmes de l'IA : l'apprentissage automatique et l'apprentissage profond

Les paradigmes d'apprentissage automatique et d'apprentissage profond ont une histoire fascinante qui remonte à plusieurs décennies. Le concept d'apprentissage automatique trouve ses racines dans les travaux pionniers des années 1950 et 1960, où les chercheurs ont exploré des techniques permettant aux machines d'apprendre à partir de données sans être explicitement programmées. Cependant, c'est vraiment dans les années 1980 et 1990 que le domaine a commencé à prendre de l'ampleur, avec des avancées significatives dans des domaines tels que les réseaux neuronaux et les algorithmes d'apprentissage automatique traditionnels [10]. L'avènement de l'apprentissage profond, souvent appelé "deep learning" en anglais, a marqué une étape

importante dans l'évolution de l'apprentissage automatique. Les réseaux de neurones profonds, inspirés du fonctionnement du cerveau humain, sont capables d'apprendre des représentations de données de manière hiérarchique, en extrayant des caractéristiques complexes à partir de données brutes. Cette capacité a conduit à des percées majeures dans des domaines tels que la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale et bien d'autres encore. Ces paradigmes représentent bien plus que des outils techniques. Ils sont une source d'inspiration et de découverte, ouvrant de nouvelles perspectives dans la manière dont nous comprenons l'intelligence, tant naturelle qu'artificielle. Leur importance réside dans leur capacité à résoudre des problèmes complexes, à automatiser des tâches fastidieuses et à créer des systèmes capables d'apprendre et de s'adapter de manière autonome. En somme, les paradigmes d'apprentissage automatique et d'apprentissage profond sont au cœur des avancées scientifiques et technologiques de notre époque.

I.4.1 L'apprentissage automatique

L'apprentissage automatique est un domaine de l'intelligence artificielle et de l'informatique qui englobe l'apprentissage supervisé et non supervisé, et qui comprend le développement de logiciels et d'algorithmes capables de faire des prédictions basées sur des données. L'apprentissage automatique est utilisé dans divers secteurs. Dans le domaine de l'analyse de données, par exemple, l'apprentissage automatique est utilisé pour faire des prédictions basées sur les tendances et les insights tirés des données. Un exemple phare de l'application de l'apprentissage automatique est le véhicule autonome. Les capteurs autour du véhicule fournissent des milliers de points de données qui sont analysés et traités pour déplacer le véhicule vers sa destination. Les données collectives de milliers de voitures autonomes peuvent être utilisées pour améliorer la sécurité des véhicules et prévenir les accidents [10]. L'apprentissage automatique Au-delà des avantages pratiques, maîtriser l'apprentissage automatique transforme les approches de résolution de problèmes, passant d'une pensée logique et mathématique à un état d'esprit plus observationnel, expérimental et statistique, élargissant ainsi les horizons et ouvrant de nouvelles voies d'exploration [11].

Nous allons citer les algorithmes d'apprentissage automatique les plus populaires [12] :

- **Régression linéaire (Apprentissage supervisé / Régression)**

La régression linéaire est un algorithme d'apprentissage automatique simple et populaire couramment utilisé pour l'analyse prédictive. Elle permet d'étudier la relation entre les variables

dépendantes et indépendantes en définissant une ligne et son équation. Cette ligne est la ligne de régression, et son équation linéaire est $y = mx + c$ où y est la variable dépendante, x est la variable indépendante, m est la pente de la ligne, et c est l'ordonnée à l'origine. Les valeurs de m et c sont calculées en minimisant la somme des distances au carré entre les deux points et la ligne de régression. Cet algorithme de régression linéaire est couramment utilisé pour prédire les mouvements du marché boursier.

- **Arbre de décision (Apprentissage supervisé / Classification / Régression)**

L'arbre de décision est un algorithme d'apprentissage automatique qui classe les variables dépendantes catégorielles et continues. Il divise les données en deux ensembles ou plus similaires en fonction des attributs et variables. Un arbre de décision commence par un nœud racine et se termine par un nœud feuille. Les branches montrent les règles / conditions de décision, le nœud interne représente les caractéristiques de l'ensemble de données et le nœud feuille représente la sortie. L'algorithme d'arbre de décision a des applications dans le monde réel comme l'identification des cellules cancéreuses et non cancéreuses, la suggestion de produits et services aux acheteurs potentiels, etc.

- **Machine à vecteurs de support (Apprentissage supervisé / Classification)**

Les machine à vecteurs de support est un algorithme de classification qui permet de représenter des données brutes sous forme de points dans un espace n -dimensionnel, où n représente le nombre de caractéristiques définies. La valeur de chaque caractéristique est associée à des coordonnées spécifiques. L'algorithme SVM crée un hyperplan ou une frontière de décision qui sépare les ensembles de données en différentes classes. Les vecteurs de support sont les points de données qui définissent l'hyperplan. Les classificateurs divisent les données et placent ces points de données sur un graphique. Les machines à vecteurs de support ont des applications dans la vie réelle, telles que la classification d'images, la détection et l'identification faciale, la découverte de médicaments, etc.

- **K plus proches voisins (Apprentissage supervisé)**

Les k plus proches voisins sont un algorithme d'apprentissage supervisé pour la classification et la régression de données. Cet algorithme est utilisé pour estimer la probabilité qu'un point de données appartienne à l'un ou l'autre groupe. Pour déterminer le groupe de points de données, l'ensemble des points est analysé par rapport à un seul point de données. L'algorithme suppose

des similitudes entre les nouveaux points de données et ceux disponibles pour les classer. La distance euclidienne entre les points de données sur un graphique les classe en catégories distinctes.

- **K-means (Apprentissage non supervisé / Clustering)**

Le K-means est un algorithme d'apprentissage automatique non supervisé qui résout les problèmes de clustering. Les ensembles de données sont classés en K clusters en fonction de leurs similitudes et de leurs différences par rapport aux autres points de données. Les centroïdes sont le point central de chaque cluster, et la distance de chaque point de données aux centroïdes est calculée. Le point de données est attribué à un cluster qui est le plus proche du centroïde. L'algorithme crée ensuite de nouveaux centroïdes et répète le processus jusqu'à ce que les centroïdes ne soient plus interchangeables.

- **Analyse en composantes principales (ACP) (Apprentissage non supervisé)**

L'analyse en composantes principales est une technique d'apprentissage non supervisé pour la réduction de la dimensionnalité. Cet algorithme réduit la dimensionnalité des ensembles de données, c'est-à-dire qu'il réduit le nombre de caractéristiques corrélées. L'ACP suit un processus statistique pour convertir les observations de caractéristiques corrélées en caractéristiques linéairement non corrélées. L'ACP est utile pour l'analyse exploratoire des données et la modélisation prédictive. Les applications de l'ACP incluent un système de recommandation de films, le traitement d'images, l'optimisation de l'allocation de puissance pour les réseaux électriques, etc.

I.4.2 L'apprentissage profond

Le concept de l'apprentissage profond remonte à plusieurs décennies, dans les années 1950 et 1960, Frank Rosenblatt a introduit le perceptron, une forme rudimentaire de réseau neuronal, mais son potentiel était limité aux séparations linéaires. Plus tard, dans les années 1960, le livre "Perceptrons" de Marvin Minsky et Seymour Papert a mis en lumière les limitations importantes des modèles de l'époque, ce qui a temporairement diminué l'intérêt pour la recherche sur les réseaux neuronaux [13].

L'apprentissage profond, également connu sous le nom de deep learning, représente une avancée significative dans le domaine de l'intelligence artificielle. Cette branche de l'apprentissage automatique utilise des réseaux de neurones artificiels profonds pour apprendre à partir de don-

nées. Inspirés par le fonctionnement du cerveau humain, ces réseaux sont composés de multiples couches de neurones interconnectées, permettant ainsi de traiter des données complexes et de produire des prédictions ou des classifications précises à partir de nouvelles données.

Les applications de l'apprentissage profond sont vastes et variées, allant de la reconnaissance d'image à la traduction automatique, en passant par la reconnaissance de la parole, la génération de texte et la prédiction de séquences. Cette technique se distingue par sa capacité à traiter des données de grande dimension et à extraire des informations ainsi que des motifs cachés dans ces données, ce qui en fait un outil précieux pour de nombreux domaines tels que la médecine, la finance, la robotique, la publicité, la sécurité et la surveillance.

L'émergence de l'apprentissage profond a été rendue possible grâce à l'augmentation de la puissance des ordinateurs et au développement de vastes ensembles de données, communément appelés "Big Data". Ces progrès ont révolutionné de nombreux domaines qui nécessitaient auparavant un traitement manuel ou semi-automatique des données, permettant ainsi des avancées significatives dans la résolution de problèmes complexes.

Dans le domaine de l'apprentissage profond, plusieurs modèles emblématiques ont joué un rôle crucial dans le développement et l'adoption de cette technologie révolutionnaire, nous nous focalisons sur les réseaux de neurones convolutifs.

Les réseaux de neurones convolutifs (CNN) représentent une architecture spécifique de réseaux de neurones artificiels comme mentionné sur la figure I.1, conçue principalement pour le traitement d'images. Cette architecture est particulièrement adaptée à la vision par ordinateur en raison de sa capacité à détecter des motifs et des structures visuelles à différentes échelles.

Le principe fondamental des CNN réside dans l'utilisation de filtres de convolution, qui sont appliqués à l'image en entrée pour extraire des caractéristiques pertinentes. Ces filtres permettent de détecter des éléments visuels tels que des formes, des contours, des textures et des objets, en effectuant des opérations de convolution sur l'image.

Les CNN sont largement utilisés dans de nombreuses applications liées à l'image, telles que la détection d'objets, la reconnaissance faciale, la segmentation d'images, la reconnaissance de gestes et la classification vidéo. Leur capacité à extraire des caractéristiques visuelles complexes en fait des outils indispensables pour l'analyse d'images dans divers domaines.

En plus de leur utilisation dans le domaine de la vision par ordinateur, les CNN ont également des applications dans d'autres domaines, tels que la reconnaissance vocale, le traitement du langage naturel et la génération de texte.

Les réseaux de neurones convolutifs ont révolutionné l'imagerie numérique en offrant une précision sans précédent pour une gamme étendue de tâches. Leur adoption a permis le développ-

ement de technologies innovantes telles que les voitures autonomes, les drones et la vidéosurveillance intelligente.

Il est important de noter que la création et l'entraînement d'un nouveau réseau de neurones convolutifs peuvent être coûteux en termes d'expertise, de matériel informatique et de quantité de données annotées requises. En pratique, les CNN sont généralement composés de plusieurs couches, notamment des couches de convolution, des couches de pooling et des couches entièrement connectées, qui sont stratégiquement agencées pour extraire et classifier les caractéristiques visuelles des images en entrée.

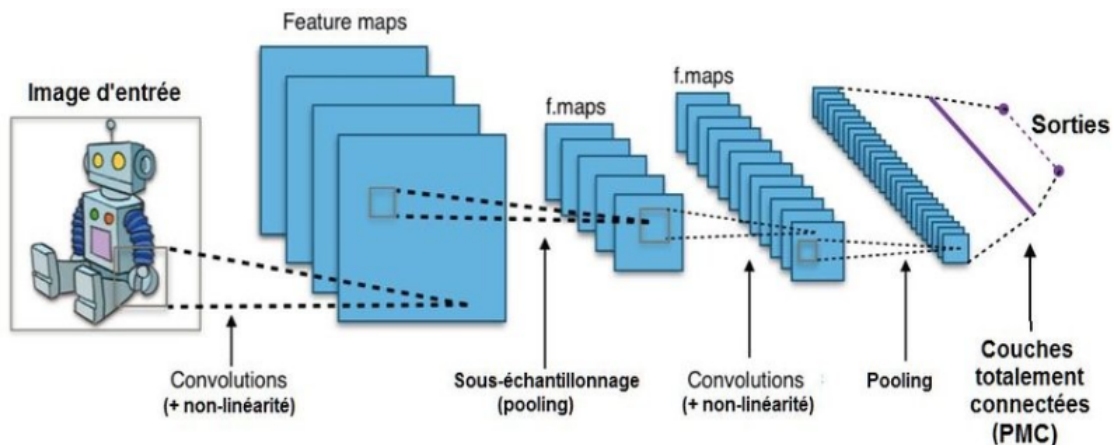


FIGURE I.1 – Architecture générale d'un réseau de neurones convolutif. Source [14].

En ce qui concerne les types de couches dans un CNN, on retrouve généralement trois types principaux :

1. La couche de convolution
2. La couche de pooling
3. La couche fully-connected (entièrement connectée)

Ces différentes couches sont combinées de manière séquentielle pour former l'architecture complète d'un réseau de neurones convolutif, permettant ainsi une analyse efficace et précise des images.

1- La couche de convolution

La couche de convolution est le cœur d'un CNN, où la plupart des calculs sont effectués. Elle utilise des données d'entrée, un filtre (également appelé noyau) et produit une carte de caractéristiques (ou feature map). Imaginons que notre entrée soit une image en couleur, représentée

par une matrice de pixels en 3D avec des dimensions de hauteur, largeur et profondeur, correspondant aux canaux Rouge, Vert et Bleu (RVB) de l'image [15].

Le filtre, ou détecteur de caractéristiques, est une matrice de poids bidimensionnelle (2D) qui parcourt les champs réceptifs de l'image pour détecter des caractéristiques spécifiques. Habituellement, le filtre est une matrice de taille 3x3, déterminant ainsi la taille du champ réceptif. Il est appliqué à une région de l'image, et un produit scalaire est calculé entre les valeurs de pixels de l'entrée et les valeurs du filtre. Ce produit scalaire est intégré dans une matrice de sortie, appelée carte de caractéristiques ou feature map. Le filtre se déplace ensuite d'une étape et le processus est répété jusqu'à ce que le filtre ait balayé toute l'image [15].

La figure I.2 expose un exemple d'une convolution :




FIGURE I.2 – Convolution avec un noyau de taille 3*3. Source [16].

Notons qu'une convolution 3x3 de profondeur 1 effectuée sur une carte de caractéristiques d'entrée 5x5, également de profondeur 1. Comme il y a neuf emplacements 3x3 possibles pour extraire les tuiles de la carte de caractéristiques 5x5, cette convolution génère une carte de caractéristiques de sortie 3x3. Après chaque opération de convolution, une fonction d'activation ReLU (Rectified Linear Unit) comme mentionné sur la figure I.3 est généralement appliquée à la carte de caractéristiques. Cela introduit une non-linéarité dans le modèle en remplaçant les valeurs négatives par zéro [15].

ReLU est une fonction qui doit être appliquée à chaque pixel d'une image après convolution, et remplace chaque valeur négative par un 0. Si cette fonction n'est pas appliquée, la fonction créée sera linéaire et le problème XOR persiste puisque dans la couche de convolution, aucune fonction d'activation n'est appliquée [16].




FIGURE I.3 – Fonction d'activation (ReLU).

ReLU est très utilisée dans les réseaux de neurones à convolution car il s'agit d'une fonction rapide à calculer : $f(y) = \max(0, y)$. Sa performance est donc meilleure que d'autres fonctions où des opérations coûteuses doivent être effectuées.

Il est important de noter qu'une couche de convolution peut être suivie par une autre couche de convolution. Dans ce cas, le CNN peut devenir hiérarchique, permettant aux couches suivantes de voir des caractéristiques plus complexes en utilisant les caractéristiques extraites par les couches précédentes. Par exemple, dans la reconnaissance d'un vélo dans une image, les parties individuelles du vélo (cadre, guidon, roues, etc.) peuvent être considérées comme des caractéristiques de bas niveau, tandis que la combinaison de ces caractéristiques forme des schémas de plus haut niveau, créant ainsi une hiérarchie de caractéristiques dans le CNN [15].

2- La couche de pooling

Les couches de pooling, également connues sous le nom de couches de sous-échantillonnage, sont utilisées dans les CNN pour réduire la dimensionnalité des données, ce qui permet de diminuer le nombre de paramètres d'entrée. Contrairement à la couche de convolution, la couche de pooling n'utilise pas de poids de filtre. Au lieu de cela, elle applique une opération d'agrégation aux valeurs du champ réceptif et produit une matrice de sortie. Il existe deux principaux types de pooling :

1. Max pooling : Pendant le balayage du filtre sur l'entrée, le pixel ayant la valeur maximale dans le champ réceptif est sélectionné et transmis à la matrice de sortie. Cette approche est généralement plus courante que l'average pooling.

2. Average pooling : Pendant le balayage du filtre sur l'entrée, la valeur moyenne des pixels dans le champ réceptif est calculée et transmise à la matrice de sortie.

présentons sur la figure I.4, un exemple de max pooling et de l'average pooling.

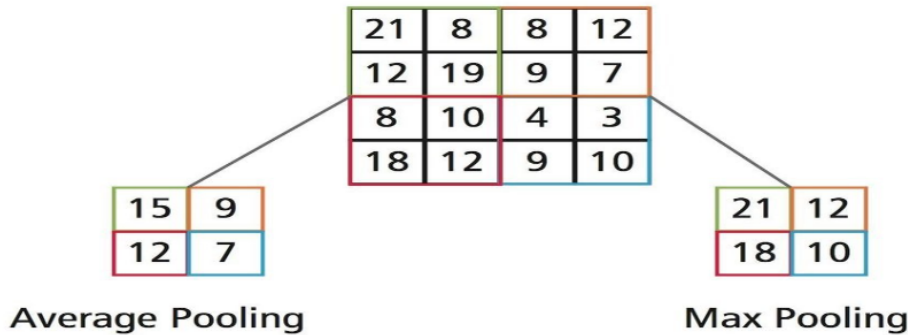


FIGURE I.4 – Exemples du max pooling et de l'average pooling.

Malgré la perte d'informations qui peut survenir lors de l'opération de pooling, cette couche présente plusieurs avantages pour le CNN. Elle contribue à réduire la complexité du modèle en diminuant le nombre de paramètres, ce qui peut améliorer l'efficacité du réseau. De plus, le pooling peut aider à prévenir le surajustement en réduisant le risque de surapprentissage aux données d'entraînement.

3- La couche fully-connected (entièrement connectée)

La couche entièrement connectée est ainsi nommée car chaque nœud de la couche de sortie est directement connecté à tous les nœuds de la couche précédente. Cela signifie que chaque caractéristique extraite des couches précédentes est prise en compte dans la classification finale. Contrairement aux couches de convolution et de pooling qui utilisent souvent des fonctions ReLU pour introduire de la non-linéarité, les couches entièrement connectées exploitent généralement la fonction d'activation softmax. Cette fonction attribue des probabilités à chaque classe possible, permettant ainsi une classification appropriée en attribuant des scores de probabilité entre 0 et 1 à chaque classe [15].

I.5 Vocation de quelques modèles des réseaux de neurones convolutif

I.5.1 U-NET

U-Net est une architecture d'apprentissage en profondeur largement utilisée pour les tâches de segmentation d'images dans le domaine de l'analyse d'images médicales. Développée par Ronneberger et ses collègues, elle a été introduite en 2015 et est rapidement devenue l'une des architectures les plus populaires pour l'analyse d'images biomédicales.

Cette architecture se compose d'une phase de contraction chargée de collecter les informations contextuelles et d'une phase d'expansion chargée de la localisation précise. La phase de contraction comprend une série de couches convolutives suivies de couches de regroupement maximum pour réduire l'échelle de l'image et augmenter le champ récepteur.

La phase d'expansion comprend une série de couches de suréchantillonnage suivies de couches de convolution pour augmenter la résolution de l'image et affiner la segmentation.

U-Net intègre également des connexions de saut entre les chemins réduits et étendus, permettant aux modèles d'utiliser des informations contextuelles locales et globales tout en conservant des détails précis. Cela le rend particulièrement efficace pour segmenter des images présentant des structures complexes telles que les organes dans les images médicales.

Dans l'ensemble, U-Net s'est avéré excellent dans diverses tâches de segmentation d'images médicales, et son architecture a été adaptée et étendue à d'autres domaines tels que la vision par ordinateur et le traitement du langage naturel. La figure I.5 montre l'architecture du modèle U-NET :




FIGURE I.5 – Architecture du modèle U-NET. [17].

I.5.2 VGG-16

Le modèle VGG-16 est une architecture de réseau neuronal convolutif (CNN) proposée par le groupe de géométrie visuelle (VGG) de l'Université d'Oxford. Il se distingue par sa profondeur, comprenant 16 couches au total, dont 13 couches convolutionnelles et 3 couches entièrement connectées. VGG-16 est renommé pour sa simplicité et son efficacité, ainsi que sa capacité à obtenir de solides performances dans diverses tâches de vision par ordinateur, notamment la classification d'images et la reconnaissance d'objets. L'architecture du modèle comprend une série de couches convolutionnelles suivies de couches de max-pooling, avec une profondeur progressivement croissante. Cette conception permet au modèle d'apprendre des représentations hiérarchiques complexes des caractéristiques visuelles, conduisant à des prédictions robustes et précises. Malgré sa simplicité par rapport aux architectures plus récentes, VGG-16 reste un choix populaire pour de nombreuses applications d'apprentissage en profondeur en raison de sa polyvalence et de ses excellentes performances [18].

Le défi de reconnaissance visuelle à grande échelle ImageNet (ILSVRC) est une compétition annuelle en vision par ordinateur où les équipes s'attaquent à des tâches telles que la localisation d'objets et la classification d'images. VGG16, proposé par Karen Simonyan et Andrew Zisserman en 2014, a obtenu les meilleurs résultats dans les deux tâches, détectant des objets

parmi 200 classes et classifiant les images dans 1000 catégories. L'architecture de VGG-16 est illustrée par les schémas de la figure I.6 .




FIGURE I.6 – Architecture de VGG-16. Source [18].

I.5.3 ResNet

ResNet est une architecture de réseau de neurones profonds introduite par des chercheurs de Microsoft Research en 2015. Le terme "ResNet" vient de "Réseaux Résiduels" et vise à résoudre le problème de la disparition des gradients dans les réseaux de neurones profonds, où les gradients deviennent très petits lors de leur propagation à travers le réseau pendant l'entraînement. La principale innovation de ResNet réside dans l'utilisation de connexions résiduelles, qui permettent au réseau d'apprendre des mappages résiduels plutôt que des mappages directs. Une connexion résiduelle saute une ou plusieurs couches du réseau et ajoute la sortie des couches sautées à la sortie des couches suivantes. Cela permet au réseau d'apprendre des mappages résiduels plus faciles à optimiser et d'éviter le problème de la disparition des gradients. L'architecture ResNet se compose d'une série de blocs résiduels, chacun composé de plusieurs couches convolutionnelles, de couches de normalisation par lots, de fonctions d'activation ReLU et de connexions de raccourci. Les connexions de raccourci permettent au réseau d'apprendre le mappage résiduel en propageant le gradient vers l'arrière à travers les couches ignorées. ResNet est une architecture très profonde, avec jusqu'à 152 couches dans sa plus grande version. Malgré sa profondeur, ResNet a atteint des performances de pointe dans diverses tâches de vision par ordinateur, telles que la classification d'images, la détection d'objets et la segmentation. Il a été

largement adopté dans les universités et l'industrie et est devenu une architecture standard. Son objectif principal est de résoudre le problème de la dégradation du gradient, qui se manifeste dans les réseaux très profonds où la précision commence à être saturée puis diminue rapidement en raison de la diminution des valeurs des gradients. Les blocs résiduels ont été introduits pour résoudre ce problème [19]. L'architecture de ResNet est illustrée par les schémas de la figure I.7

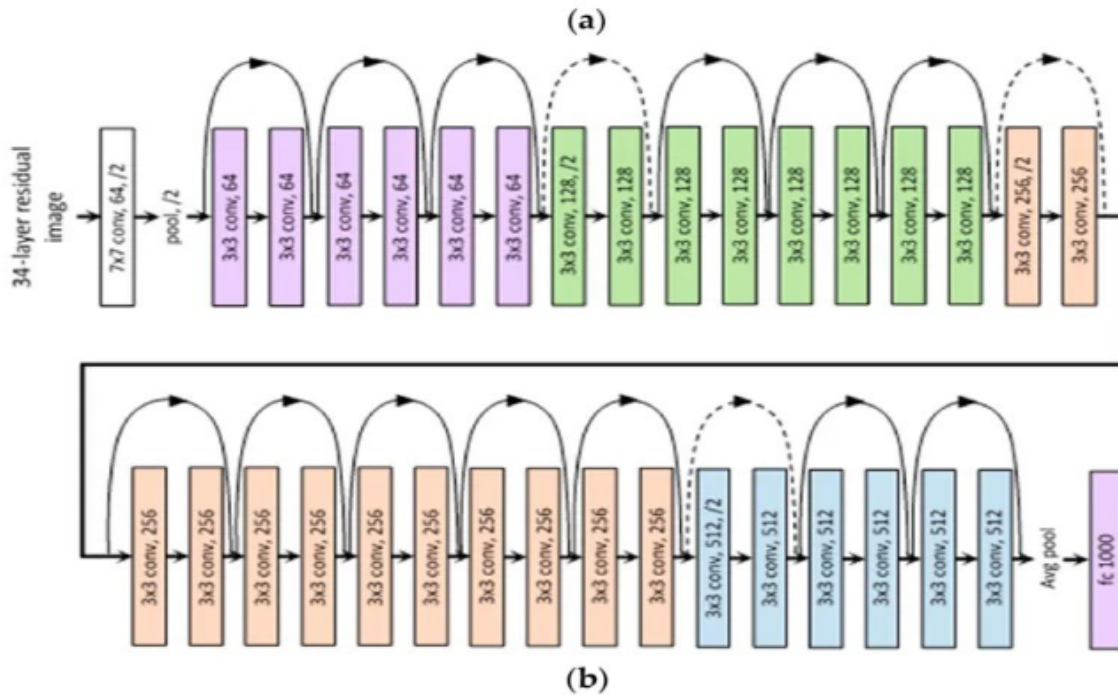


FIGURE I.7 – Architecture ResNet. Source [20].

