



BIBLIOTHÈQUE

CÉGEP DE L'ABITIBI-TÉMISCAMINGUE
UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de l'auteur de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.

Mémoire de recherche

Université du Québec en Abitibi-Témiscamingue



**École de génie
Maîtrise de recherche en ingénierie
En Génie électrique**

**Présenté par :
ABDELHAK MEHADJBIA**

Sujet de recherche :

**L'inspection et la détection des anomalies structurelles et
électriques en utilisant l'intelligence artificielle**

Directeur de recherche : Professeur. Fouad Slaoui-Hasnaoui

Décembre 2024

Remerciements

Avant d'entamer ce rapport, c'est avec un grand plaisir que je réserve ces quelques lignes en signe de gratitude et de profonde reconnaissance à tous ceux qui, de près ou de loin, ont contribué à l'aboutissement de ce travail.

Je tiens à exprimer ma profonde reconnaissance envers mon directeur de recherche, le **Pr. FOUAD SLAOUI HASNAOUI**, pour sa guidance précieuse, sa motivation inébranlable et le temps généreusement accordé tout au long de cette période. Les conseils et le soutien que j'ai reçus du début à la fin m'ont permis de développer des compétences en recherche et de mieux comprendre le sujet de recherche.

Cher **Pr. FOUAD SLAOUI HASNAOUI**, je vous remercie de m'avoir guidé tout au long de cette période. Votre soutien et votre dévouement ont joué un rôle essentiel dans ma réussite. Je suis vraiment reconnaissant de vous avoir comme professeur et directeur de recherche.

Détection d'anomalie, Inspection visuel automatisé, Deep learning, Intelligence artificielle, Panneaux solaires, Éoliennes, Cartes à circuits imprimée

Je tiens également à remercier chaleureusement ma famille ma mère, mon père, et mes frères à leur soutien, leurs encouragements et leur patience.

Table des matières

Remerciements	<i>i</i>
Table des matières	<i>ii</i>
Table des figures	<i>v</i>
Résumé	<i>vi</i>
Abstract	<i>vii</i>
Chapitre 1	<i>1</i>
Introduction générale	<i>1</i>
1.1. Contexte générale	<i>2</i>
1.2. Originalités	<i>4</i>
1.3. Objectifs du sujet de recherche	<i>5</i>
1.4. Problématique	<i>5</i>
1.5. Hypothèses	<i>6</i>
1.6. Méthodologie de recherche	<i>7</i>
Chapitre 2	<i>10</i>
Aperçu sur la vision intelligente et l'inspection visuelle automatisée	<i>10</i>
2.1. Introduction	<i>10</i>
2.2. Vision intelligente	<i>11</i>
2.3. Le rôle de l'IA dans les technologies de vision intelligente	<i>12</i>
2.4. Composants clés de la vision intelligente	<i>16</i>
2.5. Inspection visuelle automatisée	<i>19</i>
2.6. Détections d'anomalies dans l'IVA	<i>21</i>
2.6.1. Méthodes utilisées	<i>21</i>
2.7. Avantages de l'inspection visuelle automatisée	<i>22</i>
2.8. Applications dans diverses industries	<i>25</i>
2.9. Défis et considérations	<i>28</i>

2.10. Conclusion	28
Chapitre 3	30
<i>Détection des défauts structurelles des éoliennes basée sur un modèle de détection d'objets légers et le deep learning</i>	30
3.1. Introduction	30
3.2. Revue de la littérature	36
3.3. Méthodologie et analyse expérimentale	39
3.3.1. Entraînement basé sur NasNetMobile	39
3.3.2. Entraînement basé sur YOLOV11	52
3.4. Conclusion	61
Chapitre 4	63
<i>Détection des dommages structurelles et électriques des panneaux solaires basée sur l'apprentissage profond</i>	63
4.1. Introduction	63
4.2. Revue de la littérature	66
4.3. Méthodologie et analyse expérimentale	70
4.4. Base des données	71
4.5. Augmentation des images	72
4.6. Modèle d'apprentissage profond MobileNetV2	72
4.7. Réglage des hyperparamètres	75
4.8. Méthodes pour l'évaluation du modèle	76
4.9. Résultats	78
4.10. Conclusion	82
Chapitre 5	83
<i>Détection des défauts des carte à circuits imprimés (PCB) en temps réel..</i>	83
5.1. Introduction	83
5.2. Revue de la littérature	86
5.3. Modèle propose de détection des défauts de PCB	90
5.3.1. Détection des défauts des PCB basé sur le modèle YOLOv8 léger	92
5.3.2. Acquisition et traitement des données	93
5.3.3. Définition des hyperparamètres	95
5.3.4. Mesures d'évaluation	95
5.4. Résultats	96

5.5. Conclusion	101
Conclusion générale	102
Bibliographie	105
ANNEX A	111
ANNEX B	112
Algorithme de YOLO :	112
ANNEX C	114
MobileNetV2 :	114
NASNetMobile :	114

Table des figures

<i>Figure 1: Démarche à suivre.....</i>	9
<i>Figure 2 : Vision par ordinateur et intelligence artificielle</i>	15
<i>Figure 3 : Inspection visuelle pour la détection des défauts.....</i>	20
<i>Figure 4 : Avantages de l'inspection visuelle automatisée</i>	24
<i>Figure 5 : Composants d'éoliennes.....</i>	34
<i>Figure 6 : Images d'éoliennes de la base des données 1 [41].</i>	40
<i>Figure 7 : L'architecture de NasNetMobile.</i>	42
<i>Figure 8 : solution proposée pour la détection des défauts des éoliennes.....</i>	43
<i>Figure 9 : Matrice de confusion.</i>	45
<i>Figure 10 : Courbe de précision et d'erreur pour l'entraînement et la validation.....</i>	48
<i>Figure 11 : Résultat de la précision, rappel, sensibilité et spécificité</i>	49
<i>Figure 12 : Matrice de confusion pour la validation et le test</i>	50
<i>Figure 13 : Visualisation de Grad-cam testé sur des images d'éoliennes défectueuses</i>	51
<i>Figure 14 : images base des données 2.....</i>	53
<