I.5.4 R-CNN

R-CNN, ou Réseau Convolutif Basé sur les Régions, est un type de modèle d'apprentissage en profondeur utilisé pour la détection d'objets dans des tâches de vision par ordinateur. Le terme "R-CNN" fait en réalité référence à une famille de modèles qui partagent une approche commune de la détection d'objets. L'idée clé derrière R-CNN est de diviser la tâche de détection d'objets en deux étapes : la proposition de régions et la classification d'objets [21].

Les étapes de fonctionnement d'un RCNN sont les suivantes :

Réseau de Proposition de Régions (RPN) : Dans la première étape, le modèle génère un ensemble de propositions de régions susceptibles de contenir des objets. Ces propositions sont des boîtes englobantes potentielles autour des objets dans l'image. Le réseau de proposition de

régions est chargé de suggérer ces régions candidates [21].

Région d'Intérêt (RoI) Pooling : Une fois que les propositions de régions sont générées, chaque région est découpée de l'image et redimensionnée à une taille fixe. Ce processus est appelé RoI pooling, et il garantit que la région d'intérêt est représentée de manière cohérente dans une carte de caractéristiques de taille fixe, indépendamment de la taille ou du rapport d'aspect de la proposition de région d'origine [21].

Extraction de Caractéristiques : Les régions découpées et redimensionnées sont ensuite passées à travers un réseau neuronal convolutif (CNN) pré-entraîné pour extraire les caractéristiques de chaque région [21].

Classification d'Objets et Régression de Boîte Englobante : Les caractéristiques extraites de chaque région sont utilisées pour deux tâches : la classification d'objets et la régression de boîtes englobantes. La classification d'objets implique de déterminer la classe de l'objet dans la région, et la régression de boîtes englobantes affine les coordonnées de la boîte englobante autour de l'objet [21].

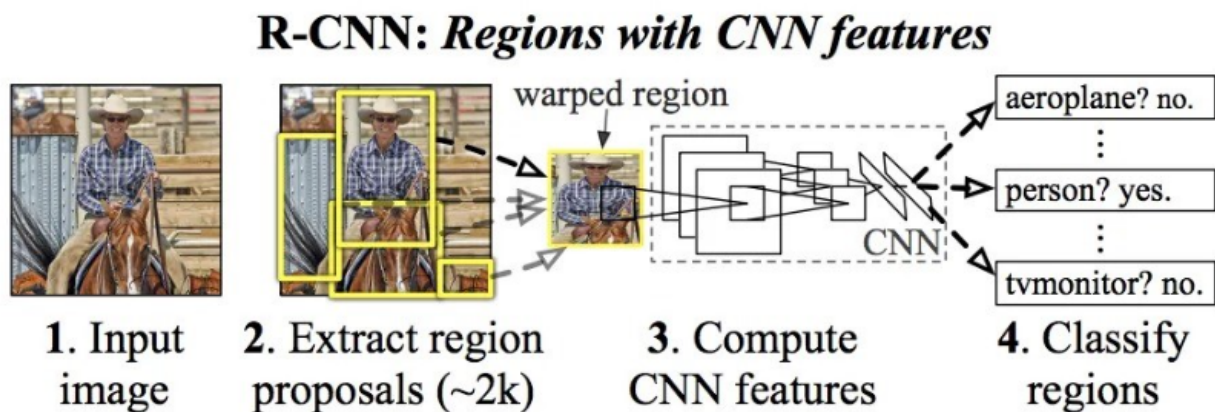


FIGURE I.8 – Architecture de RCNN. Source [22].

RCNN a été révolutionnaire lors de son introduction car il a considérablement amélioré la précision de la détection d'objets par rapport aux méthodes précédentes. Cependant, il peut être coûteux en termes de calcul en raison de son processus en plusieurs étapes, ce qui a conduit à des développements ultérieurs tels que Fast R-CNN, Faster R-CNN et Mask R-CNN, qui visaient à améliorer la vitesse et la précision.

I.5.5 Fast R-CNN

Cette approche a été proposée pour améliorer la vitesse de traitement de RCNN avec une structure mentionnée sur la figure I.9. Plutôt que de traiter chaque région proposée séparément, Fast R-CNN utilise une seule passe de convolution sur l'image entière pour extraire les caractéristiques. Ensuite, il utilise ces caractéristiques pour classifier les régions proposées et ajuster les boîtes englobantes. Cela rend Fast R-CNN plus rapide que RCNN, car il partage les calculs de convolution entre les différentes régions.




FIGURE I.9 – Architecture de Fast R-CNN. Source [21].

I.5.6 Faster R-CNN

Cette extension de Fast R-CNN introduit un composant supplémentaire appelé "Région Proposal Network" (RPN). Plutôt que d'utiliser une méthode de proposition de régions externe comme sélective search, Faster R-CNN utilise le RPN pour générer les propositions de régions de manière intégrée dans le réseau. Cela rend le processus global plus rapide et plus fluide, car toutes les étapes sont optimisées ensemble. Nous présentons sur la figure I.10 l'architecture de Faster R-CNN.

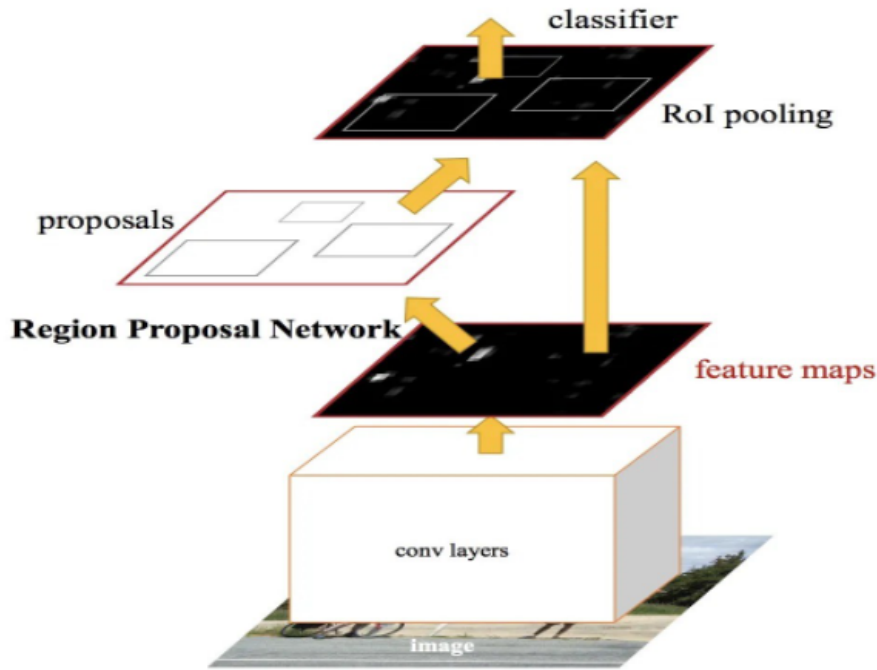


FIGURE I.10 – Architecture de Faster R-CNN. Source [23].

I.5.7 Mask R-CNN

Mask R-CNN est un modèle d'apprentissage profond conçu pour la détection d'objets et la segmentation d'instances, renommé pour sa précision et son efficacité. Sa force réside dans sa capacité à identifier et à délimiter précisément chaque objet dans une image, le rendant très efficace pour les tâches complexes d'analyse d'image. Le modèle a été développé par des chercheurs de Facebook AI Research en 2017 et s'appuie sur le modèle de détection d'objets Faster R-CNN en ajoutant une branche pour prédire les masques d'objets en parallèle avec la branche existante pour la détection de boîtes englobantes. L'architecture de Mask R-CNN se compose de trois composants principaux : un réseau de base, un réseau de proposition de régions (RPN), et deux branches parallèles pour la détection de boîtes englobantes et la prédiction de masques, comme illustré dans la figure I. 11. Le réseau de base est généralement un réseau neuronal convolutif (CNN) qui extrait des caractéristiques des images d'entrée et est partagé par les deux branches. Le RPN génère un ensemble de propositions de régions susceptibles de contenir des objets, basé sur les cartes de caractéristiques générées par le réseau de base. La branche de boîtes englobantes prédit l'étiquette de classe et les coordonnées de la boîte englobante pour chaque proposition de région, tandis que la branche de masques prédit un masque binaire pour chaque instance d'objet à l'intérieur de la boîte englobante [24].

L'article de recherche présenté par Kaiming He, Georgia Gkioxari, Piotr Dollár et Ross Girshick en 2017 a introduit Mask R-CNN, une extension de Faster R-CNN pour la segmentation d'instances. Voici un résumé de son fonctionnement [25] :

1. **Détection d'objets** : Comme Faster R-CNN, Mask R-CNN utilise un réseau de neurones convolutionnels (CNN) pour détecter les objets dans une image. Il propose des régions d'intérêt à l'aide d'un Région Proposal Network (RPN).
2. **Extraction de caractéristiques** : Une fois les régions d'intérêt générées, l'image passe à travers un réseau de neurones convolutionnels pour extraire des caractéristiques. Ces caractéristiques sont utilisées pour classifier les régions d'intérêt et prédire les boîtes englobantes pour chaque objet.
3. **Segmentation des masques** : Contrairement à Faster R-CNN, qui prédit seulement des boîtes englobantes, Mask R-CNN ajoute une branche supplémentaire au réseau qui prédit un masque pixel par pixel pour chaque région d'intérêt. Cela permet de segmenter précisément les contours des objets dans l'image.
4. **Entraînement conjoint** : L'ensemble du réseau, y compris le RPN, le réseau de détection d'objets et le réseau de segmentation de masques, est entraîné de manière conjointe. Cela permet à Mask R-CNN d'apprendre à détecter les objets et à segmenter leurs masques simultanément.

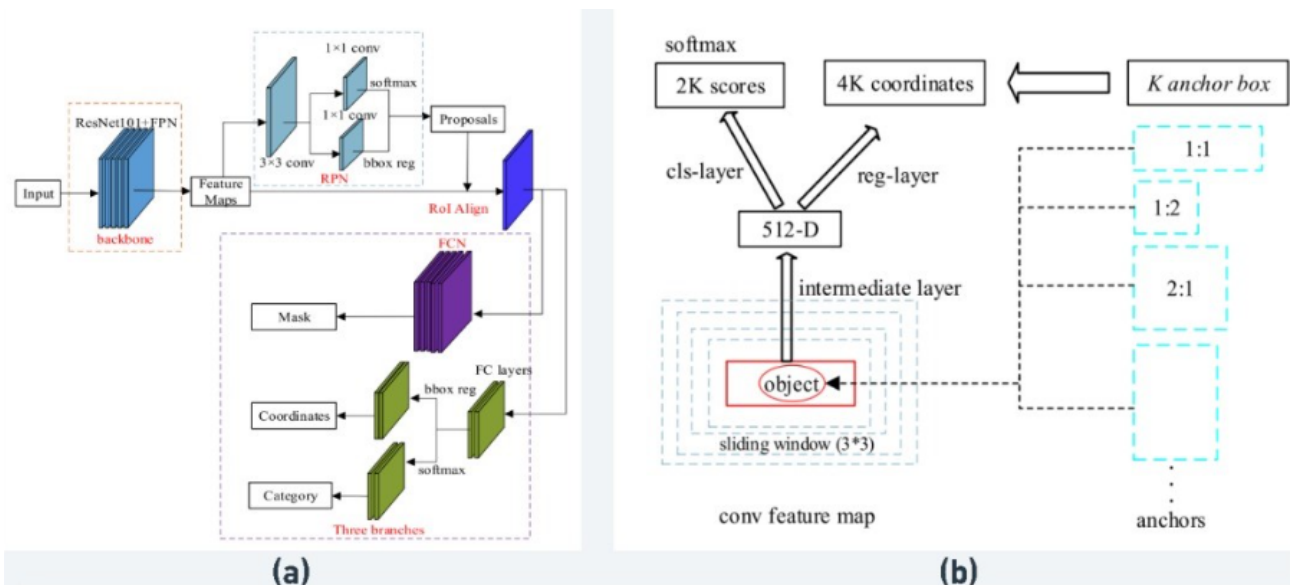


FIGURE I.11 – L'architecture de Mask R-CNN avec (a) : un diagramme de structure mettant en évidence le réseau de base, le RPN, les branches de détection de boîtes englobantes et de prédiction de masques, et en (b) : une vue détaillée du réseau de proposition de régions (RPN) [24].

Mask R-CNN peut détecter les objets dans une image tout en segmentant précisément leurs contours. Cela le rend particulièrement utile pour des tâches comme la détection d'objets et la segmentation sémantique, où une localisation précise des objets est nécessaire.

I.5.8 YOLO

You Only Look Once (YOLO) propose d'utiliser un réseau neuronal de bout en bout qui fait des prédictions de boîtes englobantes et de probabilités de classe en une seule fois. Il diffère de l'approche suivie par les algorithmes précédents de détection d'objets, qui réutilisaient des classificateurs pour effectuer la détection. Adoptant une approche fondamentalement différente de la détection d'objets, YOLO a obtenu des résultats de pointe, surpassant de loin les autres algorithmes de détection d'objets en temps réel. Alors que des algorithmes comme Faster RCNN fonctionnent en détectant les régions d'intérêt possibles à l'aide du Region Proposal Network, puis en effectuant la reconnaissance sur ces régions séparément, YOLO réalise toutes ses prédictions à l'aide d'une seule couche entièrement connectée. Les méthodes utilisant des Region Proposal Networks effectuent plusieurs itérations pour la même image, tandis que YOLO s'en tire avec une seule itération [26]. You Only Look Once (YOLO) est un algorithme de détection d'objets en temps réel de pointe, introduit en 2015 par Joseph Redmon, Santosh Divvala, Ross Girshick et Ali Farhadi dans leur célèbre article de recherche "You Only Look Once : Unified, Real-Time Object Detection".

Les méthodes de détection basées sur l'apprentissage profond peuvent être regroupées en deux étapes : la première est appelée algorithmes de détection à deux étages qui font des prédictions en plusieurs étapes, comprenant des réseaux tels que RCNN, Fast-RCNN et d'autres, la deuxième classe de détecteurs est appelée détecteurs à un étage tels que SSD, EfficientDet et notre YOLO.

Bien que YOLO ne soit pas le seul modèle de détection en une étape, il est généralement plus efficace que les autres en termes de vitesse et de précision. Après tout, si l'on considère le problème de détection comme une approche de régression en une étape pour déterminer la boîte englobante, les modèles YOLO sont souvent très rapides et très petits, ce qui les rend plus rapides à apprendre et plus faciles à déployer, surtout sur des appareils avec des ressources informatiques limitées.

Le modèle YOLO de base prédit des images à 45 images par seconde (IPS) sur un GPU Titan X. Les auteurs ont également développé une version beaucoup plus légère de YOLO appelée Fast YOLO, qui comporte moins de couches et traite les images à 155 IPS.

Ainsi, YOLO a atteint 63,4 mAP (précision moyenne), plus du double de celle des autres détecteurs en temps réel, ce qui le rend encore plus spécial. Tant YOLO que Fast YOLO surpassent largement les variantes de détecteurs d'objets en temps réel DPM en termes de précision moyenne (presque deux fois plus) et d'IPS (FPS).

TABLE I.1 – Comparaison de YOLO avec d'autres modèles en temps réel.

Real-Time Detectors	Train	mAP	FPS
100Hz DPM	2007	16.0	100
30Hz DPM	2007	26.1	30
Fast YOLO	2007+2012	52.7	155
YOLO	2007+2012	63.4	45

Les auteurs posent le problème de détection d'objets comme un problème de régression plutôt qu'une tâche de classification en séparant spatialement les boîtes englobantes et en associant des probabilités à chacune des images détectées à l'aide d'un seul réseau neuronal convolutif (CNN). la figure I. 12 illustre une chronologie du développement de YOLO au cours des dernières années.

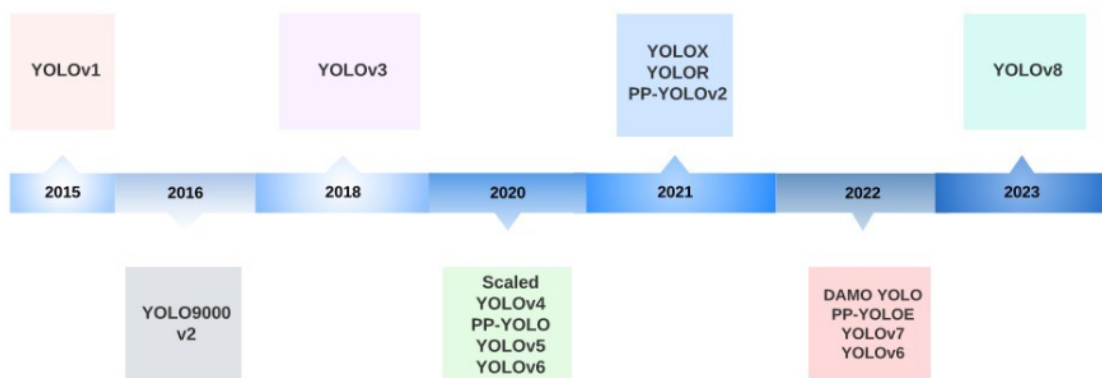


FIGURE I.12 – Une chronologie des versions de YOLO. Source [27].

L'algorithme YOLO prend une image en entrée, puis utilise un simple réseau neuronal convolutif profond pour détecter les objets dans l'image. la figure I. 13 l'architecture du modèle CNN qui forme l'épine dorsale de YOLO est illustrée ci-dessous.

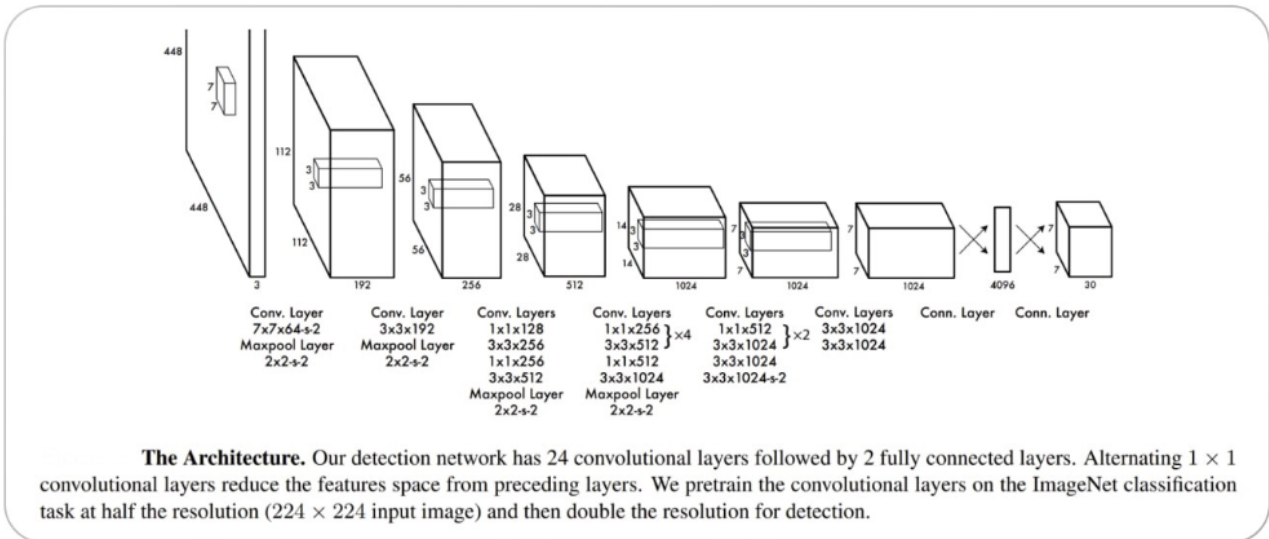


FIGURE I.13 – Architecture de YOLO . Source [26].

Les 20 premières couches de convolution du modèle sont pré-entraînées en utilisant ImageNet en ajoutant temporairement une couche de pooling moyenne et une couche entièrement connectée. Ensuite, ce modèle pré-entraîné est converti pour effectuer la détection, car des recherches antérieures ont montré que l'ajout de couches de convolution et connectées à un réseau pré-entraîné améliore les performances. La couche entièrement connectée finale de YOLO prédit à la fois les probabilités de classe et les coordonnées des boîtes englobantes.

YOLO divise une image d'entrée en une grille $S \times S$. Si le centre d'un objet tombe dans une cellule de grille, cette cellule de grille est responsable de détecter cet objet. Chaque cellule de grille prédit B boîtes englobantes et des scores de confiance pour ces boîtes. Ces scores de confiance reflètent à quel point le modèle est confiant que la boîte contient un objet et à quel point il pense que la boîte prédite est précise.

YOLO prédit plusieurs boîtes englobantes par cellule de grille. Pendant l'entraînement, nous voulons qu'un seul prédicteur de boîte englobante soit responsable de chaque objet. YOLO attribue un prédicteur pour être "responsable" de la prédiction d'un objet en fonction de la prédiction ayant actuellement le plus haut IOU avec la vérité terrain. Cela conduit à une spécialisation entre les prédicteurs de boîtes englobantes. Chaque prédicteur devient meilleur pour prévoir certaines tailles, rapports d'aspect ou classes d'objets, améliorant ainsi le score de rappel global. Nous présentons sur la figure I.14 un exemple de fonctionnement de YOLO.

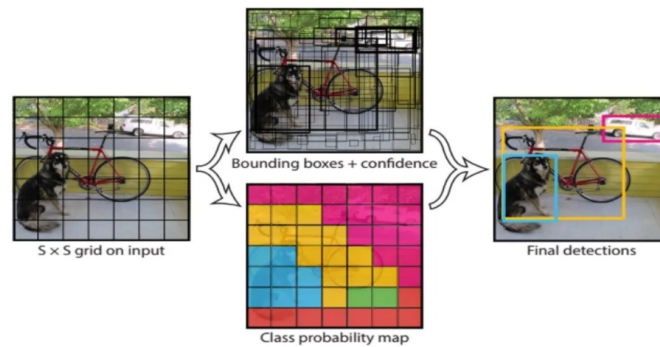


FIGURE I.14 – Exemple de fonctionnement de YOLO. Source [28].

Une technique clé utilisée dans les modèles YOLO est la suppression non maximale (NMS). La NMS est une étape de post-traitement utilisée pour améliorer la précision et l'efficacité de la détection d'objets. En détection d'objets, il est courant que plusieurs boîtes englobantes soient générées pour un seul objet dans une image. Ces boîtes englobantes peuvent se chevaucher ou être situées à des positions différentes, mais elles représentent toutes le même objet. La NMS est utilisée pour identifier et supprimer les boîtes englobantes redondantes ou incorrectes et pour produire une seule boîte englobante pour chaque objet dans l'image.

• YOLOv2

Après sa première introduction en 2016, la famille de modèles YOLO continue à évoluer chaque année. Par exemple, l'année suivante, le YOLOv2 a été publié, recevant une mention honorable à CVPR 2017. Un certain nombre d'améliorations itératives ont été apportées à l'architecture sur la base de YOLO, notamment BatchNorm, une résolution plus élevée et des boîtes d'ancrage. Le YOLOv2 amélioré a utilisé diverses nouvelles techniques pour surpasser les méthodes actuelles telles que Faster-RCNN et SSD à la fois en vitesse et en précision. Une de ces techniques était l'apprentissage multi-échelle, qui permettait au réseau de prédire à différentes tailles de données d'entrée, permettant un compromis entre vitesse et précision.

À une résolution de données d'entrée de 416×416 , YOLOv2 a atteint 76,8 mAP sur l'ensemble de données VOC 2007 et 67 IPS sur le GPU Titan X. Sur le même ensemble de données de 544×544 , YOLOv2 a atteint 78,6 mAP et 40 IPS.

• YOLOv3

En 2018, les développeurs Redmon et Farhadi ont publié YOLOv3, qui s'appuie sur les modèles précédents en ajoutant une estimation d'objectivité aux prédictions de boîtes englobantes, en

ajoutant des connexions aux couches du réseau de référence, et en faisant des prédictions à trois niveaux de détail distincts pour améliorer les performances sur les petits objets. Il est entraîné sur différentes résolutions d'image telles que 320×320 , 416×416 . À une résolution de 320×320 , YOLOv3 atteint 28,2 mAP à 45 IPS sur un GPU Titan X et a la même précision que le détecteur à déclenchement unique (SSD321), mais 3 fois plus rapide.

Après la sortie de YOLOv3, Joseph Redmon s'est éloigné de la recherche en vision par ordinateur. Ensuite, le chercheur Alexey Bochkovsky et des innovateurs tels que Glenn Jocher ont commencé à rendre leurs avancées en vision par ordinateur open source.

- **YOLOv4**

En avril 2020, Alexey Bochkovsky a publié YOLOv4. Il s'agit de son premier travail dans la "famille YOLO" qui n'a pas été rédigé par Joseph Redmon. YOLOv4 est le résultat de nombreuses expérimentations et recherches, combinant diverses petites nouvelles techniques pour améliorer la précision et la vitesse du réseau neuronal convolutif. Dans cet article, des expériences approfondies sur différentes architectures de GPU ont été menées et ont montré que YOLOv4 surpasse toutes les autres architectures de réseaux de détection d'objets en termes de vitesse et de précision.

- **YOLOv5**

YOLOv5 a été publié en juin 2020, seulement deux mois après YOLOv4, par Glenn Jocher. Il s'agit à son tour du premier modèle de la "famille YOLO" qui n'a pas été publié avec un document accompagnant et est donc en "développement continu" dans le référentiel. Cela a suscité une certaine controverse au début, mais cette notion a rapidement été dissipée alors que ses capacités étaient sous-estimées par le bruit. YOLOv5 propose une famille d'architectures de détection d'objets pré-entraînées sur l'ensemble de données MS COCO. Il a été suivi de la sortie d'EfficientDet et de YOLOv4. Aujourd'hui, le modèle est l'un des modèles officiels de pointe avec un soutien énorme et une utilisation plus facile en production. La version 5 est implémentée nativement en PyTorch, supprimant les limitations du framework Darknet (basé sur le langage de programmation C et non conçu pour les environnements de production).

- **YOLOv6**

YOLOv6 publié dès 2022, est une itération du tronc et du cou YOLO, les redessinant en tenant compte du matériel - introduisant ce qu'ils appellent le Backbone EfficientRep et le Neck Rep-

PAN. Dans les modèles YOLO jusqu'à YOLOv5 inclus, les têtes de classification et de régression de boîtes utilisent les mêmes caractéristiques. Dans YOLOv6, les têtes sont séparées, c'est-à-dire que le réseau dispose de couches supplémentaires séparant ces caractéristiques de la tête finale, ce qui a montré empiriquement une augmentation des performances. Le modèle YOLOv6 simule l'ensemble de données COCO de manière plus précise que YOLOv5 à un débit de sortie comparable. Cela a été testé sur un GPU Tesla V100.

• YOLOv7

YOLOv7 disponible en juillet 2022, est le détecteur d'objets en temps réel le plus récent et le plus performant de la famille YOLO. Cette version est actuellement considérée comme le détecteur d'objets en temps réel le plus rapide et le plus précis. Ce modèle contient toutes les techniques d'entraînement avancées les plus récentes des réseaux de neurones profonds. Dans YOLOv7, les auteurs s'appuient sur la recherche effectuée sur ce sujet, en tenant compte de la quantité de mémoire nécessaire pour stocker les couches en mémoire et de la distance parcourue par le gradient pour se propager à travers les couches - plus le gradient est court, plus le réseau sera capable d'apprendre efficacement. Ils ont choisi la dernière agrégation de couche E-ELAN, une version étendue de l'unité de calcul ELAN.

• YOLOv8

YOLOv8 lancé le 10 janvier 2023, est la dernière version de YOLO. Ultralytics a développé YOLOv8. Ce modèle de pointe s'appuie sur les succès des versions précédentes de YOLO et intègre de nouvelles avancées pour améliorer ses performances et sa polyvalence tout en dépassant les performances des versions précédentes comme mentionné sur la figure I.15.




FIGURE I.15 – comparaison de YOLOv8 par rapport aux modèles précédents. Source [29].

YOLOv8, la dernière version du modèle à un étage, a été construite sur les fondations fournies par les modèles YOLO précédents, tels que YOLOv3 et YOLOv5. Comparé aux modèles à deux étages, YOLOv8 prédit directement les boîtes englobantes et les probabilités de classe sans avoir besoin d'un réseau de proposition de régions séparé, simplifiant ainsi le processus de détection d'objets. Une innovation clé dans YOLOv8 est l'adoption d'une approche sans ancrage, centrée sur l'objet, pour la détection d'objets, qui offre plusieurs avantages par rapport aux méthodes traditionnelles basées sur des ancres telles que YOLOv5, YOLOv6 et YOLOv7. YOLOv8 met en œuvre l'Ensemble Pseudo ou la Supervision Pseudo (PS), une méthode qui consiste à entraîner plusieurs modèles avec des configurations distinctes sur le même ensemble de données pour générer un ensemble de prédictions plus diversifié, améliorant la précision et la robustesse de la prédiction finale. De plus, YOLOv8 exploite l'architecture Darknet-53, un réseau neuronal convolutif profond de 53 couches optimisé pour l'extraction de caractéristiques et la détection d'objets. Un changement architectural significatif dans YOLOv8 est le remplacement du module C3 par le module C2F. Le module C3, également appelé module convolutif, traite les données d'entrée à travers une série d'opérations convolutives. Le module C2F, une version améliorée du module C3, améliore la précision et les temps de traitement par rapport aux modèles précédents. De plus, YOLOv8 substitue la couche de convolution 6x6 par une couche de convolution 3x3 dans le réseau de base du modèle, réduisant le nombre de paramètres et créant un réseau plus compact et plus efficace en termes de calcul. YOLOv8 utilise également une tête désolidarisée, qui sépare les tâches de prédiction de la présence d'objet et de classification des types d'objet, améliorant ainsi à la fois la précision et la vitesse de traitement. Cette amélioration positionne YOLOv8 comme une solution efficace pour la détection d'objets et la segmentation d'instances en vision par ordinateur [24].

L'une des principales forces de YOLOv8 est sa polyvalence. En tant que framework prenant en charge tous les modèles YOLO précédents, il est facile pour les utilisateurs de passer d'une version à l'autre et d'évaluer leurs performances, ce qui en fait un excellent choix pour ceux qui souhaitent utiliser la dernière technologie YOLO tout en étant capable d'utiliser leurs anciens modèles. En plus de sa polyvalence, YOLOv8 présente plusieurs autres innovations qui en font un candidat solide pour une large gamme de tâches de détection d'objets et de segmentation d'images. Celles-ci incluent un nouveau réseau de base, une tête de détection sans ancrage et une fonction de perte. De plus, YOLOv8 est très efficace et peut fonctionner sur une variété de matériels, des CPU aux GPU.

I.6 Conclusion

Dans ce chapitre, nous avons fourni un aperçu détaillé des piliers fondamentaux de l'analyse d'images et de la vision par ordinateur, voire plus, les paradigmes d'intelligence artificielle à savoir l'apprentissage automatique et l'apprentissage profond. Dans le prochain chapitre, nous détaillerons les éventuels dommages qui peuvent intervenir au niveau des moteurs d'avion et l'état de l'art traitant la détection automatique de ces dangereux dommages pouvant causer les craches d'avions. En effet, nous exposerons notre problématique de recherche dans ce sens.

CHAPITRE II

DETECTION AUTOMATIQUE DES
DOMMAGES SURGISSANT AU NIVEAU DU
MOTEUR AÉRIEN BASÉE SUR LES
PARADIGMES DE L'INTELLIGENCE
ARTIFICIELLE : PROBLÉMATIQUE ET
ÉTAT DE L'ART

II.1 Introduction

En maintenance des moteurs d'avion, la première inspection effectuée se fait par voie boroscopique. En effet, elle désigne un processus à forte intensité de main-d'œuvre utilisé pour détecter les défauts des moteurs d'avion qui contiennent des zones non visibles lors d'une inspection visuelle générale. Un borescope est inséré dans le moteur et ceci eu dessus de l'aile et ainsi les pièces rotatives sont inspectées.

L'inspecteur doit examiner chaque pale pour déceler des repères de dommage. Si un dommage est observé, il doit être enregistré et quantifié quant à son acceptabilité. L'inspection se déroule dans un environ critique avec plusieurs contraintes, telles que la complexité de l'arrière-plan, les vues restreintes, l'éclairage restreint, une résolution en pixels limitée, la distraction et la pression du temps.

Le résultat du processus en grande partie dépend du jugement des professionnels de maintenance qui l'effectuent. Dans ce sens, la nécessité d'une détection automatique n'a cessé d'accroître pour palier aux erreurs de détection des dommages causant parfois le crash d'un avion.

II.2 Aperçu sur le moteur aérien

Le moteur aéronautique offre une alimentation électrique constante à l'avion et joue un rôle clé dans le domaine de l'aviation, comme le montre la figure. Le moteur d'avion est composé de milliers de composants, et tous subissent des conditions de fonctionnement défavorables, dues à des températures élevées ou un rayonnement intense à une fraîcheur glaciale, engendrant que le fait que les composants soient constamment stables et exécutant normalement une tâche difficile, un réel défi [30]. Il est donc d'une grande importance d'agir en temps opportun et surveiller de manière non destructive l'état des composants du moteur d'avion, éliminant ainsi le risque que les avions peuvent rencontrer dans l'air. La pale d'un moteur d'avion désigne un de ses composants clés, elle tourne à haute vitesse pour offrir une poussée vers l'avant, subissant un environnement délicat. L'état de la pale détermine si le moteur d'avion peut fonctionner ou non. Nous présentons sur la figure II.1 une coupe transversale d'un moteur d'avion.




FIGURE II.1 – Coupe transversale d'un moteur d'avion. Source [30].

Les composants des moteurs d'avion sont soumis à divers facteurs internes et externes tels que les vibrations, les températures élevées, la vitesse de rotation, le frottement, la corrosion et les corps étrangers. Tous ces facteurs combinés peuvent provoquer des contraintes internes et des dommages matériels pouvant potentiellement provoquer une défaillance d'une pièce au fil du temps. Par conséquent, pour assurer la sécurité du fonctionnement, les moteurs d'avion sont inspectés fréquemment, soit après un nombre défini d'heures de vol (par exemple, 15 000 à

20000) ou cycles de vol, c'est-à-dire le nombre de vols du début à l'atterrissage (par exemple, 5000 à 10000) [30]. Les pièces rotatives telles que les pales du moteur sont soumises à une usure et déchirure plus importantes par rapport aux composants statiques. A cet effet, un entretien préventif et des inspections fréquentes pourront prolonger la durée de vie de ces composants, économisant ainsi les coûts de matériel de la compagnie aérienne. Récemment, comme le montre la figure II.2, le moteur d'avion brûlé et blessé provenait d'un avion Boeing 777-200 d'United Airlines le 20 février 2021 [6]. Le moteur a subi une panne inattendue, ce qui a conduit l'avion à effectuer un atterrissage d'urgence. Suite à une enquête menée par l'administration fédérale de l'aviation et transport national, ils ont révélé que deux pales de ventilateur s'étaient rompues. La cause de l'accident est une fracture au niveau de la pale du compresseur, sous l'action d'un flux d'air à grande vitesse, qui a engendré des dommages au moteur d'avant en arrière, provoquant l'incendie du moteur d'avion.




FIGURE II.2 – Cas de panne de moteur d'avion. en (a) : Boeing 777-200 avec moteur droit en feu , en (b) : Perspective agrandie, moteur droit en feu , en (c) : Enquêteurs vérifient l'avion , et en (d) : Deux pales cassées. Source [6].

II.3 Types de dommages du moteur aérien

Nous examinerons trois types de dommages courants subis par les moteurs aériens [2] :

Tourbillon

Ce composant est situé dans la chambre de combustion du moteur. Le carburant, une fois injecté par l'injecteur de carburant, il est entièrement mélangé à l'air à haute vitesse et haute pression dans le tourbillon. Lors de l'allumage, le carburant commence à brûler et libère une grande quantité de chaleur et de pression. Par conséquent, le tourbillon est soumis à une chaleur considérable à l'intérieur du moteur. Cela comprend les dépôts de carbone, la décoloration des métaux causée par température élevée et déformations/cracks/perte de composants causées par l'impact. De tels dommages sont mortels pour la chambre de combustion et menacent sérieusement le fonctionnement normal de la chambre de combustion.

Grand tuyau coudé

Ce composant est situé à l'extérieur de la chambre de combustion. Il dispose de nombreux événements pour aider à évacuer les gaz chauds après la combustion. C'est dans un contexte extrêmement environnement à haute température. De ce fait, son matériau présente des problèmes de fissuration et l'ablation de la dénaturation provoquée par une température élevée.

Pales de compresseur d'air / turbine

nous distinguons généralement un petit nombre d'images de dommages des pales de la turbine du fait que le borescope éprouve du mal à pénétrer jusqu'aux pales de la turbine. La principale menace pour ces composantes vient des corps étrangers inhalés ainsi que la matière et les molécules d'huile dans l'air. Les corps étrangers endommageront ou déformeront les pales et les molécules d'huile adhéreront aux pales, ce qui entraînera une dégradation des performances du moteur. Les pales de turbine se trouvent à proximité de la chambre de combustion, ce qui, en raison de la température élevée, peut également causer des dommages, y compris l'ablation/déformation de la pale, l'abrasion de la pointe de la pale et le gondolage provoqué par le frottement avec la paroi de la turbine.

II.4 Inspections visuelles du moteur d'avion

L'inspection visuelle est la vérification la plus courante des moteurs d'avion, car elle représente 90% de tous les contrôles non destructifs (CND) [31]. Le but de toute inspection est de garantir que les produits ou services d'une organisation répondent à une norme définie [31]. Il est donc essentiel de comprendre le degré de précision de l'inspection. C'est-à-dire dans quelle mesure les écarts par rapport à la norme sont détectés et la facilité des décisions d'entretien sont prises. La mesure la plus courante pour évaluer les performances de l'inspection est la précision de l'inspection. Ceci, par la considération des inspections correctes et incorrectes des produits défectueux et des pièces non défectueuses.

Des études antérieures ont analysé les performances de l'inspection dans le cadre des processus d'assurance qualité dans la fabrication et des inspections de fonctionnement dans les opérations de maintenance. Les précisions d'inspection obtenues vont de 67% à 76% et de 52% à 68%, respectivement. Dans le domaine de la maintenance aéronautique, l'inspection de plusieurs composants dont le fuselage de l'avion, les soutes, le train d'atterrissage et les composants et les pièces de moteur ont été abordés, où des taux d'inspection de 42% à 87% ont été rapportés. Toutes les études n'ont pas rapporté un taux de détection spécifique, car celui-ci dépend sur le type et la taille du dommage. Ainsi, les fissures et les bosses sont les défauts les plus couramment étudiés dans des études précédentes de la littérature.

II.4.1 Les tests non destructifs

Ils font référence à tous les types de tests menés pour comprendre la qualité, l'état, les performances et la structure interne du produit sans endommager la forme, la structure et les performances du produit [32]. Actuellement, les tests non destructifs sont largement utilisés dans le domaine de l'aviation, qui sont utilisés dans la détection des dommages du moteur de l'avion. Il existe de nombreux types de méthodes de contrôle non destructif en choisissant la méthode de test appropriée selon la situation. Nous distinguons cinq méthodes courantes [32] :

1. **Tests radiographiques** Des tests radiographiques sont utilisés pour détecter la discontinuité de la structure interne en utilisant l'atténuation de l'intensité des rayons (rayons X, rayons γ , rayons neutroniques...) traversant le matériau ou la pièce. La figure II.3 suivante montre le diagramme des tests radiographiques.




FIGURE II.3 – Radiographic Testing Diagram. Source [32].

2. **Tests par ultrasons** Quand l'onde ultrasonore se propage dans le matériau testé, le changement des caractéristiques d'acoustique et la structure interne du matériau ont un certain impact sur la propagation de l'onde ultrasonore. La technologie de compréhension du changement de la performance du matériau et de la structure grâce à la détection du degré et l'état de l'onde ultrasonore est appelé détection ultrasonique. La figure II.4 montre le schéma des tests par ultrasons.




FIGURE II.4 – Ultrasonic Testing Diagram. Source [32].

3. **Test de particules magnétiques** Contrôle non destructif de détection de la discontinuité entre la surface et la surface proche de l'éprouvette en utilisant la fuite du flux magnétique et le milieu de test approprié. La figure II.5 montre le diagramme des tests de particules magnétiques.




FIGURE II.5 – Magnetic Particle Testing Diagram. Source [32].

4. **Test de ressuage** L'action capillaire du liquide est utilisée pour pénétrer le perméat dans le défaut de la surface matérielle du solide. Le liquide pénétrant est alors adsorbé sur la surface pour montrer l'existence de défauts. Cette méthode de contrôle non destructif est appelée test de ressuage. La figure II.6 montre le processus de ressuage.




FIGURE II.6 – The Process of Penetrant Testing. Source [32].

5. **Tests par courants de Foucault** Le test par courants de Foucault est utilisé pour analyser la qualité interne de la pièce par les courants de Foucault induits par la bobine ferromagnétique dans la pièce. Le principe est indiqué ci-dessous :




FIGURE II.7 – Schematic Diagram of Eddy Current Testing. Source [32].

II.4.2 La détection des dommages du moteur d'avion par borescope

C'est un contrôle non destructif, cependant ses scénarios d'application sont différents de ceux ci-dessus. Dans les années 1960, avec le développement de la technologie de contrôle non destructif, la détection par borescope a été utilisée pour entretenir le moteur d'avion, progressivement, elle est devenue la principale technologie de surveillance et de diagnostic de dommages dans la maintenance des moteurs d'avion [32]. Le développement du borescope est passé par trois étapes : l'endoscope à tige dure, miroir à fibre optique à tube flexible et miroir électronique à tube flexible. Le miroir électronique à tube flexible est principalement composé de l'endoscope, du centre de traitement vidéo, de la source lumineuse, de l'image, système d'enregistrement...etc, Il utilise des éléments CCD pour convertir les images de l'objet observé du signal photoélectrique à un signal numérique, puis le transmet au centre de traitement vidéo. Enfin, il réalise l'objectif d'affichage et d'extraction de données. Le principe de base de la détection par borescope est d'utiliser les moyens optiques pour transmettre l'état interne du moteur à travers le trou, puis évaluer, inspecter et diagnostiquer l'image optique. La technologie de détection par borescope peut étendre la vue des êtres humains, changer la direction de la vue à volonté et observer avec précision l'état de la surface intérieure de l'objet. De plus, dans le processus de détection par borescope, il n'y a aucun contact avec le moteur, aucune destruction ou dommage, et aucun besoin de démonter l'objet cible. Par conséquent, il est devenu un moyen important de la technologie du contrôle non destructif des moteurs, et a un large éventail d'applications dans la détection de dommages dans un moteur d'avion. Nous présentons sur la figure II.8 ,un ingénieur en aéronautique effectuant la détection par borescope.




FIGURE II.8 – La détection par borescope. en (a) : L'ingénieur aéronautique effectue l'inspection à l'aide de borescope , en (b) : Ce que l'écran de l'borescope affiche. Source [36].

Pour la détection des dommages de surface des pales de moteurs d'avion, l'inspection par borescope est une technologie courante. Comme le montre la figure II.9 :

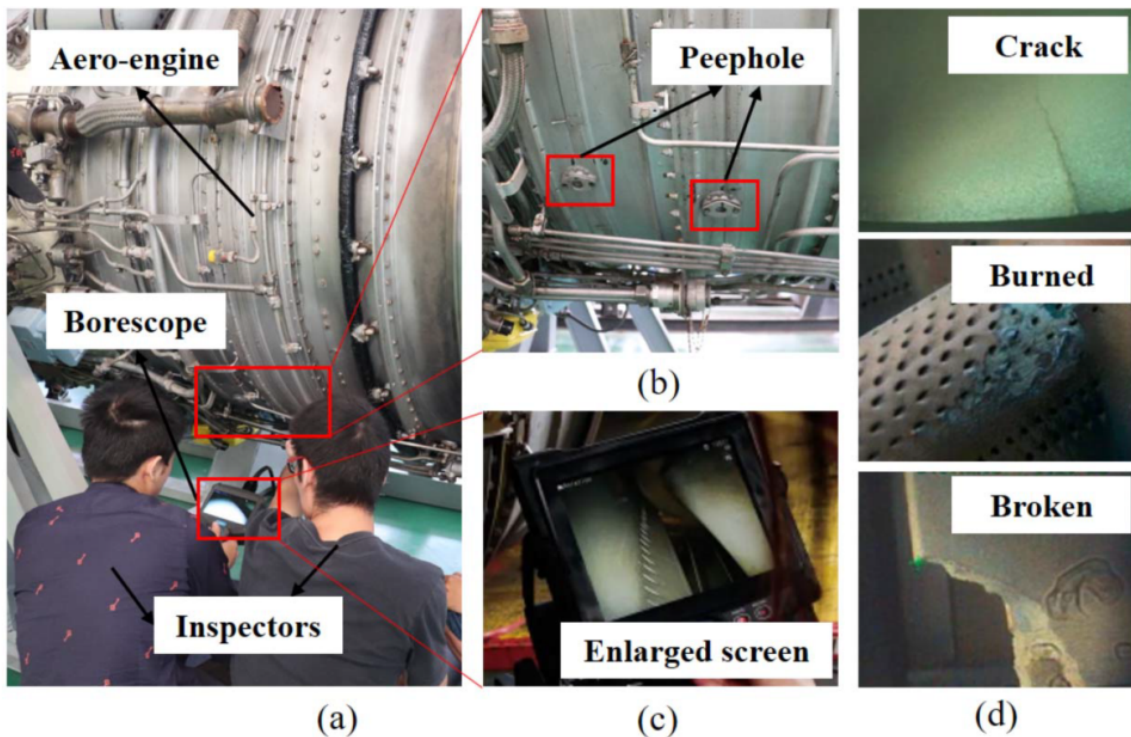


FIGURE II.9 – Diagramme schématique de l'inspection par borescope. en (a) : Les inspecteurs inspectent les pales du moteur , en (b) : Judas sur le moteur d'avion , en (c) : Agrandir l'écran du borescope , et en (d) : Trois types de dommages classiques aux pales. Source [6].

Nous allons détailler davantage le processus de détection des dommages par borescope comme présenté sur la figure. L'inspection par borescope est utilisée pour acquérir des images réelles de pales endommagées de moteurs d'avion [33], Comme le montre la figure II.10 , le processus d'inspection par borescope est le suivant :

1. Lorsque l'avion atterrit sur l'aire de trafic ou s'arrête dans le hangar, les militaires effectuent une inspection endoscope du moteur de l'avion. Ce processus nécessite la coopération de plusieurs personnes. Comme le montre la figure II.10 (a), on secoue le levier ou la pale du ventilateur la plus externe pour faire tourner lentement les pales du réseau multicouche pour l'inspection des pales une par une. L'un contrôle le tube de l'endoscope pour entrer dans le moteur d'avion depuis le judas et ajuste l'angle et la direction pour observer la perspective globale de la pale. On observe l'écran de borescope et analyse les dégâts selon l'expertise et le manuel d'entretien. De plus, un personnel auxiliaire doit avoir sur lui le manuel de maintenance pour référence et enregistrer les dommages lors de l'inspection.
2. Comme le montre la figure II.10 (b), il y a des judas correspondants à la position du compresseur du moteur d'avion pour une inspection par borescope. Le diamètre de ces judas est compris entre 5 mm et 8 mm, et le tube borescope sera inséré dans le moteur de l'avion à partir de ces judas pour inspecter les pales.
3. Comme le montre la figure II.10 (c), les militaires doivent utiliser soigneusement le borescope, regarder l'écran et effectuer une analyse qualitative et quantitative des dommages conformément à leurs connaissances professionnelles et à leur manuel de maintenance. Ce processus prend du temps et demande beaucoup de travail. Cela nécessite des compétences professionnelles élevées et une accumulation de connaissances de la part des inspecteurs.
4. Comme le montre la figure II.10 (d), l'écran du borescope présente la scène intérieure du moteur d'avion, et les militaires observent les images des pales sur l'écran en temps réel et portent un jugement. De plus, la photographie et l'enregistrement vidéo peuvent être utilisés pour générer des rapports d'inspection et accumuler des données.
5. Comme le montre la figure II.10 (e) à (g), nous montrons plusieurs exemples d'images de pales obtenues lors d'une inspection par borescope.

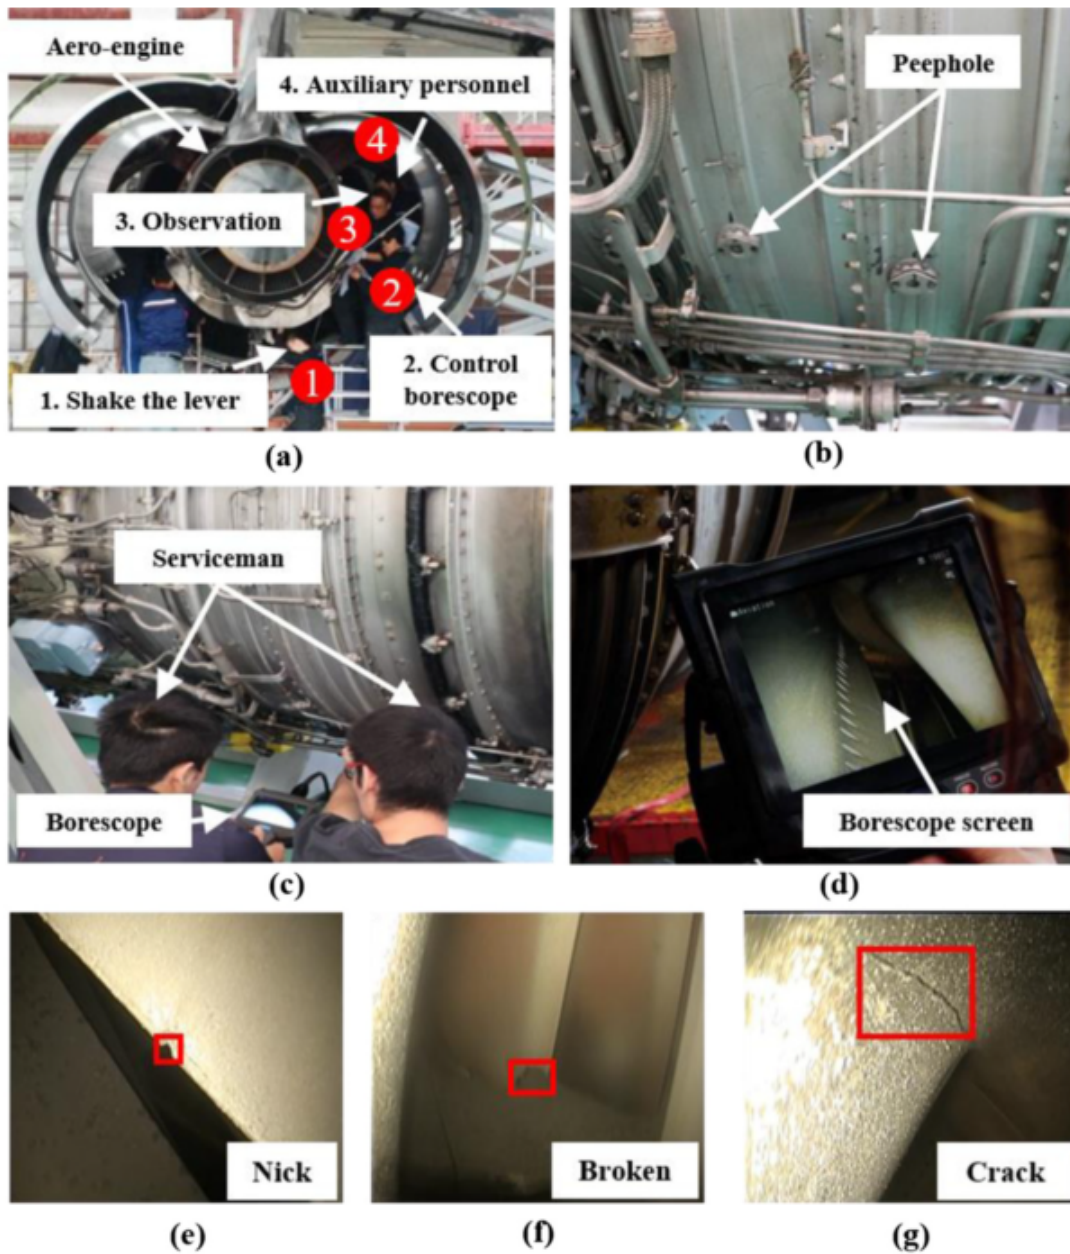


FIGURE II.10 – Processus inspection in-situ par borescope. Source [33].

L'inspection par borescope nécessite au moins trois inspecteurs plusieurs heures pour observer si la pale du moteur d'avion est endommagée. L'un est responsable du contrôle de la rotation de la pale, l'autre est responsable de contrôler la direction de l'extrémité avant du borescope, le dernier est responsable d'observer et de juger s'il y a eu un dommage. Nous résumons sept étapes de l'inspection par borescope en service de détection des dommages de surface des pales de moteurs d'avion comme suit [6] :

1- Formation professionnelle et apprentissage des connaissances :

L'inspecteur doit compléter l'étude de manuel de la maintenance ainsi que la technologie du borescope.

2- Attendez-vous sur l'aire de stationnement avec endoscope :

Après l'atterrissage de l'avion, les inspecteurs doivent emporter l'endoscope pour travailler sur l'aire de trafic.

3- Ouvrir les judas ou percer la buse arrière :

Ouvrez les judas et insérez le tube de l'endoscope. Montez dans le moteur depuis la tuyère arrière pour inspecter les pales de la turbine.

4- Faites tourner la pale et faites fonctionner l'endoscope :

Une personne secoue la pale à travers le manche, une autre fait fonctionner l'équipement de l'endoscope et les autres aident dans le travail.

5- Regardez fixement l'écran et inspectez la pale :

Les inspecteurs doivent juger si la pale est endommagée à l'œil nu, cela nécessite de grandes compétences et de riches connaissances.

6- Enregistrez les données et les journaux :

Une fois les dommages identifiés, les inspecteurs utilisent le borescope pour le prendre en photo sous différents angles et emplacements.

7- Générer un rapport d'inspection par endoscope :

Selon les données et les journaux enregistrés, un rapport global est généré sur l'analyse qualitative et quantitative.

II.4.3 La détection des dommages du moteur d'avion par la vision par ordinateur

L'ultime but consiste en l'utilisation de l'appareil photo et de l'ordinateur pour remplacer l'œil humain et reconnaître, suivre et mesurer la cible et effectuer un traitement graphique supplémentaire, afin que la cible devienne plus adaptée à l'observation de l'œil humain ou l'image transmise à l'instrument pour détection. Dans le domaine de la détection des dommages des moteurs d'avion, les chercheurs ont suivi deux directions : l'une est basée sur la technologie de traitement d'image traditionnel, telle que la détection de contour, la transformation en ondelettes, segmentation par seuillage. La seconde approche consiste à appliquer l'apprentissage profond pour la détection des dommages relatifs aux moteurs d'avion.

II.5 Problématique

À l'heure actuelle, les méthodes de détection des dommages de surface des composants de moteurs d'avions sont généralement incluses dans l'inspection par borescope. D'autre part, la poudre magnétique, le rayon, la pénétration, les courants de Foucault et les méthodes ultrasoniques ont obtenu de bonnes performances pour la détection de composants de moteurs d'avion, cependant de nombreux dommages sont trop petits pour être détectés avec ces méthodes, et la tâche de détection repose principalement sur des inspecteurs expérimentés, qui effectuent un travail intensif et peuvent facilement manquer de minuscules dommages. Il existe donc un besoin urgent de détection par approches issues de la vision par ordinateur qui peuvent remplacer les méthodes manuelles [34]. Nous allons souligner quelques points problématiques dans ce sens :

1. Les moteurs d'avion à turbine à gaz sont inspectés à intervalles réguliers ou après un incident connu (par exemple, impact d'oiseau). Alors que l'entretien, la réparation et la révision des moteurs sont cruciaux pour la sécurité des vols, ils sont principalement effectués par des opérateurs humains qui sont enclins à erreur. L'Association du transport aérien international (IATA) a indiqué que la maintenance et les erreurs d'inspection figurent parmi les trois principales causes d'accidents d'avion et cela dans 26% des cas [35]. Dans certains cas, un événement provoqué par la maintenance a déclenché la chaîne d'événements. Selon les enregistrements de la fédération d'autorité d'Aviation (FAA), la maintenance était impliquée dans 27,4% des décès et 6,8% des incidents. En outre, il a été signalé que des défaillances de composants ou de structures sont la principale cause première des incidents liés à la maintenance et qu'ils se produisent très probablement au niveau du moteur.
2. Boeing rapporte que le coût de réparation des dommages causés par le débris de corps étrangers peut dépasser 1 million de dollars pour une seule opération de révision par moteur, soit plus de 20% du prix catalogue du moteur. Par conséquent, la condamnation d'un moteur doit être effectuée avec prudence mais rapidement afin de minimiser les temps d'arrêt [4].
3. La pale du moteur d'avion est un élément essentiel de tout moteur d'avion, car il est exposé à certaines des conditions de fonctionnement les plus sévères en termes de température et de pression tout en fonctionnant à des vitesses extrêmement élevées. Tout dommage sur la pale peut entraîner l'arrêt du moteur vers le bas, provoquant des incidents [5]. Même si les processus de fabrication, de maintenance et de réparation ont considérablement

- amélioré au fil des années, il reste difficile de détecter des défauts minimes de la taille de 1 mm ou moins. Ces petits défauts continuent de présenter une menace considérable pour l'exploitation sûre des avions. À cet égard, diverses techniques et méthodologies sont continuellement développées pour automatiser le processus de détection des défauts des pales des moteurs d'avion [5].
4. L'inspection par borescope implique un grand progrès de travail humain. Pour l'inspection d'un seul moteur, le temps moyen dure environ 20 heures, pendant lesquelles les techniciens doivent être pleinement concentré afin de trouver avec précision tous les dégâts. Avec le développement fulgurant des compagnies aériennes ces dernières années, la méthode traditionnelle d'inspection par borescope humain ne peut pas répondre à la vaste demande ainsi qu'à l'exigence de haute précision pour l'inspection des dommages. Par conséquent, une mise en œuvre automatique est en ordre et des méthodes intelligentes qui peuvent extraire des informations sur les dommages au sein des images ou vidéos pour accélérer le processus d'inspection et améliorer la précision simultanément [37].
 5. Selon l'association du transport aérien international (IATA), les erreurs d'inspection et de maintenance des avions font partie des principales causes des accidents d'avion. L'aviation fédérale (FAA) a également signalé que 6,8% des accidents et 27,4% des décès sont causés par des erreurs de maintenance. Même s'il n'est pas toujours possible de fournir des statistiques sur le nombre exact d'incidents impliquant des dommages aux pales, la FAA a noté qu'entre 2008 et 2018, il y a eu plusieurs rapports de dysfonctionnements ou de pannes de moteur aux États-Unis. Les incidents récents ont mis en évidence la nécessité d'une intervention régulière et une inspection approfondie des pales pour prévenir les accidents et améliorer la sécurité des passagers et de l'équipage [5].
 6. Le point clé de l'identification des dommages du moteur d'avion est de traiter et extraire la zone de dommage, dans le processus d'analyse d'image, la méthode principale consiste à utiliser la segmentation d'image pour segmenter la zone de dommage de l'arrière-plan. Dans la détection des dommages du moteur interne, nous rencontrons les difficultés suivantes : premièrement, il existe de nombreux types de dommages internes du moteur et divers descripteurs d'images, il est donc impossible d'utiliser une segmentation unifiée pour les gérer. Deuxièmement, la majeure partie des algorithmes de segmentation d'image se basent sur le principe que le niveau de gris de la zone cible et la zone d'arrière-plan changent considérablement et la texture est claire. Cependant, la structure interne du moteur est complexe, la zone de défaut et la zone de fond sont mélangées ensemble, et

- même le niveau de gris de certains défauts n'est pas évident, et la texture de la zone de défaut est complexe, ce qui apporte de grandes difficultés à la segmentation des images. Basé sur les difficultés du traitement d'image traditionnel en reconnaissance de dommages dans les moteurs aériens, l'application de l'apprentissage profond est en ordre.
7. Dans le cadre des travaux pratiques, les ingénieurs doivent souvent inspecter le moteur pour vérifier s'il y a des dommages. Ils prennent les photos de l'intérieur par borescope, puis les analysent pour déterminer s'il y a un dommage. Dans ce cas, ils ont besoin de définir le type de dommage, la taille du dommage et autres informations. Cependant, le résultat final dépend de l'expérience personnelle d'ingénieurs, et différents ingénieurs peuvent arriver à des idées différentes en conclusion d'où le besoin d'une méthode automatique est en ordre.
 8. Le processus d'inspection est sujet à des tendances à l'erreur humaine ainsi qu'à un manque de précision, fiabilité, subjectivité, cohérence et répétabilité, entre autres facteurs. Manquer un défaut (faux négatif) lors d'une tâche d'inspection n'importe où sur cette chaîne peut potentiellement entraîner une panne moteur catastrophique, d'où un risque de dommages au moteur et au fuselage, ainsi que de graves dommages aux passagers, voire des décès. D'autre part, une détection faussement positive peut engager le moteur dans un processus de réparation inutile et coûteux en termes de temps et d'utilité financière. Par conséquent, les tâches d'inspection visuelle introduisent des points de décision clés dans le processus de maintenance, avec des conséquences considérables [35]. De plus, la maintenance du moteur est une tâche complexe, longue et coûteuse et une visite en atelier peut créer des coûts équivalents au prix catalogue du moteur. Ceci est très critique, car les contraintes de temps ne doivent pas avoir d'impact négatif sur la qualité de l'inspection, ce qui affecte la sécurité des passagers. Cela contribue en outre à l'erreur humaine et au risque de manquer un défaut critique.
 9. Le borescope est la première phase d'une séquence de plusieurs activités d'inspection. C'est une procédure dépendante de l'opérateur, longue et fastidieuse, l'inspecteur doit identifier une grande variété de défauts, avec différents degrés de gravité et emplacements sous différents angles. Cette activité éclaire la décision de laisser ou non le moteur continuer à voler, réduire l'intervalle d'inspection pour vérifier la propagation des défauts dans le temps, ou retirer le moteur pour l'entretien. Engager le moteur dans un processus de démontage (coûteux) permet d'autres moyens d'inspection, tant visuels que d'autres méthodes d'essais non destructifs (CND) à appliquer [35].

10. En raison de la complexité et de l'évolution de l'arrière-plan à l'intérieur du moteur, les images de blessures ne peuvent pas être aussi claires et précises de caractéristiques et de contours comme les images reconnues durant la vie quotidienne, ce qui apporte de grandes difficultés au traitement de l'image. En outre, de nombreux types de dégâts créent des obstacles pour cibler la détection [38].
11. Les cracks dans les pales de turbine peuvent affecter les performances de la turbine et présenter un risque pour la sécurité et la durée de vie. En effet, les pales de turbine sont particulièrement intéressantes, car elles sont complexes et très fines ainsi qu'exposées à des charges élevées et sont chimiquement très impurs. Cependant, l'identification manuelle des cracks dans les images prend du temps et nécessite des compétences et de l'expérience des spécialistes. Les cracks dans les bords de fuite des pales de turbine sont extrêmement petits (environ entre 8×6 et 8×34 pixels), ce qui donne le nombre de pixels représentant un crack étant significativement moins de 0,1% de l'intégralité des pixels d'une image. En effet, les cracks sont difficiles, voire impossibles, à identifier des gens non formés [39]. De plus aucune datasets n'est accessible au public. Les cracks du béton sont généralement plus courtes et moins larges, mais néanmoins beaucoup plus longues et plus larges que les cracks des pales de turbine.
12. Avec l'essor du développement des compagnies aériennes ces dernières années, les méthodes d'inspection visuelle ne peuvent pas répondre à la vaste demande, ni aux exigences de haute précision, pour l'inspection des cracks et d'autres dommages, en raison des fausses détections causées par la fatigue humaine. Par conséquent, une méthode automatique et intelligente qui peut extraire des informations sur les cracks à partir d'images ou de vidéos est nécessaire afin de réduire le travail humain et d'aider les ingénieurs de maintenance à accélérer le processus d'inspection et améliorer la précision simultanément. En outre, les structures de l'avion, en particulier l'arrière-plan interne du moteur, sont très complexes, et les performances de l'algorithme dans des environnements complexes sont très exigeantes [40]. En effet, l'éclairage se limite à la LED de diode du borescope intégrée, et est absorbé différemment selon la propreté et le revêtement [31]. De plus, la vue est limitée par la conception du moteur et le chevauchement des pales adjacentes. A cet effet, les attentes envers les inspecteurs de borescopes sont de trouver chaque défaut dans un environnement aussi difficile.
13. Les méthodes basées sur l'apprentissage profond nécessitent généralement des données massives pour l'apprentissage afin d'obtenir un modèle optimal. Cependant, la collecte de

données et la création d'étiquettes sont des tâches à la fois longues et laborieuses. D'autre part, nous nous trouvons face au défi de déséquilibre des données que nous le rencontrons fréquemment lors de la détection des dommages de pales de moteurs d'avion. Cela se produit lorsque les échantillons normaux sont largement plus nombreux que les données défectueuses ou les données d'apprentissage ne représentent pas toutes les catégories de dommages également. Cela peut entraîner un biais du modèle en faveur des classes surreprésentées et les mesures de performance telles que la précision et le rappel pourraient être trompeurs dans ce cas. Par exemple, un modèle qui atteint une grande précision peut toujours fonctionner mal à détecter les classes de défauts sous-représentées. Il est donc essentiel de remédier au déséquilibre des données pour garantir que le modèle puisse identifier avec précision toutes les catégories de défauts.

14. Un autre problème fatal est que la réalisation des étiquettes (labeling) doit être effectuée par des professionnels, sinon les erreurs d'étiquetage entraîneront des résultats indésirables, c'est-à-dire que la qualité de l'étiquette a un impact significatif sur les performances du modèle.

II.6 État de l'art sur la détection automatique des dommages surgissant au niveau du moteur aérien basée machine learning et deep learning

La sécurité du fonctionnement des moteurs d'avion joue un rôle croissant dans la vie des personnes, dans la fiabilité du transport aérien et dans les avantages économiques des compagnies aériennes. Pour effectuer efficacement l'inspection et la maintenance des moteurs d'avion, de nombreux chercheurs ont mené des études sur la surveillance de l'état de la structure, la surveillance des performances du trajet des gaz et la détection et l'identification des défauts de moteur d'avion [33]. En tant qu'élément important des moteurs d'avion, la fonction principale des pales est de comprimer l'air entrant dans le moteur et de produire beaucoup de poussées. Dans le processus de fonctionnement d'un moteur d'avion, les pales sont soumises à une force d'inertie centrifuge en raison de la rotation à grande vitesse, à une force aérodynamique en raison de l'écoulement du gaz, et elles sont également impactées par des corps étrangers. Des cracks, des bris, des brûlures, des déformations et d'autres dommages se produisent fréquemment. Sous l'action de la charge de fatigue composite, les dommages externes favoriseront la propagation du crack où ce dommage se produit souvent à proximité de la zone de concentra-

tion des contraintes. Les défauts de conception et les traces d'usinage au cours du processus de production deviennent également la source de cracks. Le bris est un autre type courant de dommages aux pales de moteurs d'avion. Pendant le décollage, l'atterrissage et le vol à basse altitude, l'impact d'objets étrangers transportés par un flux d'air à grande vitesse endommagera les pales du compresseur et une concentration de contraintes se produit généralement au niveau de la partie endommagée, qui devient exactement le crack. Les accidents catastrophiques et soudains provoqués par une défaillance des pales menacent sérieusement le fonctionnement sûr des moteurs d'avion. Il est donc nécessaire de vérifier régulièrement les pales pour garantir leur sécurité et leur fiabilité via des approches automatiques basées sur les paradigmes de l'intelligence artificielle. Dans ce sens, nous présentons dans le tableau suivant un état de l'art sur l'incorporation de l'intelligence artificielle au secteur aérien. Tableau II.1 Approches de détection automatique des dommages surgissant au niveau du moteur aérien.

TABLE II.1: Approches de détection automatique des dommages surgissant au niveau du moteur aérien.

Réf	Types de dommage	Méthode	Nombre d'images	Acc	mAP
[41]	Régions défectueuses ou normales	Un CNN avec deux couches convolutives et deux couches entièrement connectées sont déployées pour la classification des dommages soupçonnés où Scale-invariant feature transform (SIFT) est utilisé pour l'extraction des descripteurs.	420	95.2%	/
[42]	Crack,dent,corrosion, missing,material, TBC-missing	YOLOv5s est utilisé pour la détection de dommages.	850	83.8%	81.9%

[4]	Casing, Compressor-rotor, Surface-damage, Material-separation, Material-deformation	Mask R-CNN est utilisé pour la segmentation des dommages.	104	/	90%
[33]	Broken, Burned, Crack, Overheated	Utilisation d'un Mask R-cnn pour détecter les dommages et un réseau de fusion de caractéristiques multi-échelles axé sur la texture (TFNet) pour accorder davantage d'attention aux informations de texture peu profondes qui reflètent la forme des dommages.	524	94.17%	62.4%
[34]	scratch, crack, gap, pit	YOLOv5 et un clustering k-means sont utilisés pour la classification de dommages où un mécanisme d'attention ECA-Net a été ajouté à l'extrémité du réseau backbone pour que le modèle accorde plus d'attention à l'extraction de caractéristiques des zones de dommages.	3500	/	98.3%
[43]	ablation, crack, coating missing	Des réseaux de neurones convolutifs sont utilisés (FWNet) où dans le but d'augmenter encore le pouvoir de représentation du réseau, un nouveau module de pondération des caractéristiques (FWM) a été proposé.	1916	/	89.4%

[44]	Crack,burn	Un modèle CNN est propos pour identifier et localiser les dommages où l'architecture du modèle se compose de six blocs : 5 blocs convolutifs pour l'extraction de caractéristiques et 1 bloc convolutif transposé pour la récupération des régions endommagées.	1443	97.26%	/
[38]	Broken,burned,crack,nick,overheated	Un modèle Transformer qui modélise efficacement les relations pixel à pixel à l'aide d'un mécanisme global d'auto-attention, et une stratégie de fenêtre décalée est utilisée pour effectuer l'échange d'informations où la capacité de la modélisation globale est bénéfique pour capturer un aperçu détaillé des dommages.	3000 (Dataset simulée) 131 (dataset réelle)	/	84.9% 54.8%
[45]	Crack	Un modèle U-Net personnalisé est développée pour détecter les dommages sur les pales du compresseur haute pression où l'annotateur d'image VGG est utilisé pour la création des masques.	Vidéo issue d'un borescope	98%	/

II.7 Conclusion

Les modèles d'apprentissage profond ont montré un grand potentiel dans la détection des dommages du moteur d'avion tout en améliorant la précision et l'efficacité de l'inspection visuelle. Cependant, ces modèles s'appuient fortement sur les données d'apprentissage pour identifier et classer les dommages avec précision. Dans les cas où surviennent des dommages nouveaux ou émergents qui ne font pas partie des données d'apprentissage, ces modèles pourraient ne pas détecter de tels défauts.

Le principal défi des études examinées est l'incapacité pour détecter des classes nouvelles ou émergentes de défauts qui ont été non inclus dans la datasets d'apprentissage.

Compte tenu des difficultés liées à l'obtention d'un volume suffisant de données sur les dommages pour développer des modèles d'apprentissage profond pour l'inspection aéronautique des moteurs, l'acquisition en temps réel des dommages et l'apprentissage des modèles pendant le processus d'inspection pourrait résoudre ce problème. Nous présentons dans le chapitre suivant le modèle développé pour la détection automatique des dommages surgissant au niveau du moteur aérien basée sur les paradigmes de l'intelligence artificielle.

CHAPITRE III

APPROCHE PROPOSÉE POUR LA
DÉTECTION AUTOMATIQUE DES
DOMMAGES SURGISSANT AU NIVEAU DU
MOTEUR AÉRIEN

III.1 Introduction

La détection efficace des dommages techniques sur les moteurs d'avion est cruciale pour garantir la sécurité des vols et maintenir la fiabilité opérationnelle des avions. Dans ce contexte, nous proposons une approche novatrice basée sur l'analyse avancée d'images pour détecter les dommages potentiels aux composants du moteur.

Notre approche repose sur l'utilisation de techniques de traitement d'images et d'apprentissage en profondeur pour analyser les images des pièces internes des moteurs d'avion. En exploitant les caractéristiques visuelles distinctes des différents types de dommages, le système proposé vise à identifier de manière précise et rapide les dommages pouvant survenir dans les composants du moteur.

L'ultime but consiste à automatiser le processus de détection des dommages, réduisant ainsi la dépendance à l'égard de l'inspection humaine sujette à des erreurs et des biais. Cela permettra non seulement d'améliorer l'efficacité des opérations de maintenance, mais aussi de prévenir les pannes coûteuses et les risques pour la sécurité associés à des dommages non détectés.

III.2 Plan d'action

Une fois avoir discuté les points problématiques dans le chapitre précédant, nous exposerons dans cette sous-section le plan d'actions comme suit :

1. Puisque 90% des inspections en maintenance aéronautique sont effectuées visuellement classification aviation [35], nous nous trouvons face à la nécessité de comprendre le risque inhérent à un tel processus d'inspection. Dans ce travail, nous développons une approche automatique de détection des dommages assistant les tâches d'inspection visuelle des composant du moteur d'avion comme les pales par exemple. En effet, l'importance de ce travail réside dans le fait qu'une grande partie de la sécurité des systèmes aéronautiques dépend de la vigilance des inspections des opérateurs humains lors de la fabrication, de l'exploitation et de la maintenance des équipements techniques du système.
2. En automatisant le processus de détection, les modèles d'apprentissage profond peuvent aider à réduire le temps et le coût du travail manuel et améliorer la cohérence et la fiabilité de détection de défauts. Récemment, axé sur la vision par ordinateur, les approches couplées au deep learning sont apparues comme techniques efficaces de détection de défauts et efficaces pour diverses applications industrielles comme la prévision maintenance et l'optimisation des processus [5]. En s'entraînant sur une large gamme d'images, les modèles peuvent apprendre à reconnaître les caractéristiques indiquant des dommages à la pale, réduire le risque de défauts manqués et augmenter la vitesse de détection. La capacité des modèles d'apprentissage profond à automatiquement extraire et reconnaître les fonctionnalités en fait un outil précieux pour améliorer la détection des dommages du moteur aérien dans l'industrie aéronautique. Notons que les pales sont responsables de la majorité des pannes d'avions [5].
3. Nous proposons une approche basée sur l'apprentissage profond, qui non seulement peut détecter avec précision et efficacité les dommages sur les images du borescope mais l'approche proposée a aussi la capacité d'afficher à la fois les types et les régions de dommages sur les images d'entrée. Ensuite, il est typique d'utiliser des techniques d'augmentation des données pour à la fois améliorer les performances et ajouter de la robustesse au modèle, citons l'application des transformations telles que la rotation, le retournement et le zoom sur les images [37].

4. Dans l'opération de détection des dommages du moteur d'avion par l'apprentissage profond, nous aurons besoin de sélectionner un modèle approprié et d'importer une grande quantité de données de dommages pour entraîner le système de détection. D'autre part, il existe une disparité importante entre datasets ImageNet et les images issues des dommages du moteur aérien [38][32]. Par conséquent, nous ne pouvons utiliser aucun modèle pré-entraîné. Dans ce sens, nous avons collecté des données auprès de la compagnie aérienne « Air Algérie » pour la construction de notre propre datasets. Comparé à d'autres algorithmes, YOLOv8 avec ses différentes versions pourraient avoir un bon compromis entre précision de détection et vitesse de détection [38].
5. La détection automatique réduit le fardeau des techniciens et augmente la probabilité de détection des dommages et élimine également dans une plus grande mesure les dangers cachés des avions [2], ce qui peut être significatif. Dans ce travail, nous utilisons Roboflow pour étiqueter les dommages : en décrivant la zone endommagée, point par point, et en précisant sa classification.
6. Compte tenu de la présence de flou de mouvement, les contours de l'image sont améliorés par un filtre de netteté consistant en le filtre Gaussien. En effet, le processus de débruitage et de netteté améliore la qualité de l'image.

III.3 Méthodologie proposée pour la détection automatique des dommages surgissant au niveau du moteur aérien

L'architecture du système proposé est présentée sur la figure III.1 Le flux de travail automatique proposé dans ce travail pour l'évaluation des dommages sur les composants du moteur d'avion possède la possibilité d'analyse des flux vidéo et images collectées lors des inspections par borescope en vue de la détection d'éventuels dommages. Les avantages d'un cadre automatique incluent la suppression des préjugés humains, un processus de décision plus rapide, des gains possibles en termes de précision et, face à l'incertitude, la capacité de quantifier cette incertitude via des scores de validation [5].

Dans ce flux de travail, les flux vidéo et images collectés lors des inspections par borescope sont

stockés et entrés dans YOLOv8. La structure du composant dans la vidéo est déduite via un cadre de segmentation d'instance basé sur le deep learning. Dans la segmentation d'instance, chaque objet dans une image vidéo est détecté, classé et localisé avec un cadre de délimitation entourant l'objet. Dans cette zone de délimitation, l'objet est identifié par un masque qui met en évidence les pixels pertinents. L'originalité de ce travail s'étend et diffère des travaux précédents sur un aspect principal : la segmentation et classification de sept types de dommages.



FIGURE III.1 – Architecture générale du système proposé de détection automatique des dommages du moteur aérien.

Nous allons évoquer, à travers les sections suivantes, les étapes de segmentation ainsi que de reconnaissance des dommages surgissant au moteur des avions.

III.4 Segmentation et reconnaissance des dommages au moteur d'avion basées YOLOv8

III.4.1 Datasets utilisée

Dans la continuité du chapitre précédent, où nous avons exploré les risques associés aux dommages affectant les moteurs d'avion, nous avons constitué une datasets diversifiée sur ces dommages.

En effet, nous avons obtenu ces données, sous formes de vidéos (jusqu'à 20 vidéos) ainsi que d'images de borescopie à partir d'un borescope situé à la base de maintenance de la compagnie aérienne d'Air Algérie à Dar El Beida - Alger (DMAR). De plus, nous avons utilisé des vidéos de borescope publiées sur des plateformes en ligne spécialisées dans les inspections de moteurs d'avion (RVI) pour la phase de test. Cette diversité d'origines garantit une représentation exhaustive des différents types de dommages susceptibles de survenir dans les moteurs d'avion. La base de maintenance d'Air Algérie à Dar El Beida - Alger (DMAR) est reconnue comme l'une des plus grandes et des plus performantes en Afrique. Avec ses installations modernes et son expertise technique de pointe, la DMAR joue un rôle crucial dans la maintenance et la réparation des avions, contribuant ainsi à assurer la sécurité et la fiabilité des opérations aériennes d'Air Algérie [46]. Comme illustré sur la figure III.2, cette datasets comprend un éventail représentatif d'exemples significatifs de dommages potentiels sur les composants du moteur. Nous avons obtenu des données provenant des moteurs de différents avions d'Air Algérie dont le Boeing 737-700 (B737), le Boeing 737-800 (B738) et autres : de moteurs CFM International CFM56 ,de moteurs General Electric CF6 ,Et d'autres.



FIGURE III.2 – Exemples d'images de dommages surgissant au moteur d'avion.

Le borescope désigne un dispositif optique équipé d'une caméra et permet aux techniciens de réaliser des inspections visuelles détaillées à l'intérieur des moteurs d'avion. Cette méthode de collecte de données offre une vision précise et directe des éventuels dommages présents sur les composants du moteur, fournissant ainsi des exemples authentiques et représentatifs des problèmes rencontrés. Nous présentons sur la figure III.3 un borescope ainsi qu'une image obtenue par ce dernier.



FIGURE III.3 – Exemple de détection de dommages à l'aide d'un borescope en (a) : le borescope en question et en (b) : l'image acquise avec un dommage à la pale.

III.4.2 Prétraitements appliqués à la datasets

Conversion de la vidéo en frames

Nous avons trié les 20 vidéos en possession en fonction des types de dommages pertinents pour notre travail, où nous avons sélectionné 10 vidéos couvrant une variété de dommages. Par la suite, nous avons converti ces vidéos en une large collection de frames à l'aide de la bibliothèque OpenCV de Python, totalisant environ 30000 frames comme mentionné sur la figure III.4.

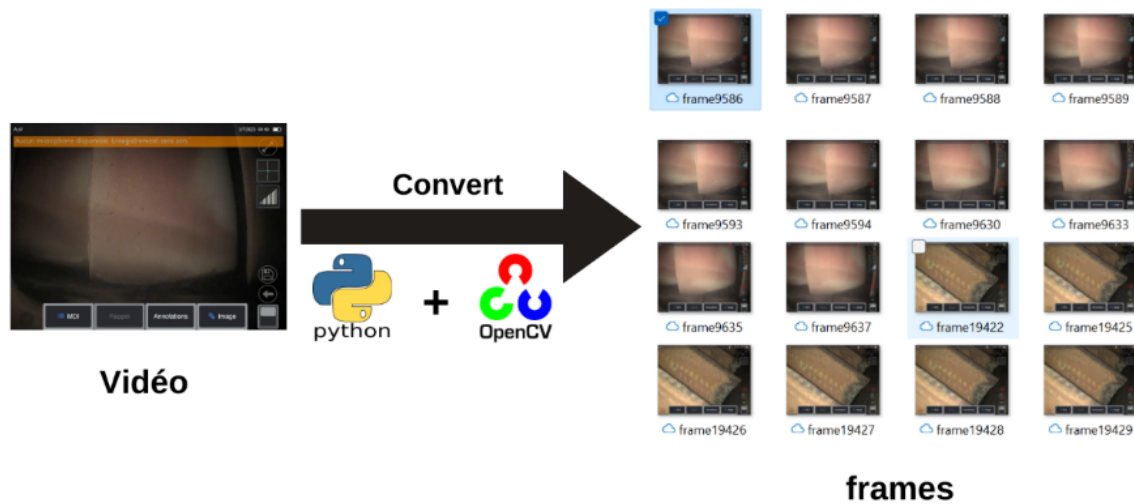


FIGURE III.4 – Exemple de la conversion d’une vidéo en un grand ensemble d’images.

Filtrage d’images par le filtre gaussien

Nous avons appliqué un filtre gaussien aux images pour lisser les détails et atténuer le bruit vu la puissance du filtre gaussien dans la suppression du moindre bruit au sein des images. Cela contribue à rendre les images plus nettes et plus esthétiques.

Augmentation de données

Nous avons obtenu 800 images de divers dommages, cependant, pour palier au problème du overfitting, nous avons opté pour la technique d’augmentation des données, également connue sous le nom de data augmentation, afin d’enrichir davantage la datasets. En effet, un grand nombre de données d’apprentissage améliore les performances du modèle de deep learning. L’augmentation des données est la technique permettant de créer un ensemble de données en modifiant l’ensemble de données d’origine, et également connu comme le processus de création de plusieurs copies de l’image originale avec différentes orientations. Nous avons appliqué les techniques suivantes d’augmentation de données :

1. Flip (Retournement) - Horizontal, Vertical : effectué des retournements horizontaux et verticaux sur les images. Cela permet d’augmenter la variabilité des images, car certaines informations visuelles peuvent apparaître différemment lorsqu’elles sont retournées.
2. 90° Rotate (Rotation de 90°) : effectuer des rotations de 90 degrés dans le sens horaire et antihoraire, ainsi que des rotations à l’envers. Cela permet de créer différentes perspectives des images, ce qui aide le modèle à apprendre à reconnaître les objets dans différentes orientations.
3. Hue (Teinte), Saturation (Saturation), Brightness (Luminosité), Exposure (Exposition) :

ajouter des variations aléatoires à la teinte, à la saturation, à la luminosité et à l'exposition des images. Cela aide à simuler différentes conditions d'éclairage et de couleur, ce qui rend le modèle plus robuste aux variations dans les conditions de prise de vue.

Suite à l'application de ces transformations de manière aléatoire à nos images, nous avons pu générer un total de 1190 images, ce qui enrichit considérablement notre datasets et permet à notre modèle d'apprentissage profond de mieux généraliser et de mieux performer lors de la phase d'apprentissage. Nous présentons sur la figure III.5 un exemple d'augmentation des données.





FIGURE III.5 – Exemple de l'application de l'augmentation des données.

La définition des classes de dommages à reconnaître

Effectivement, le choix des classes de dommages à reconnaître est une étape cruciale dans le traitement de la datasets. Il s'agit de diviser les images en plusieurs parties ou régions appartenant à des catégories spécifiques. Chaque classe représente un type de dommage potentiel sur les moteurs d'avion, ce qui simplifie l'analyse et la compréhension des données. En divisant notre ensemble de données en sept catégories distinctes, nous pouvons mieux étudier les différents types de dommages présents. Cela nous permet de développer des méthodes de détection plus précises et efficaces, car chaque classe représente un scénario spécifique que notre modèle doit reconnaître et classer correctement. Le choix de sept classes de dommages était par rapport aux données fournies par la compagnie aérienne d'air Algérie. En effet, elles représentent les sept dommages rencontrés auparavant. Nous présentons sur le tableau III.1, les sept catégories de dommages couvertes par notre système.

TABLE III.1: Les différentes catégories de dommages couverts par notre système.

Les classes	Types de dommages
	<p>Fissuré (Crack) : Les fissures sur les composants du moteur d'aéronef se manifestent par des lignes sombres et irrégulières. Elles peuvent être axiales, radiales ou circonférentielles. La taille de ces fissures peut varier de 1 à 50 millimètres, et leur durée est un critère majeur pour les inspecteurs lors de l'évaluation des dommages [6].souvent invisibles à l'œil nu. Elles peuvent se développer progressivement sous l'effet de contraintes mécaniques ou de cycles de charge et de décharge, ce qui peut conduire à une défaillance catastrophique si elles ne sont pas détectées et réparées à temps.</p>
	<p>Recourbé (Tip curl) : Ce type de dommage se produit lorsque les extrémités des composants, telles que les aubes des turbines, se déforment ou se courbent sous l'effet de contraintes mécaniques ou thermiques. Cela peut entraîner une mauvaise performance du moteur et une usure prématurée des composants. Leur taille peut varier de 10 à 50 millimètres carrés [6].</p>



Cassé (Broken) : Ce type de dommage se produit lorsqu'une partie du composant du moteur se brise ou se fracture, généralement en raison d'un choc ou d'une contrainte excessive. Lorsque le matériau de la lame est manquant ou n'est plus intact en raison d'impacts de corps étrangers ou de surchauffe, on observe des dommages cassés. Leur taille peut varier de 5 à 50 millimètres carrés, et les inspecteurs se basent sur la longueur et la profondeur de ces dommages pour évaluer leur gravité [6].



Nick : Les dommages de type nick se présentent sous une forme en V, avec une profondeur utilisée comme critère d'évaluation. Leur apparence comprend un fond clair et des côtés sombres, et ils sont généralement observés sur les composants du compresseur ou de la turbine [6]. Bien que les ébréchures puissent sembler mineures, elles peuvent compromettre l'intégrité du composant et entraîner des défaillances à long terme.



Surchauffé (Overheated) : Les dommages surchauffés sont fréquents sur les aubes de turbine et se caractérisent par des zones où le revêtement tombe. Leur taille peut varier de 10 à 50 millimètres carrés, et la plupart des zones endommagées prennent une teinte blanc grisâtre [6]. Ce dommage survient lorsque le composant est exposé à des températures excessives, ce qui peut provoquer une déformation, une décoloration ou d'autres altérations de ses propriétés physiques. Cela peut être causé par une surutilisation, un dysfonctionnement du système de refroidissement ou d'autres facteurs.



Brûlé (Burned) : Les dommages par brûlure surviennent lorsque le composant est exposé à des températures élevées. Les dommages brûlés sont caractérisés par un fond clair et des côtés sombres. Ils sont courants sur les turbines haute pression et dans la chambre de combustion. Leur taille peut varier de 10 à 50 millimètres carrés, et la zone endommagée est utilisée comme critère d'évaluation par les inspecteurs [6].



Corrosion : La corrosion est le résultat de l'interaction entre le matériau du composant et son environnement, souvent sous forme d'oxydation due à l'exposition à l'humidité, aux produits chimiques ou à d'autres agents corrosifs. Cela peut affaiblir le matériau et entraîner une détérioration progressive du composant.

Labelling des images et génération des masques à l'aide de Roboflow

Roboflow est choisi pour plusieurs raisons. Tout d'abord, c'est une plateforme qui offre une solution complète pour la gestion des données d'imagerie, de la collecte à la préparation en passant par l'annotation et l'entraînement des modèles. Cela simplifie considérablement le flux de travail, en réduisant le besoin de jongler entre plusieurs outils et plates-formes.

Roboflow propose une interface utilisateur conviviale et intuitive, ce qui rend la création et l'annotation de données d'image plus efficaces et accessibles même pour les utilisateurs novices. Cela permet à notre équipe de gagner du temps et de se concentrer davantage sur le développement de modèles et l'analyse des données.

De plus, Roboflow prend en charge une large gamme de formats de données et offre des fonctionnalités avancées telles que l'augmentation des données, la fusion de jeux de données et la visualisation des données. Cela nous permet d'effectuer des transformations complexes sur nos données d'image, ce qui peut améliorer les performances des modèles finaux.

Nous avons utilisé Roboflow pour créer des labels pour chaque classe de dommage identifiée dans nos données. Cela se fait généralement en plusieurs étapes :

1. Annotation des données : Nous marquons manuellement les zones d'intérêt dans nos images en utilisant des outils d'annotation fournis par Roboflow. Pour chaque type de dommage, nous identifions et dessinons des contours autour des zones concernées dans les images, ceci à l'aide des ingénieurs en aéronautique.
2. Génération des masques : Une fois que les annotations sont terminées, Roboflow génère automatiquement des masques pour chaque classe en utilisant les contours que nous avons

définis. Ces masques sont des images en niveaux de gris où chaque pixel appartient à une classe spécifique.

3. Application des masques : Les masques générés sont ensuite appliqués à nos images d'origine, créant ainsi des images segmentées où chaque classe de dommage est mise en évidence par un masque distinct. Cela nous permet de visualiser et d'analyser facilement les différentes régions de dommages dans nos données.

Nous présentons sur la figure III.6 des exemples de génération des masques par Roboflow.




FIGURE III.6 – Exemple de génération de labelling des dommages par Roboflow.

III.4.3 Implémentation de YOLOv8 pour la segmentation et la reconnaissance des dommages au sein du moteur aérien

Nous avons choisi la segmentation et la reconnaissance automatique d'instance pour spécifier nos besoins actuels car elle s'aligne parfaitement avec la méthode utilisée par les inspecteurs de borescope pour identifier avec précision les dommages. En effet, les inspecteurs capturent les dommages dans les images acquises à partir du borescope, puis identifient manuellement ces dommages à l'aide d'applications de bureau spéciales situées sur les ordinateurs du service de maintenance, comme illustré dans la figure III.7. En optant pour la segmentation et la reconnaissance automatique d'instance, nous avons pu adapter les masques pour chaque instance de dommage identifiée, ce qui nous permet de fournir des analyses plus précises et détaillées. Cette approche nous offre également une plus grande flexibilité pour traiter différents types de

dommages et améliorer la fiabilité de notre système d'identification des dommages au niveau du moteur de l'avion. Ceci, permettra d'effectuer la détection de dommages en fractions de secondes sans que le système ne s'influence par la fatigue subie par les inspecteurs vu le grand nombre d'images traitées ainsi que la diversité des dommages rencontrés.

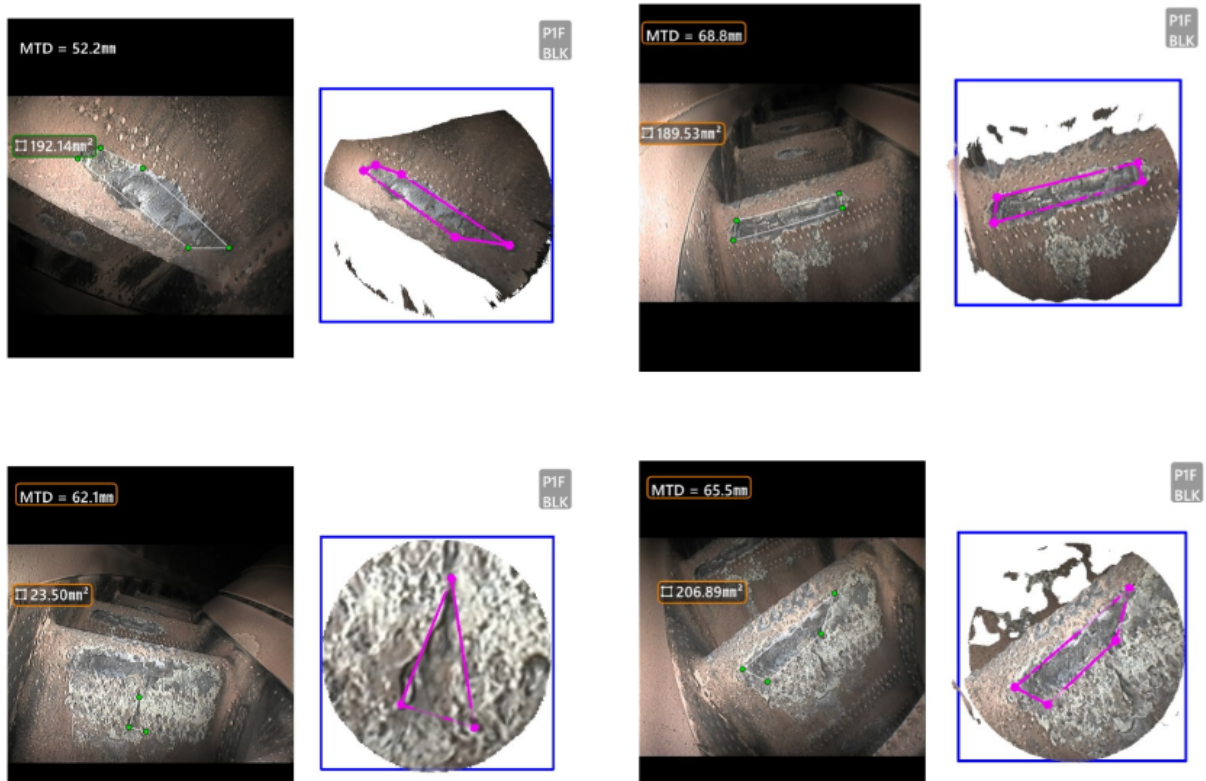


FIGURE III.7 – Exemples de méthodes utilisées par les inspecteurs de borescope pour la détection des dommages au sein de la base de maintenance d'Air Algérie.

Nous effectuons le même processus pour le labelling des dommages comme mentionné sur la figure III.8 à la différence que notre processus de segmentation des dommages s'effectue automatiquement mais avec le même principe suivi par les ingénieurs de maintenance.




FIGURE III.8 – Exemples de la méthode que nous avons adoptée pour la segmentation d’instance.

Nous avons utilisé les versions récentes du modèle YOLO, YOLOv8. Ces modèles possèdent une fonction de segmentation d’instance, étendant la tâche de détection d’objets pour prédire à la fois l’objet et sa forme en segmentant les objets du fond détecté. Avant de décider d’utiliser YOLOv8, nous avons envisagé d’autres modèles ayant des capacités en segmentation d’instance, tels que Mask R-CNN. Cependant, nous avons sélectionné YOLOv8 pour plusieurs raisons. Premièrement, la famille YOLO présente de bonnes performances dans les tâches de détection d’objets, les rendant compétitifs et adaptés à nos tâches de segmentation d’instance. Deuxièmement, les algorithmes des deux modèles ont été développés en utilisant PyTorch, un cadre open-source largement utilisé dans la communauté de l’apprentissage en profondeur, facilitant ainsi le processus d’entraînement et de test avec un ensemble de données personnalisé. Troisièmement, YOLOv8 a surpassé Mask R-CNN dans l’article de référence en détectant, segmentant et classant des objets spécifiques [47].

Le processus d’apprentissage de YOLO-V8 est configuré pour atteindre une vitesse significativement plus rapide par rapport aux modèles de segmentation d’objets en deux étapes, ce qui en fait une option efficace pour les projets avec des contraintes temporelles strictes. S’éloignant de la structure observée dans ultralytics/YOLO-V5, des modifications substantielles ont

été apportées à l'architecture du système. Cela a impliqué le remplacement de C3 par C2f et l'intégration du principe ELAN de YOLO-V7 [48].

YOLOv8 propose un modèle de segmentation d'instance appelé YOLOv8-seg, qui applique des principes inspirés de YOLACT pour la segmentation d'instance. La structure de YOLOv8-seg se compose de trois parties principales : la colonne vertébrale, le cou et la tête de segmentation, comme illustré dans la figure III.9. La colonne vertébrale de YOLOv8-seg initie l'extraction de caractéristiques à partir d'une image en utilisant une couche CSP modifiée appelée module C2f. Ce module agit comme un goulot d'étranglement inter-étape qui intègre une couche convolutive pour améliorer la précision de la détection en intégrant des caractéristiques de haut niveau. Ensuite, la couche SPPF extrait des informations des images à différentes échelles, ce qui améliore considérablement les capacités de généralisation du modèle. Le cou est similaire à celui de YOLOv8, un réseau de pyramide de caractéristiques (FPN), qui intègre des caractéristiques de tailles diverses. La tête se compose de branches de détection et de segmentation. La branche de détection produit la catégorie et la boîte englobante, tandis que la branche de segmentation produit les k prototypes ainsi que les k coefficients de masque. La détection et la segmentation sont calculées en parallèle dans la tête de segmentation, qui produit des sorties de segmentation à différentes échelles héritées de la partie précédente (cou). Enfin, les sorties de segmentation sont combinées pour produire une sortie unique, par exemple, la segmentation d'instance.

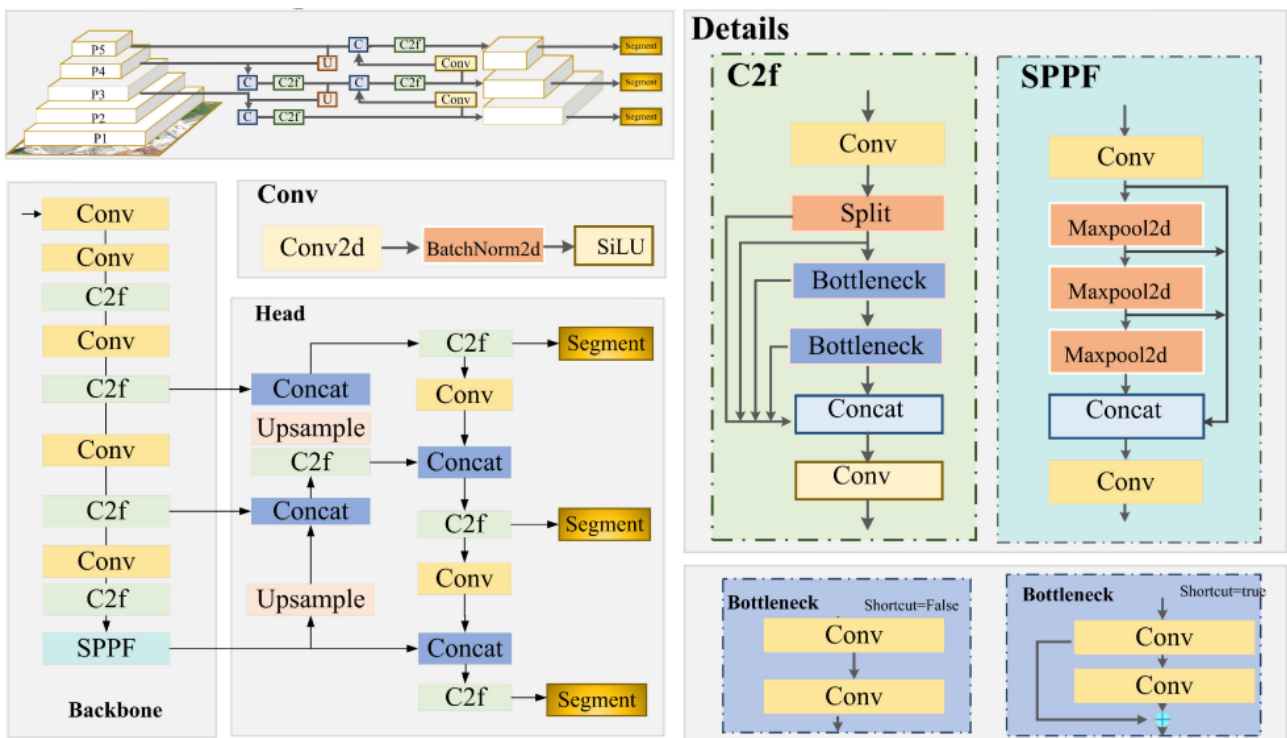


FIGURE III.9 – La structure du modèle YOLOv8-seg.

Contrairement à YOLOv5-seg, YOLOv8-seg utilise un modèle sans ancre avec une tête séparée pour traiter indépendamment les tâches d'objet, de classification et de régression. Cette conception permet à chaque branche de se concentrer sur sa tâche spécifique et améliore la précision globale du modèle. Il existe cinq types de YOLOv8-seg en fonction de la complexité du modèle, étiquetées n, s, m, l et x, chacune caractérisée par des profondeurs de canal et des nombres de filtres variables comme décrit dans le Tableau III. 2.

TABLE III.2 – Les diverses spécifications du modèle YOLOv8.

Model	d (depth_multiple)	w (width_multiple)	r (Ratio)
YOLO-V8 n	0.33	0.25	2.0
YOLO-V8 s	0.33	0.50	2.0
YOLO-V8 m	0.67	0.75	1.5
YOLO-V8 l	1.00	1.00	1.0
YOLO-V8 x	1.00	1.25	1.0

III.5 Conclusion

Dans ce Chapitre, nous avons mis en lumière les étapes clés suivies pour la détection des dommages affectant les moteurs d'avion. En effet, nous avons détaillé notre méthodologie à travers l'exploration des techniques de segmentation d'images et l'utilisation de modèles avancés tels que YOLOv8, nous avons élaboré une approche novatrice visant à identifier avec précision les anomalies susceptibles de compromettre la fiabilité opérationnelle des avions. La mise en œuvre de cette approche est prévue ainsi que l'évaluation des résultats obtenus dans le dernier chapitre.

CHAPITRE IV

EVALUATION DES PERFORMANCES DE
L'APPROCHE PROPOSÉE

IV.1 Introduction

Dans ce chapitre, nous examinerons les performances de notre approche de détection des dommages dans les moteurs d'avion en utilisant YOLOv8. Nous commencerons par détailler l'environnement de développement et les outils utilisés pour entraîner et évaluer notre modèle. Ensuite, nous présenterons les résultats de l'évaluation de l'approche proposée basée sur les expériences menées. Enfin, nous évaluerons l'efficacité de l'approche proposée et si elle est généralisable pour la détection de différents types de dommages spécifiques aux moteurs d'avion où nous utiliserons pour ceci une vidéo de borescope qui a été acquise ailleurs et non pas au sein de la compagnie aérienne d'air Algérie.

IV.2 Environnement de développement et outils utilisés

IV.2.1 Matériel utilisé

Nous présentons sur le tableau IV.1 les caractéristiques du matériel utilisé.

TABLE IV.1 – Les caractéristiques du matériel utilisé.

Nom du pc	Processeur	Système d'exploitation	Mémoire (RAM)	Carte graphique
HP-EliteBook-840-G5	Intel(R) Core (TM) i7-8650U CPU @ 1.90GHz 2.11 GHz	Windows 11 Pro	16.0 GB	Intel UHD Graphics 620

IV.2.2 Google Colab

Google Colab est un service en nuage gratuit qui prend désormais en charge les GPU gratuits, permettant d'améliorer les compétences de codage en langage de programmation Python.

Il permet de développer des applications d'apprentissage approfondi à l'aide de bibliothèques populaires telles que Keras, TensorFlow, PyTorch et OpenCV. La fonctionnalité la plus importante qui distingue Colab des autres services de cloud computing gratuits est la suivante : Colab fournit un GPU et est totalement gratuit [50].

Nous présentons sur la figure IV.1 l'environnement de Google Colab.

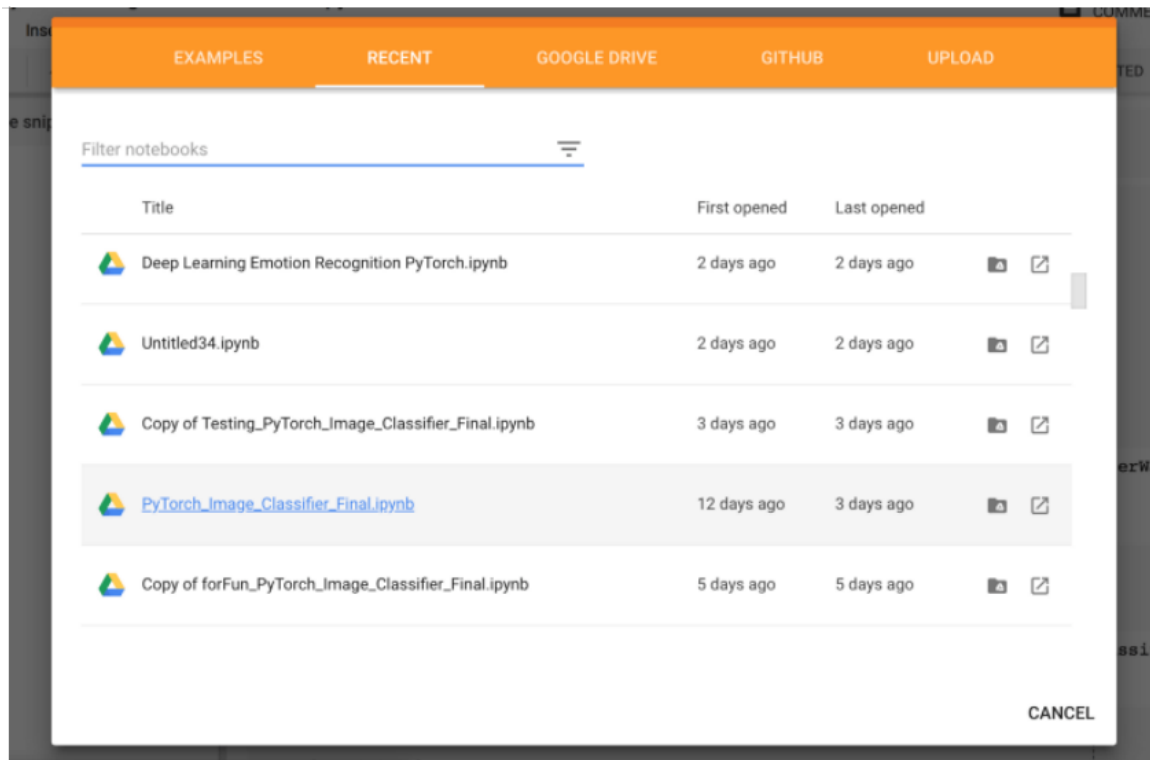


FIGURE IV.1 – Environnement de Google Colab.

IV.2.3 Nécessité de travailler avec un GPU

Les GPU, ou unités de traitement graphique, sont essentiels pour la plupart des approches d'apprentissage automatique et d'apprentissage en profondeur en raison de la quantité importante de données sur lesquelles ces algorithmes doivent travailler. Les calculs mathématiques nécessaires à l'apprentissage profond sur un CPU peuvent prendre beaucoup de temps, parfois même des mois. Cependant, ces mêmes calculs peuvent être effectués beaucoup plus rapidement sur un GPU. Il est donc fortement recommandé d'utiliser un GPU pour l'entraînement de réseaux de neurones en raison de sa capacité à effectuer des calculs parallèles à grande échelle. Les GPU sont généralement coûteux, tout comme les plates-formes cloud telles qu'AWS et GCP qui offrent des services de calcul sur GPU. Cependant, il existe des alternatives gratuites telles que Google Colab fournissant un accès gratuit à un GPU Nvidia Tesla K80, dont le prix sur le marché est assez élevé. En utilisant Colab, les utilisateurs peuvent bénéficier de la puissance de calcul rapide et efficace des GPU pour l'entraînement de leurs modèles de machine learning et deep learning sans avoir à investir dans leur propre matériel coûteux.

IV.2.4 Le langage Python

Python est un langage de programmation de haut niveau largement utilisé dans le domaine de la programmation générale. Créé par Guido van Rossum et publié pour la première fois en 1991, Python se distingue par sa philosophie de conception axée sur la lisibilité du code, favorisant notamment l'utilisation d'espaces significatifs pour organiser le code de manière claire. Ce langage de programmation offre une syntaxe claire et concise, ce qui en fait un choix populaire pour les développeurs de tous niveaux, des débutants aux experts. Python prend en charge une variété de paradigmes de programmation, notamment la programmation orientée objet, impérative, fonctionnelle et procédurale. De plus, Python dispose d'un système de type dynamique et d'une gestion automatique de la mémoire, ce qui simplifie le processus de développement en évitant les soucis liés à la gestion manuelle de la mémoire. L'une des caractéristiques les plus attrayantes de Python est sa vaste bibliothèque standard, qui offre un large éventail de modules et de packages pour accomplir une multitude de tâches, allant de la manipulation de fichiers à la création d'interfaces graphiques. De plus, Python bénéficie d'une grande portabilité, avec des interpréteurs disponibles pour de nombreux systèmes d'exploitation, ce qui facilite son utilisation sur différentes plateformes [51].

IV.2.5 Bibliothèques utilisées

Voici quelques-unes des bibliothèques que nous avons utilisées :

1. TensorFlow

TensorFlow est souvent connue comme la référence en matière de bibliothèque d'apprentissage automatique, offrant accessibilité et puissance. Avec son support pour diverses architectures de réseaux neuronaux comme les CNN et les RNN. En effet, elle permet aux développeurs de construire des modèles d'apprentissage profond à grande échelle. En utilisant des graphes de calcul, TensorFlow facilite la visualisation de la construction des réseaux neuronaux grâce à TensorBoard, ce qui simplifie le processus de débogage. En outre, sa capacité à être déployé sur CPU et GPU en fait un choix idéal pour les projets nécessitant des calculs intensifs, garantissant ainsi une performance optimale, même à grande échelle [52].

2. NumPy

NumPy, abréviation de "Numerical Python", est une bibliothèque fondamentale pour le calcul scientifique en Python. Elle offre une vaste gamme de fonctionnalités pour effectuer des calculs numériques de manière efficace, principalement sur des tableaux multidimen-

sionnels et des structures de données matricielles. Son utilisation est prépondérante dans les domaines de la science des données et de l'apprentissage automatique pour plusieurs raisons [53] :

- Les tableaux Numpy utilisent moins de mémoire que les listes python normales.
- Une liste python normale est un groupe de pointeurs pour séparer les objets Python (par exemple les nombres à l'intérieur de la liste).
- Un tableau Numpy est conçu pour être un tableau de valeurs uniformes, sans utiliser d'espace pour les pointeurs de type.
- Numpy peut également lire les informations plus rapidement et dispose de nombreuses opérations de diffusion pratiques qui peuvent être effectuées à travers les dimensions du tableau.

3. Ultralytics

Ultralytics est une bibliothèque open source pour la détection d'objets basée sur YOLO. Elle fournit un ensemble d'outils pour l'apprentissage, l'inférence et l'évaluation de modèles de détection d'objets. Ultralytics est conçue pour être facile à utiliser et efficace, et elle est largement utilisée dans les applications de vision par ordinateur [54].

Ultralytics YOLOv8 est un modèle de pointe (SOTA) qui s'appuie sur le succès des versions précédentes de YOLO et introduit de nouvelles fonctionnalités et améliorations pour améliorer encore les performances et la flexibilité. YOLOv8 est conçu pour être rapide, précis et facile à utiliser, ce qui en fait un excellent choix pour un large éventail de tâches de détection et de suivi d'objets, de segmentation d'instances, de classification d'images et d'estimation de poses.

IV.3 Métriques d'évaluation des performances utilisées

Nous distinguons diverses métriques pour l'évaluation de la détection d'objets et la segmentation d'images, notamment la précision (P), le rappel (R) et la précision moyenne (mAP) :

La courbe Précision-Rappel (P-R Curve) est une courbe avec le rappel en abscisse (x) et la précision en ordonnée (y). Chaque point représente une valeur de seuil différente, et tous les points sont connectés pour former une courbe.

En effet, ces mesures ont été utilisées pour évaluer les modèles entraînés sur les données de test. La précision moyenne (mAP) a été utilisée comme principale métrique d'évaluation, en particulier la mAP50. La mAP a été dérivée de l'indice d'intersection-sur-union (IoU) ou indice

de Jaccard, qui représente la moyenne des valeurs de précision à différents niveaux de rappel pour un seuil IoU spécifique. L'IoU est utilisé pour mesurer la similarité entre deux régions et est défini comme le rapport de l'intersection à l'union des deux. Les équations des métriques utilisées sont indiquées dans les équations suivantes :

$$\text{Précision} = \frac{\text{Vrais Positifs}}{\text{Vrais Positifs} + \text{Faux Positifs}} \quad (\text{IV.1})$$

$$\text{Rappel} = \frac{\text{Vrais Positifs}}{\text{Vrais Positifs} + \text{Faux Négatifs}} \quad (\text{IV.2})$$

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (\text{IV.3})$$

où les Vrais Positifs (TP) désignent le résultat de prédiction en tant que classe positive et jugé comme vrai ; les Faux Positifs (FP) désignent le résultat de prédiction en tant que classe positive mais jugé comme faux, et les Faux Négatifs (FN) désignent le résultat de prédiction en tant que classe négative mais jugé comme faux.

En général, la précision moyenne (AP) pour une seule classe est déterminée en classant les prédictions du modèle par leurs scores de confiance, puis en calculant l'aire sous la courbe précision-rappel, comme indiqué dans l'équation :

$$\text{AP} = \sum_n ((\text{Rappel}_n - \text{Rappel}_{n-1}) \cdot \text{Précision}_n) \quad (\text{IV.4})$$

Puisque notre recherche visait à détecter sept classes, la mAP était égale à la moyenne de la AP de chaque classe. La mAP50 fait référence à la AP à un seuil IoU de 0.5. La mAP50 : 95 fait référence à la AP pour chaque seuil IoU de 0.5 à 0.95 en incrémentant de 0.05 ; ces valeurs sont ensuite moyennées comme indiqué dans l'équation :

$$\text{mAP} = \frac{\text{AP}_{\text{IoU}=0.5} + \text{AP}_{\text{IoU}=0.55} + \dots + \text{AP}_{\text{IoU}=0.95}}{k} \quad (\text{IV.5})$$

Où k est le nombre de seuils IoU considérés. La mAP50 et la mAP50 : 95 ont été utilisées pour évaluer la capacité du modèle entraîné à segmenter précisément des objets à différents seuils IoU. Parmi les métriques, la mAP était la principale métrique utilisée dans la détection d'objets multi classes pour évaluer nos modèles entraînés. De plus, la mAP, la précision et le rappel ont été utilisés pour évaluer à la fois les boîtes englobantes et les masques de segmentation des modèles de segmentation d'instance. Nous avons évalué notre approche en utilisant la précision moyenne (AP) et sa moyenne (mAP).

IV.4 Expérimentations

Dans notre approche de la détection des dommages dans les moteurs d'avion, nous avons identifié sept types de dommages sur lesquels nous allons concentrer nos efforts consistant en :

1. **Rupture (Broken)** Caractérisée par des fractures dans les composants du moteur.
2. **Brûlé (Burned)** Résultant de l'exposition à des températures élevées, entraînant des déformations ou des changements de couleur.
3. **Corrosion** Causée par l'interaction avec des agents corrosifs, entraînant une perte de matière ou des perforations.
4. **Fissure (Crack)** Petites fissures dans les composants métalliques.
5. **Éraflure (Nick)** Petites entailles ou marques de surface causées par des impacts ou des frottements.
6. **Surchauffé (Overhated)** Les composants exposés à des températures excessives peuvent se déformer ou se dégrader.
7. **Courbure de l'extrémité (Tip curl)** Déformation ou courbure à l'extrémité des composants du moteur.

Les algorithmes de YOLOv8 ont été développés en utilisant PyTorch, une bibliothèque populaire et largement adoptée dans la communauté de l'apprentissage en profondeur, ce qui facilite le processus d'apprentissage et de test sur notre datasets locale. En outre, lors d'une comparaison avec d'autres modèles ayant des capacités de segmentation d'instances, tels que Mask R-CNN, YOLOv8 a démontré des performances supérieures dans la détection, la segmentation et la classification spécifiques des objets. Cette constatation a renforcé notre choix en faveur de YOLOv8 pour notre tâche de détection de dommages sur les moteurs d'avion. YOLOv8 offre une architecture flexible avec plusieurs tailles de modèle, allant de nano à extralarge, ce qui nous permet de choisir le modèle le mieux adapté à nos besoins en fonction de la complexité de notre datasets et des ressources disponibles. Cette flexibilité nous permet d'optimiser à la fois la précision du modèle et la vitesse d'inférence, ce qui est crucial pour une application en temps réel dans le contexte de la maintenance des avions.

IV.5 Evaluation des performances de l’approche proposée de détection automatique des dommages du moteur aérien

IV.5.1 Evaluation des performances des premières expérimentations

Pour l’apprentissage notre modèle de détection dispose d’un ensemble de données comprenant environ 1077 images pour l’apprentissage, 66 images pour la validation et 47 images pour le test. Ces données couvrent une variété de scénarios de dommages et sont essentielles pour garantir que notre modèle soit capable de détecter efficacement les différents types de dommages rencontrés dans les moteurs d’avion.

Nous avons sélectionné **YOLOv8n-seg** et **YOLOv8s-seg** en raison de leur conception compacte et légère, les rendant adaptés aux applications en temps réel et idéaux pour les appareils aux ressources limitées. Leur faible empreinte mémoire et leur efficacité de traitement les rendent particulièrement adaptés aux situations où la vitesse et l’efficacité sont essentielles. Nous présentons sur le tableau IV.2 les hyperparamètres appliqués avec ces deux modèles.

TABLE IV.2 – Les hyperparamètres appliqués durant les premières expérimentations.

Modèle	Dimension des images	Learning Rate	Batch Size	Momentum	Epoch	Nombre de classes
YOLOv8n-seg	640 × 640	0.01	16	0.937	50	7
YOLOv8s-seg	640 × 640	0.01	16	0.937	50	7

Ceci nous a permis de comparer les performances de ces modèles pour choisir celui qui répond le mieux à nos besoins.

La figure IV.2 montre les courbes d’apprentissage de mAP0.5 et mAP0.5 :0.95 pour les modèles de segmentation d’instance en termes de détection d’objets et de précision de segmentation. Dans l’ensemble, ces modèles ont montré un potentiel en termes de convergence élevée et de précision de détection. YOLOv8n-seg avait une précision de détection en utilisant des cadres englobants mAP0.5(B) de 63% et YOLOv8s-seg avait une précision de détection de mAP0.5(B) de 73% comme mentionné sur la figure IV.2(a). Alors que pour mAP0.5 :0.95(B), la précision

des cadres de délimitation pour YOLOv8n-seg était supérieure à 32%, tandis que celle de YOLOv8s-seg était supérieure à 42% comme indiqué sur la figure IV.2 (b). YOLOv8n-seg avait une précision de détection en utilisant les masques mAP0.5 de 68% et YOLOv8s-seg avait une précision de détection de mAP0.5 de 75% comme mentionné sur la figure IV.2(c), tandis que mAP0.5 :0.95 était pour les deux, YOLOv8n-seg était supérieur à 31%, tandis que YOLOv8s-seg était supérieur à 38% comme indiqué sur la figure IV.2(d). La courbe d'apprentissage a également confirmé que 50 epochs étaient suffisantes pour l'identification de divers dommages au moteur aérien.

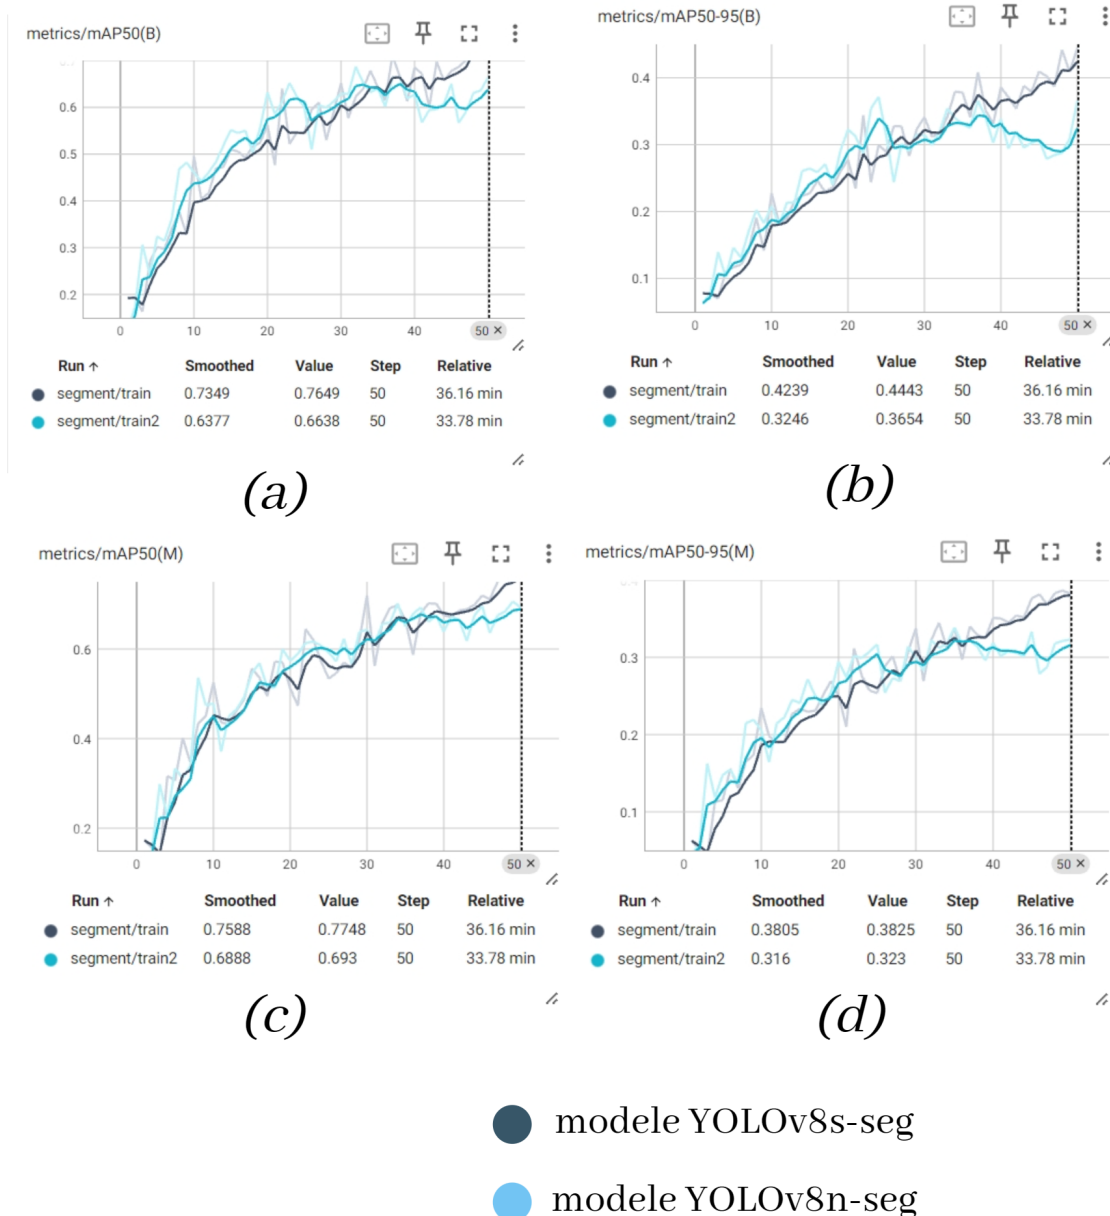


FIGURE IV.2 – Les détails de l'apprentissage des modèles YOLOv8n-seg et YOLOv8s-seg.

Il semble que les résultats de l'apprentissage du modèle YOLOv8s-seg étaient généralement

meilleurs que ceux de YOLOv8n-seg.

Par conséquent, nous avons décidé d'adopter le modèle YOLOv8s-seg et avons commencé une phase d'augmentation des données, car les résultats de détection pour certaines catégories n'étaient pas satisfaisants, comme indiqué dans le tableau IV.3, où les performances du modèle YOLOv8s-seg sont présentées. Globalement, le modèle a obtenu de bons résultats avec une mAP50 de 0,765. Cependant, pour certaines catégories spécifiques, les performances peuvent varier. Par exemple, la précision pour la catégorie "Broken" était de 0,696 en utilisant des cadres englobants et de 0,806 en utilisant des masques. Pour la catégorie "Crack", la précision était de 0,807 en utilisant des cadres englobants et de 0,581 en utilisant des masques.

TABLE IV.3 – Performances de segmentation d'instance pour l'ensemble de données de validation.

Class	Precision (B)	Recall (B)	mAP@0.5 (B)	mAP@0.5 :0.95 (B)	Precision (M)	Recall (M)	mAP@0.5 (M)	mAP@0.5 :0.95 (M)
Broken	0.537	0.408	0.696	0.27	0.945	0.667	0.806	0.261
Burned	0.648	0.6	0.624	0.425	0.714	0.65	0.67	0.394
Corrosion	0.627	1.0	0.995	0.895	0.636	1.0	0.995	0.821
Crack	0.831	0.703	0.807	0.433	0.592	0.484	0.581	0.197
Nick	0.865	0.558	0.762	0.326	0.863	0.55	0.8	0.235
Overheated	0.558	0.8	0.786	0.487	0.645	0.9	0.874	0.551
Tip curl	0.935	0.545	0.683	0.272	0.96	0.545	0.697	0.218

Même si le modèle YOLOv8s-seg a montré une pertinence à détecter et à segmenter des objets avec précision, cependant il peut encore y avoir des améliorations spécifiques nécessaires pour certaines classes.

IV.5.2 Evaluation des performances des secondes expérimentations en vue de l'amélioration du modèle obtenu durant les premières expérimentations

Comme déjà mentionné durant la problématique de ce travail, la classe "crack" faisait l'objet d'une médiocre détection dans la majorité des travaux vu que la tailles des cracks est extrêmement petite (environ entre 8×6 et 8×34 pixels), ce qui donne le nombre de pixels représentant un crack étant significativement moins de 0,1% de l'intégralité des pixels d'une image. Dans ce sens, les cracks sont difficiles, voire impossibles, à identifier des catégories non formés. Pour l'augmentation des données de la classe "crack" aucune datasets n'est accessible au public. D'autre part, les cracks du béton sont généralement plus courtes et moins larges, mais néanmoins beaucoup plus longues et plus larges que les cracks des pales de turbine par exemple.

La solution adoptée pour améliorer les performances de détection de la classe "crack" a été d'ajouter de nouvelles données à l'ensemble de données existant. Dans ce sens, des efforts ont été concentrés spécifiquement sur l'acquisition de données supplémentaires pour la catégorie "crack". Malheureusement, il a été difficile de trouver suffisamment de données pertinentes pour cette catégorie. En conséquence, une approche alternative a été adoptée, consistant à utiliser des exemples de la vie réelle, notamment des images de fissures dans des panneaux et des murs. Environ 70 nouvelles images représentant des exemples de fissures dans des panneaux et des murs ont été ajoutées aux données d'apprentissage, spécifiquement pour la catégorie "crack". Cette augmentation de données a permis d'enrichir la variabilité des exemples de fissures, ce qui devrait aider le modèle à mieux généraliser et à améliorer sa capacité à détecter cette catégorie dans différents contextes. La figure IV.3 illustre quelques-unes des nouvelles données ajoutées pour la catégorie "crack" dans les panneaux et les murs.



FIGURE IV.3 – Exemple données ajoutées pour la classe "crack" obtenues à partir des panneaux et des murs.

En ajoutant de nouvelles données pour diverses classes, nous avons pu augmenter le nombre total de données d'apprentissage à 3984 images. Cette augmentation devrait considérablement améliorer les performances de détection pour les différentes classes. Enrichir l'ensemble de données avec des exemples supplémentaires permet au modèle d'apprendre à reconnaître et à généraliser plus efficacement les caractéristiques distinctives de chaque classe, ce qui se traduira par une meilleure précision et une meilleure capacité de détection dans des scénarios réels.

Le modèle de segmentation YOLOv8 utilisé dans ce contexte compte environ 11,78 millions de paramètres entraînaibles. Ces paramètres comprennent les poids et les biais dans les couches du réseau neuronal, qui sont appris lors du processus d'apprentissage pour permettre au modèle de faire des prédictions précises. Les images d'apprentissage et de validation ont été sélectionnées de manière aléatoire dans chaque ensemble de données en suivant un ratio de 80% pour l'apprentissage et de 20% pour la validation. Au total, **3984 images** ont été considérées pour l'apprentissage, **357 images** pour la validation. Des vidéos ont été sélectionné aléatoirement

pour tester les performances du modèle. La distribution des instances pour chaque classe est représentée dans la Figure IV.4. Les hyperparamètres tels que le taux d'apprentissage, la taille du lot et le nombre d'époques ont été optimisés en fonction des performances du modèle YOLOv8, un taux d'apprentissage de 0,01 a été obtenu, ainsi qu'une taille de lot de 16 et 50 epochs. La taille de l'image a été fixée à 640 x 640 pixels. Ces valeurs ont été déterminées par essais et erreurs pour trouver le juste équilibre entre la précision du modèle et l'efficacité de l'entraînement.




FIGURE IV.4 – Distribution des instances selon les sept classes.

Nous présentons sur le tableau IV.4 les performances de segmentation des dommages aboutis par le modèle final qui a été obtenu suite à l'amélioration du premier modèle réalisé durant les premières expérimentations.

TABLE IV.4 – Performances de segmentation d’instance pour l’ensemble de données de validation.

Class	Precision (B)	Recall (B)	mAP@0.5 (B)	mAP@0.5 :0.95 (B)	Precision (M)	Recall (M)	mAP@0.5 (M)	mAP@0.5 :0.95 (M)
Broken	0.908	0.895	0.973	0.763	0.862	0.85	0.862	0.411
Burned	0.905	0.953	0.952	0.768	0.915	0.963	0.962	0.717
Corrosion	0.814	1.0	0.995	0.895	0.813	1.0	0.995	0.828
Crack	0.884	0.892	0.956	0.716	0.848	0.857	0.916	0.435
Nick	0.988	0.893	0.976	0.558	0.954	0.862	0.945	0.498
Overheated	0.913	0.912	0.934	0.704	0.912	0.912	0.934	0.665
Tip curl	0.961	0.959	0.991	0.682	0.934	0.932	0.979	0.539
ALL	0.91	0.929	0.968	0.727	0.891	0.911	0.942	0.585

Par la considération de 357 images de validation portant 509 dommages ou instances. La précision des boîtes (Box(P)) atteint 0,91, indiquant une proportion élevée de prédictions de boîtes correctes, tandis que le rappel (R) est de 0,929, représentant un taux élevé de détection réussie.

La précision moyenne de toutes les classes à un seuil d’intersection sur union (IoU) de 50% (mAP50) est de 0,968, indiquant un bon compromis entre précision et rappel. Le mAP50-95, qui mesure la précision moyenne sur différents seuils d’IoU, est de 0,727.

En examinant les classes individuelles, nous observons des performances de détection variables. Par exemple, la classe "Broken" atteint une précision de 0,908 et un rappel de 0,895, avec un score mAP50 élevé de 0,973. De même, la classe "Nick" obtient une précision de 0,988, un rappel de 0,893 et un impressionnant score mAP50 de 0,976. En revanche, la classe "Crack" a augmenté de précision de l’ordre de (0,884) et un rappel de 0,892, un score mAP50 de 0,956.

En ce qui concerne la vitesse de traitement, le modèle démontre une performance efficace avec un temps moyen de prétraitement de 0,5 ms par image, un temps d’inférence de 7,4 ms par image et un temps de post-traitement de 4,7 ms par image.

Nous afficherons la matrice de confusion donnant une vue globale de la précision de notre modèle pour la détection des différents dommages comme indiqué sur la figure IV.5.




FIGURE IV.5 – La matrice de confusion de YOLOv8 pour la détection des dommages du moteur aérien.

Nous allons citer quelques observations clés à partir de la matrice de confusion :

1. Broken : Le modèle a atteint une précision notable de 98% dans la détection des objets cassés, avec seulement un taux de 2% de mauvaise classification comme background.
2. Corrosion, Tip curl : Le modèle a montré des précisions parfaites de 100% pour ces deux classes, indiquant une classification précise sans aucune mauvaise classification.
3. Burned : Le modèle a montré une précision élevée de 98% dans l'identification correcte des objets brûlés, avec seulement un taux de 1% de mauvaise classification comme background et 1% de mauvaise classification comme Overhated.
4. Crackk : Le modèle a montré une précision élevée de 95% dans la détection correcte des objets fissurés, avec seulement un taux de 5% de mauvaise classification comme background.
5. Nick : Le modèle a montré une précision élevée de 95% dans l'identification correcte des objets nick, avec seulement un taux de 4% de mauvaise classification comme background

et 1% de mauvaise classification comme Tip curl.

6. Overhated : Le modèle a montré une précision élevée de 93% dans l'identification correcte des objets Overhated, avec seulement un taux de 5% de mauvaise classification comme background et 2% de mauvaise classification comme Burned.

Le modèle YOLOv8 a démontré des performances prometteuses dans la détection des différentes classes de dommages moteur, avec des précisions élevées observées pour la plupart des classes. Sur plusieurs epochs, les valeurs de perte pour les boîtes, les classes et la focalisation de la détection diminuent, indiquant une amélioration de la localisation, de la classification, et de la détection, comme affirmé sur la figure IV.6 représentant les courbes d'apprentissage et la figure IV.7 les courbes de validation. Des métriques telles que la précision, le rappel, mAP@50 et mAP@50-95 s'améliorent progressivement, indiquant une précision croissante, comme le montre la figure IV.8. Aucun Overfitting n'est observé car les performances de validation sont cohérentes avec l'ensemble d'apprentissage. Dans l'ensemble, les résultats montrent des progrès prometteurs dans la capacité du modèle à détecter et localiser avec précision les divers dommages.




FIGURE IV.6 – Courbes loss de la phase d'apprentissage.




FIGURE IV.7 – Courbes loss de la phase de validation.




FIGURE IV.8 – Progression des mesures d'évaluation des performances au long de l'apprentissage.

Nous allons présenter quelques résultats quantitatifs de détection de dommages de l'approche proposée sur les figures IV.9 et IV.10 respectivement.




FIGURE IV.9 – Exemples de résultats de détection par l'approche proposée (partie 1).


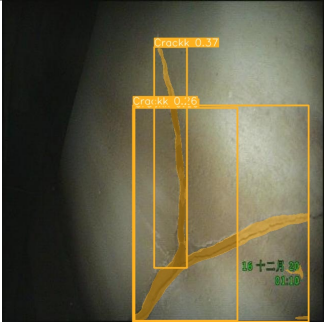



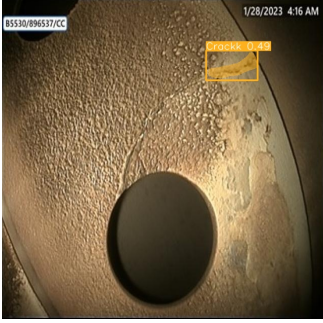
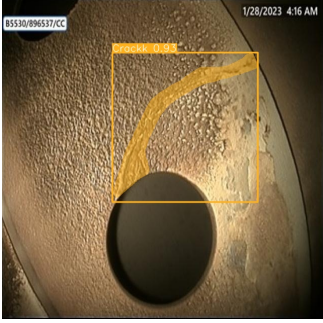

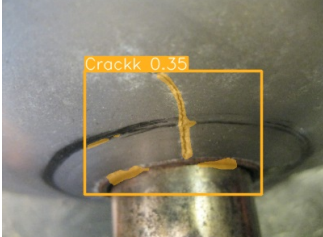



FIGURE IV.10 – Exemples de résultats de détection par l’approche proposée (partie 2).

A présent nous allons exposer sur le tableau IV.5 des dommages de crack où le modèle amélioré a réussi à les détecter et qui n’ont pas été détecté par le premier modèle.

TABLE IV.5 – Une nette amélioration des résultats de détection des cracks par le modèle YOLOv8s-seg amélioré (modèle final) : à gauche les résultats du premier modèle YOLOv8n-seg ensuite ceux du second modèle YOLOv8s-seg et à droite les résultats du modèle 2 amélioré, à savoir YOLOv8s-seg amélioré.

Premières expérimentations		Secondes expérimentations
Modèle 1 : YOLOv8n-seg	Modèle 2 : YOLOv8s-seg	Modèle 2 YOLOv8s-seg amélioré
		
		
		



Nous pouvons constater que le modèle 2 YOLOv8s-seg amélioré détecte avec précision les dommages, spécialement le crack qui désigne un dommage critique pour tous les travaux antérieurs dans ce domaine vu la taille petite de ce dommage par rapport à la taille de l'intégralité de l'image.

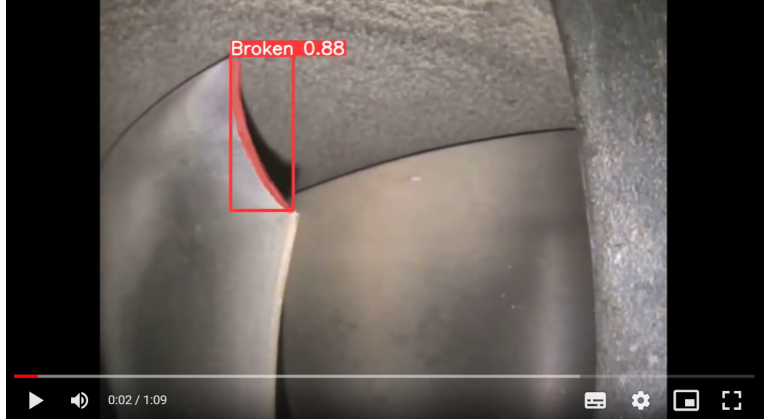
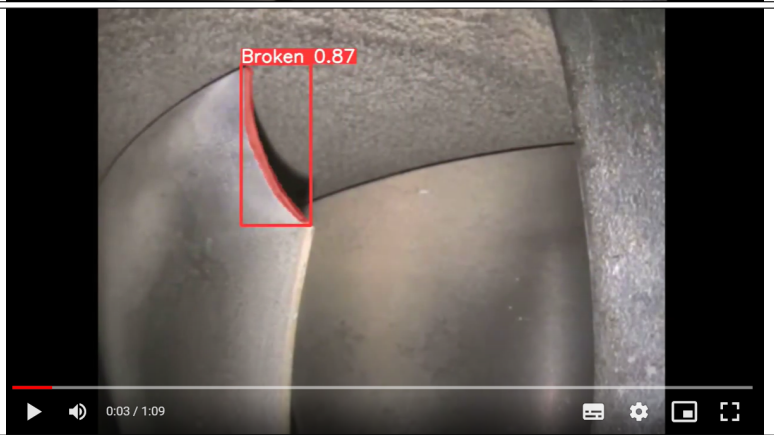
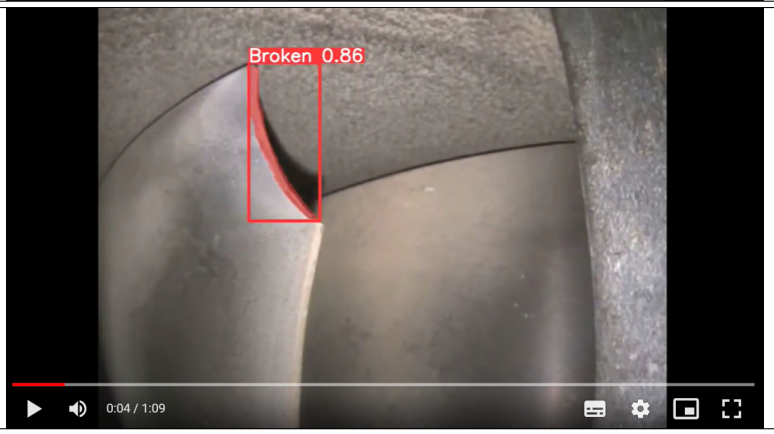
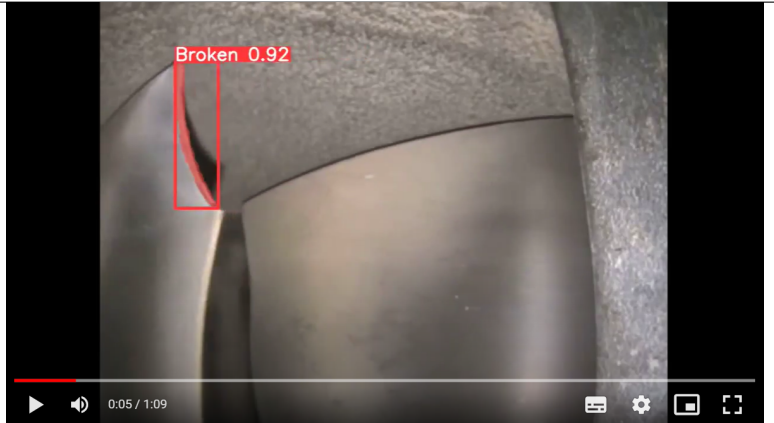
IV.6 Evaluation des performances de l'approche proposée sur des données de test pour confirmer sa généralisabilité





Nous avons collecté sept vidéos, provenant de la chaîne YouTube " RVI Ltd Remote Visual Inspections" [55]. Ces vidéos ont été éditées et regroupées en une seule vidéo à l'aide de Microsoft clipchamp.





Le modèle peut également délimiter précisément les contours des dommages, fournissant ainsi des informations détaillées sur leur étendue et leur forme. Nous présentons sur le tableau IV.6 les résultats obtenus de détection des dommages du moteur aérien sur des données jamais vu par le modèle proposé.


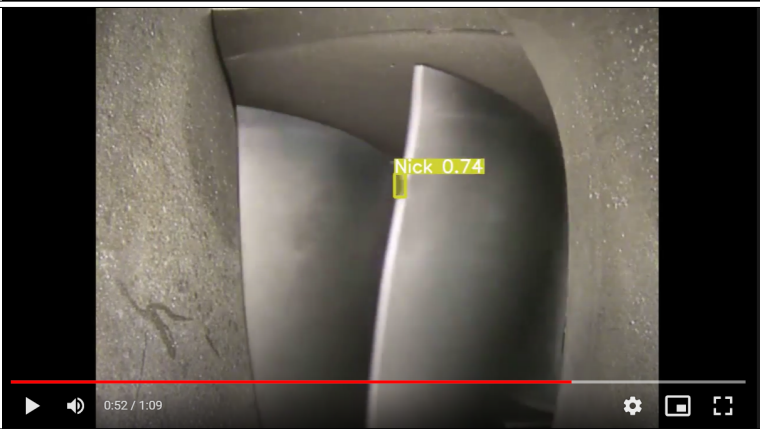

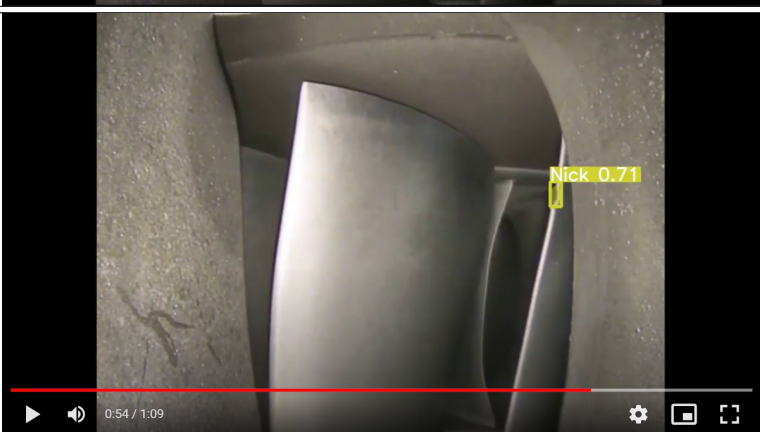
TABLE IV.6: Résultats obtenus de détection des dommages du moteur aérien sur des données de tests.

Classe	Temps	Résultats de détection
Aucun dommage détecté	A 0 :00	
Broken	A 0 :01	

Broken	A 0 :02	
Broken	A 0 :03	
Broken	A 0 :04	
Broken	A 0 :05	

<p>Aucun dommage détecté</p>	<p>A 0 :06</p>	
<p>Tip curl</p>	<p>A 0 :08</p>	
<p>Tip curl</p>	<p>A 0 :09</p>	
<p>Tip curl</p>	<p>A 0 :10</p>	

Tip curl	A 0 :11	 <p>A video frame showing a close-up of a curved metal surface. A green bounding box highlights a small, curved defect. The label 'Tip curl 0.81' is positioned above the box. The video player interface at the bottom shows a progress bar at 0:11 / 1:09.</p>
Crackk	A 0 :33	 <p>A video frame showing a close-up of a curved metal surface. An orange bounding box highlights a thin, dark crack. The label 'Crackk 0.90' is positioned above the box. The video player interface at the bottom shows a progress bar at 0:33 / 1:09.</p>
Crackk	A 0 :34	 <p>A video frame showing a close-up of a curved metal surface. An orange bounding box highlights a thin, dark crack. The label 'Crackk 0.81' is positioned above the box. The video player interface at the bottom shows a progress bar at 0:34 / 1:09.</p>
Crackk	A 0 :35	 <p>A video frame showing a close-up of a curved metal surface. An orange bounding box highlights a thin, dark crack. The label 'Crackk 0.84' is positioned above the box. The video player interface at the bottom shows a progress bar at 0:35 / 1:09.</p>

<p>Crackk</p> <p>A 0 :36</p>		 <p>A video frame showing a crack on a surface. A yellow box highlights the crack, and the text "Crackk 0.88" is overlaid in yellow. The video player interface at the bottom shows a progress bar at 0:36 / 1:09.</p>
<p>Nick</p> <p>A 0 :52</p>		 <p>A video frame showing a nick on a curved surface. A yellow box highlights the nick, and the text "Nick 0.74" is overlaid in yellow. The video player interface at the bottom shows a progress bar at 0:52 / 1:09.</p>
<p>Nick</p> <p>A 0 :53</p>		 <p>A video frame showing a nick on a curved surface. A yellow box highlights the nick, and the text "Nick 0.75" is overlaid in yellow. The video player interface at the bottom shows a progress bar at 0:53 / 1:09.</p>
<p>Nick</p> <p>A 0 :54</p>		 <p>A video frame showing a nick on a curved surface. A yellow box highlights the nick, and the text "Nick 0.71" is overlaid in yellow. The video player interface at the bottom shows a progress bar at 0:54 / 1:09.</p>



Nous pouvons affirmer que l'approche proposée détecte avec précision élevée tous les types de dommages sur les données de test où les frames de la vidéo défilent avec une vitesse considérable. Nous avons également testé l'approche proposée sur un ensemble d'images de test où les résultats sont exposés sur la figure IV.11.

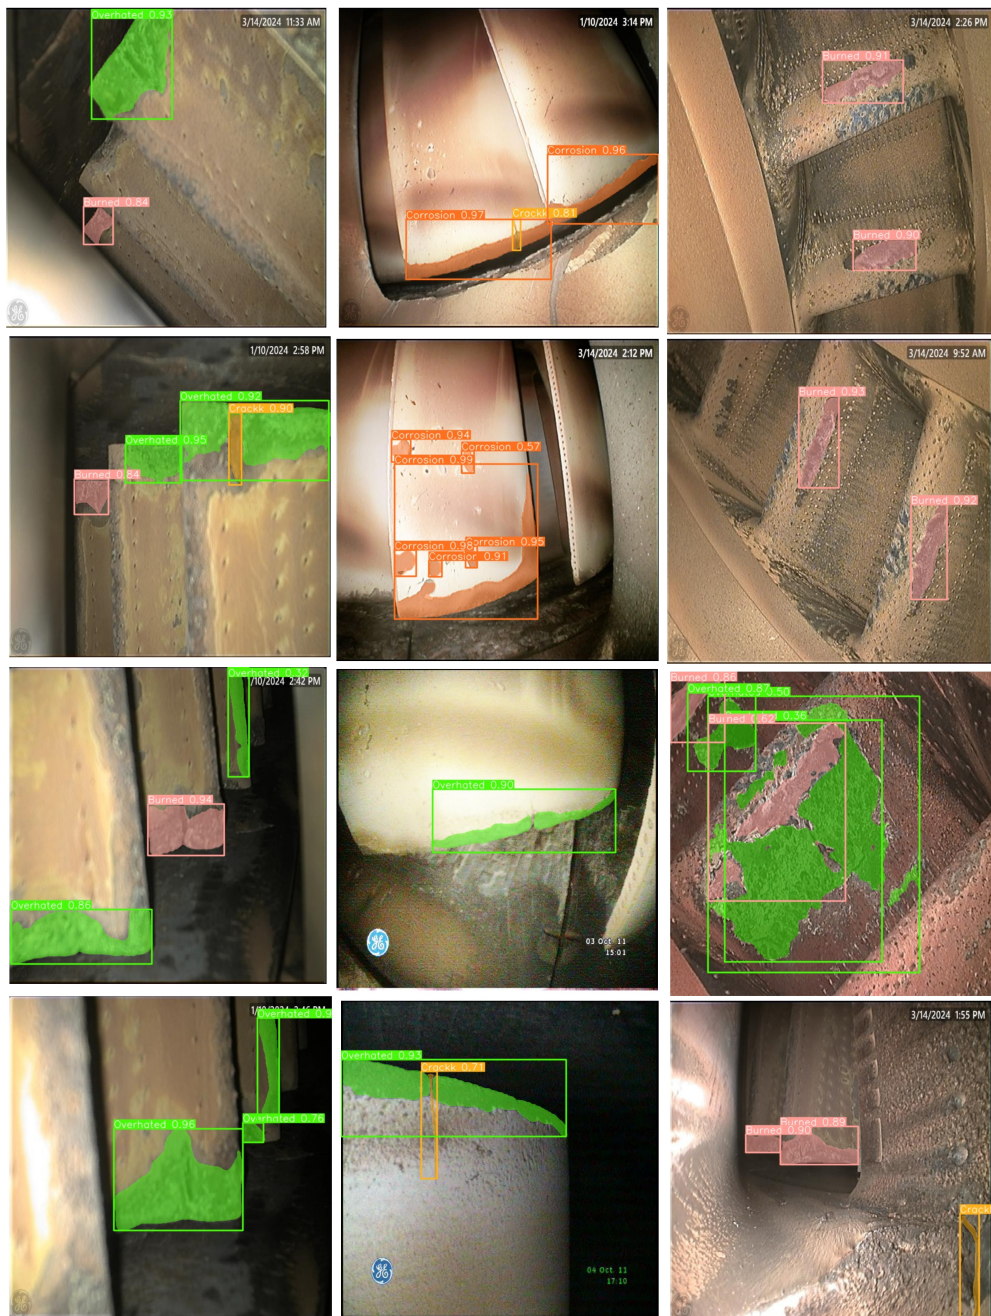


FIGURE IV.11 – Exemples de résultats de détection de dommages du moteur aérien sur des images de test.

nous pouvons affirmer la puissance de notre approche à détecter les dommages du moteur aérien sur des images de test jamais traitées.

IV.7 Présentation de quelques vue de l'interface de notre approche

Nous avons développé une application "AIMDAED" de bureau destinée aux ordinateurs de la base de maintenance d'Air Algérie. Elle se connecte automatiquement à la caméra borescope via Bluetooth pour détecter les dommages. L'application permet de capturer des images et vidéos, détecte automatiquement les anomalies et les enregistre sur les ordinateurs. Cela simplifie la génération de rapports de dommages pour les ingénieurs. Nous présentons sur la figure IV.12 une vue globale de l'interface du système proposé.

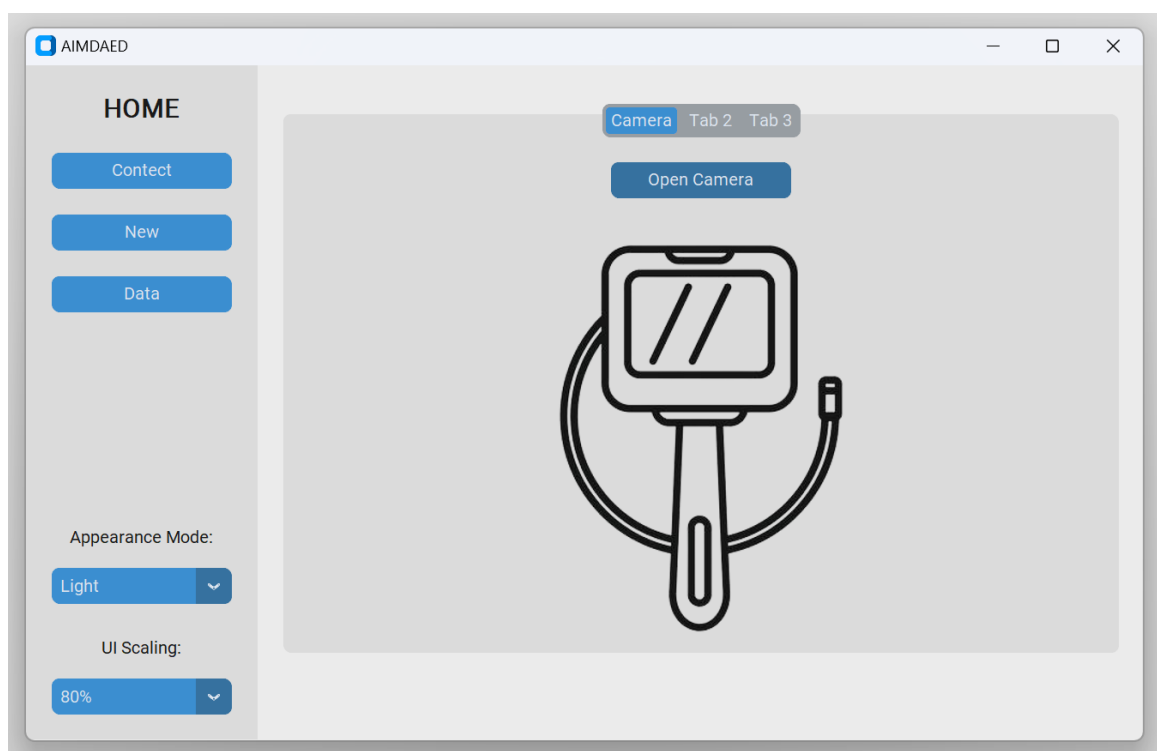


FIGURE IV.12 – Interface de notre Système.

Nous présentons sur la figure IV.13 le processus d'acquisition d'une vidéo ou une image prises par le borescope.

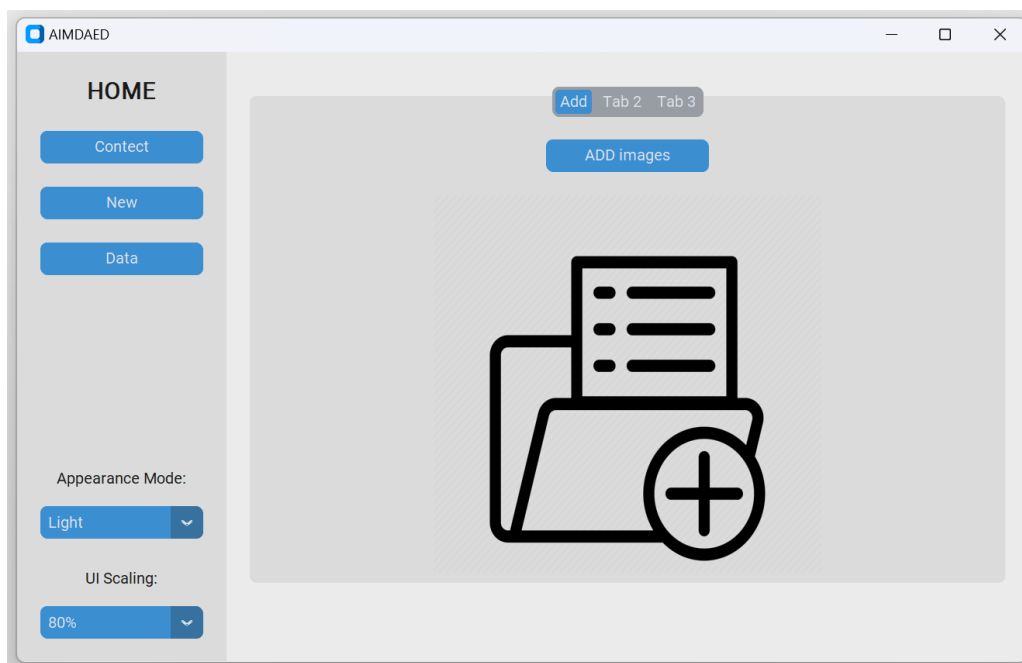


FIGURE IV.13 – Processus d’acquisition d’une image ou une vidéo prises par le borescope.

Nous exposons sur la figure IV.14 la détection des dommages du moteur d’avion par l’approche proposée.

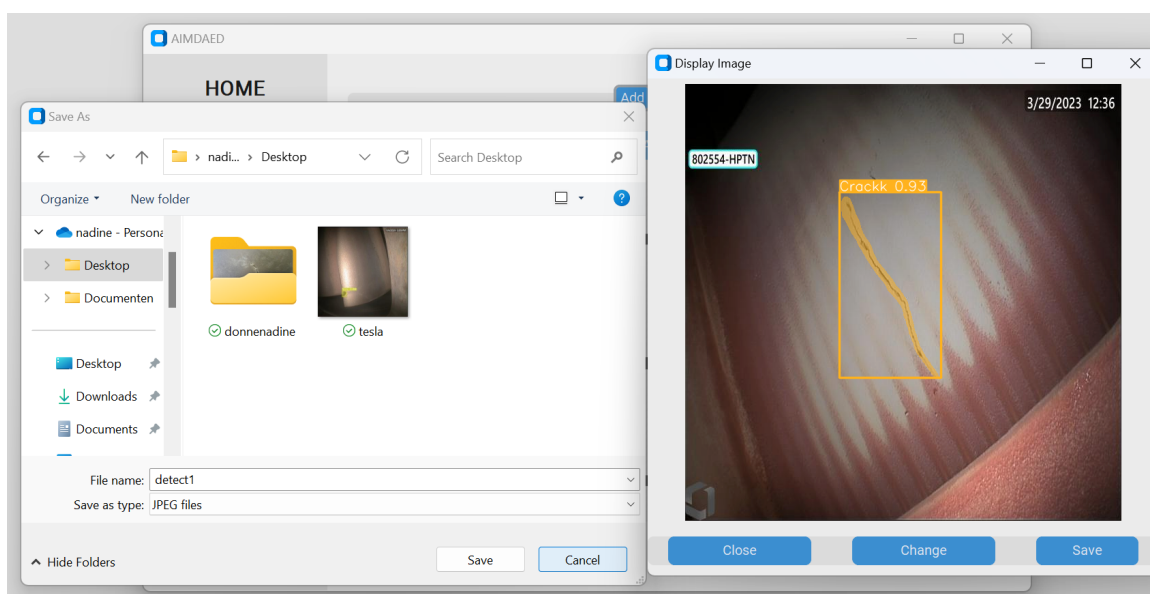


FIGURE IV.14 – Détection des dommages du moteur aérien et sauvegarde des résultats.

Nous présentons sur la figure IV.15 un exemple de détection du dommage depuis la caméra.

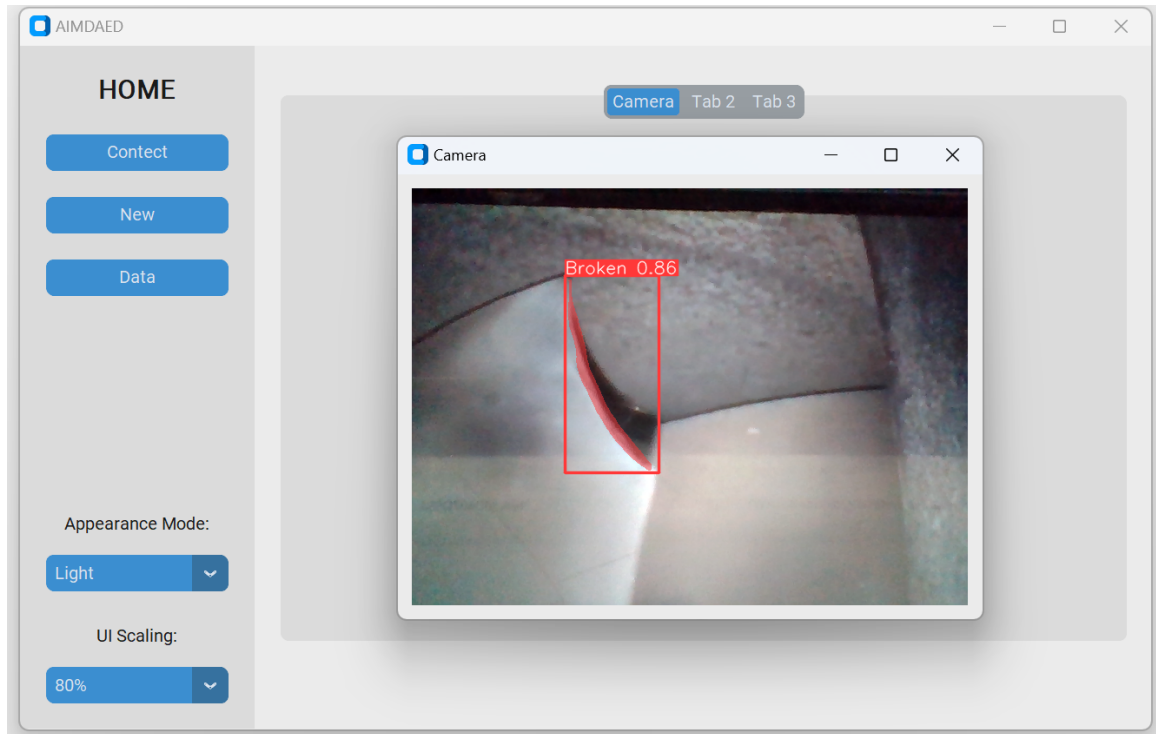


FIGURE IV.15 – Détection des dommages du moteur depuis la caméra.

IV.8 Conclusion

Dans ce chapitre, nous avons évoqué les expériences de pointes et les résultats obtenus qui contribuent à consolider nos connaissances requises. Nous avons d'abord discuté l'environnement de développement et les outils utilisés. Ensuite, nous avons comparé deux modèles de segmentation pour Yolov8 en utilisant une base de données locale acquise au niveau de la compagnie aérienne « Air Algérie ». Un premier modèle de détection a été implémenté qui était suivi d'un deuxième modèle où les performances étaient améliorées. Pour approuver la pertinence du modèle définitif de détection de dommages, nous l'avons testé sur des vidéos issues de YouTube ainsi que d'autres images de dommages aériens qui n'appartenaient pas à notre base de données. Dans ce sens, l'approche proposée a affirmé sa pertinence sur ces données de test. Enfin, nous avons développé une application "AIMDAED" de bureau. On peut dire que l'application peut détecter divers dommages sur le moteur de l'avion.

CONCLUSION GÉNÉRALE

L'inspection visuelle manuelle des composants du moteur d'avion est liée à la sécurité des vols. Cependant, elle est coûteuse et a une faible efficacité. Actuellement, l'inspection par borescope est la technologie dominante [6]. La courante technique pratique pour l'inspection par borescope consiste à insérer une caméra flexible dans le port d'inspection sur un moteur [56]. Les images sont capturées par la caméra et affichées sur un moniteur portable, puis inspectées manuellement par des techniciens pour déceler des signes de défauts. C'est un processus à forte intensité de main d'œuvre. Les résultats dépendent souvent du jugement des techniciens exécutant le processus.

Dans certains cas, les erreurs d'inspection laissent inaperçus les défauts des moteurs d'avion. Lorsqu'elle est effectuée par une personne, l'inspection borescope d'un moteur d'avion est facilement influencée par les expériences individuelles et les facteurs humains qui peuvent conduire à des décisions de maintenance incorrectes [57], entraînant potentiellement des catastrophes graves, ainsi qu'une faible efficacité. Afin de répondre aux exigences absolues de la sécurité des vols et améliorer l'efficacité pour diminuer les coûts de maintenance. Avec les progrès de l'analyse des données et de l'apprentissage profond, il existe une demande dans l'industrie pour transformer la maintenance manuelle des avions en un processus automatisé, efficace et prédictif. Cependant, la majorité des chercheurs ont utilisé une petite datasets engendrant un modèle qui sera difficile à généraliser pour divers dommages rencontrés dans la vie quotidienne.

Dans ce sens, l'approche présentée dans ce travail vise à automatiser la détection des dommages des moteurs d'avion pour l'inspection par borescope en combinant des techniques de deep learning de pointe et celles de la vision par ordinateur classique, basées sur une datasets de taille considérable avec des images réelles d'inspection par borescope acquise au sein de la compagnie

aérienne « Air Algérie ». En effet, nous avons utilisé YOLOv8 et sept classes de dommages où les résultats de détection de dommages étaient très pertinents. Comme les dommages sont détectés par modèle d'apprentissage profond impartial, les erreurs humaines potentielles et les biais sont éliminés. Comme perspectives de détection automatique des dommages dans l'industrie aérospatiale, diverses idées sont distinguées, citons :

- L'absence d'une datasets de référence standardisées pour évaluer la performance des modèles de détection de dommages est un défi important. Tous les travaux examinés utilisent des datasets personnalisées qui ne sont pas accessibles au public. Par conséquent, une datasets de référence est essentielle pour comparer les performances de différents modèles et suivre les progrès du domaine. Il est donc nécessaire de collaborer entre l'industrie et le monde universitaire pour créer publiquement des datasets de référence afin d'effectuer une évaluation standardisée durant la détection des dommages des composants des moteurs d'avion, permettant une comparaison de différents modèles et facilitation du développement d'algorithmes plus efficaces.
- La faible capacité à détecter de minuscules défauts par les CNN en raison de la haute résolution de l'image après acquisition automatique, les zones défectueuses de la surface des composants sont relativement faibles dans la zone d'image, et la taille des défauts est infime. Par conséquent, la résolution des cartes de caractéristiques diminue continuellement pendant le processus de convolution. Cette perte de détails conduit à une mauvaise détection des dommages minuscules. Même si une image haute résolution est redimensionnée à une basse résolution, les informations sémantiques significatives sur les minuscules défauts dans l'image originale sera perdu dans le processus de redimensionnement.
- Les images de borescope sont prises dans différentes chambres et avec différentes caméras borescope. Donc la détection automatique doit être robuste pour gérer diverses images avec des différences.

BIBLIOGRAPHIE

- [1] I. Uzun, “Damage detection in aircraft engine borescope inspection using deep learning,” 2023.
- [2] X. Huang, L. Li, J. Zhang, D. Yin, X. Hu, and P. Du, “An aero-engine damage detection method with low-energy consumption based on multi-layer contrastive learning,” *Electronics*, vol. 11, no. 13, p. 2093, 2022.
- [3] C. aux projets Wikimedia, “Accident d’un iliouchine il-76 algérien en 2018,” **URL**, January 25 2024, accessed : 2024-05-20.
- [4] C. Y. Wong, P. Seshadri, and G. T. Parks, “Automatic borescope damage assessments for gas turbine blades via deep learning,” in *AIAA Scitech 2021 Forum*, 2021, p. 1488.
- [5] Y. Abdulrahman, M. M. Eltoun, A. Ayyad, B. Moyo, and Y. Zweiri, “Aero-engine blade defect detection : A systematic review of deep learning models,” *IEEE Access*, 2023.
- [6] H. Shang, J. Wu, C. Sun, J. Liu, X. Chen, and R. Yan, “Global prior transformer network in intelligent borescope inspection for surface damage detection of aero-engine blade,” *IEEE Transactions on Industrial Informatics*, 2022.
- [7] P. européen, “Intelligence artificielle : définition et utilisation,” **URL**, July 9 2020, accessed : 2024-05-20.
- [8] “Computer vision - richard szeliski,” **URL**, accessed : 2024-05-20.
- [9] “Digital image processing, 4th edition - rafael gonzalez,” **URL**, accessed : 2024-05-20.
- [10] edX, “Best online machine learning courses and programs,” **URL**, accessed : 2024-05-20.
- [11] “Introduction to machine learning,” Google for Developers, **URL**, accessed : 2024-05-20.
- [12] DataCamp, “Top machine learning use cases and algorithms,” **URL**, accessed : 2024-05-20.

-
- [13] E. Thompson, “Deep learning evolution : The complete history of AI innovation,” **URL**, August 14, 2023, accessed : May 20, 2024.
- [14] “Architecture typique d’un réseau neuronal convolutif,” **URL**, accessed : May 20, 2024.
- [15] “Convolutional neural networks,” **URL**, accessed : May 20, 2024.
- [16] “Support de cours - deep learning, chapitre 3 : CNN,” **URL**, accessed : May 20, 2024.
- [17] “U-net model architecture,” **URL**, accessed : May 20, 2024.
- [18] “VGG-16 CNN model,” **URL**, accessed : May 20, 2024.
- [19] “Residual networks (ResNet) - deep learning,” **URL**, accessed : May 20, 2024.
- [20] S. Bhosale, “ResNet architecture explained,” **URL**, accessed : May 20, 2024.
- [21] “Mask R-CNN in machine learning,” **URL**, accessed : May 20, 2024.
- [22] Soren-Kierkegaard, “R-CNN,” **URL**, accessed : May 20, 2024.
- [23] “Faster R-CNN,” **URL**, accessed : May 20, 2024.
- [24] R. Sapkota, D. Ahmed, and M. Karkee, “Comparing YOLOv8 and Mask R-CNN for object segmentation in complex orchard environments,” arXiv preprint arXiv :2312.07935, 2023.
- [25] K. He et al., “Mask R-CNN,” Computer Society, pp. 2980–2988, 2017.
- [26] “YOLO object detection,” **URL**, accessed : May 20, 2024.
- [27] “Object detection,” **URL**, accessed : May 20, 2024.
- [28] A. Karwal, “YOLO : You only look once - real-time object detection explained,” **URL**, accessed : May 20, 2024.
- [29] Ultralytics, “Ultralytics,” **URL**, accessed : May 20, 2024.
- [30] Y. Jiao, Z. Li, J. Zhu, B. Xue, and B. Zhang, “A novel ensemble model on defects identification in aero-engine blade,” *Processes*, vol. 9, no. 6, p. 992, 2021.
- [31] J. Aust, D. Pons, and A. Mitrovic, “Evaluation of influence factors on the visual inspection performance of aircraft engine blades,” *Aerospace*, vol. 9, no. 1, p. 18, 2021.
- [32] F. Zou, “Review of aero-engine defect detection technology,” in *2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, vol. 1. IEEE, 2020, pp. 1524–1527.
- [33] H. Shang, C. Sun, J. Liu, X. Chen, and R. Yan, “Deep learning-based borescope image processing for aero-engine blade in-situ damage detection,” *Aerospace Science and Technology*, vol. 123, p. 107473, 2022.
- [34] X. Li, C. Wang, H. Ju, and Z. Li, “Surface defect detection model for aero-engine components based on improved YOLOv5,” *Applied Sciences*, vol. 12, no. 14, p. 7235, 2022.
- [35] J. Aust and D. Pons, “Methodology for evaluating risk of visual inspection tasks of aircraft engine blades,” *Aerospace*, vol. 8, no. 4, p. 117, 2021.

- [36] E. McMenemy, “Remote Visual Inspection : Video Borescope STO NDT standards,” **URL**, August 10, 2015, Accessed : 2024-05-20.
- [37] Z. Shen, X. Wan, F. Ye, X. Guan, and S. Liu, “Deep learning-based framework for automatic damage detection in aircraft engine borescope inspection,” in *2019 International Conference on Computing, Networking and Communications (ICNC)*. IEEE, 2019, pp. 1005–1010.
- [38] D. Zhang, N. Zeng, and L. Lin, “Detection of blades damages in aero engine,” in *2020 Chinese Automation Congress (CAC)*. IEEE, 2020, pp. 6129–6134.
- [39] B. E. Jaeger, S. Schmid, C. U. Grosse, A. Gogelein, and F. Elischberger, “Infrared thermal imaging-based turbine blade crack classification using deep learning,” *Journal of Nondestructive Evaluation*, vol. 41, no. 4, p. 74, 2022.
- [40] Y. Li, Z. Han, H. Xu, L. Liu, X. Li, and K. Zhang, “YOLOv3-lite : A lightweight crack detection network for aircraft structure based on depthwise separable convolutions,” *Applied Sciences*, vol. 9, no. 18, p. 3781, 2019.
- [41] Y.-H. Kim and J.-R. Lee, “Videoscope-based inspection of turbofan engine blades using convolutional neural networks and image processing,” *Structural Health Monitoring*, vol. 18, no. 5-6, pp. 2020–2039, 2019.
- [42] X. Li, W. Wang, L. Sun, B. Hu, L. Zhu, and J. Zhang, “Deep learning-based defects detection of certain aero-engine blades and vanes with DDSC-YOLOv5s,” *Scientific Reports*, vol. 12, no. 1, p. 13067, 2022.
- [43] L. Chen, L. Zou, C. Fan, and Y. Liu, “Feature weighting network for aircraft engine defect detection,” *International Journal of Wavelets, Multiresolution and Information Processing*, vol. 18, no. 03, p. 2050012, 2020.
- [44] Shen, Z., Wan, X., Ye, F., Guan, X., Liu, S. (2019). Deep learning based framework for automatic damage detection in aircraft engine borescope inspection. In *2019 International Conference on Computing, Networking and Communications (ICNC)* (pp. 1005–1010). IEEE.
- [45] Upadhyay, A., Li, J., King, S., Addepalli, S. (2023). A Deep-Learning-Based Approach for Aircraft Engine Defect Detection. *Machines*, 11(2), 192. MDPI
- [46] Author/Uploader, “Title of the video,” **URL**, Year Published, accessed : Date Accessed.
- [47] R. Sapkota, D. Ahmed, and M. Karkee, “Comparing YOLOv8 and Mask R-CNN for object segmentation in complex orchard environments,” *arXiv preprint arXiv :2312.07935*, 2023.
- [48] Z. Ge, S. Liu, F. Wang, Z. Li, and J. Sun, “YOLOX : Exceeding YOLO series in 2021,” *arXiv :2107.08430*, vol. 8430, 2021.
- [49] R. Bai, M. Wang, Z. Zhang, J. Lu, and F. Shen, “Automated construction site monitoring based on improved YOLOv8-SEG instance segmentation algorithm,” *IEEE Access*, 2023.

- [50] ByteXD. "What is Google Colab? A Beginner Guide." Accessed May 20, 2024. **URL**.
- [51] intelligence-artificielle.com, "Python." Accessed May 20, 2024. **URL**.
- [52] LinkedIn. "Quelles sont les principales différences entre NumPy et SciPy?" Consulté le 20 mai 2024. **URL**.
- [53] LinkedIn. "Quelles sont les principales différences entre NumPy et SciPy?" Consulté le 20 mai 2024. **URL**.
- [54] Ultralytics. "Ultralytics." **URL**.
- [55] Rviltremotevisualinspecti2187. "YouTube Channel." Accessed May 20, 2024. **URL**.
- [56] Upadhyay, A., Li, J., King, S., Addepalli, S. (2023). A Deep-Learning-Based Approach for Aircraft Engine Defect Detection. *Machines*, 11(2), 192.
- [57] Li, X., Wang, W., Sun, L., Hu, B., Zhu, L., Zhang, J. (2022). Deep learning-based defects detection of certain aero-engine blades and vanes with DDSC-YOLOv5s. *Scientific Reports*, 12(1), 13067.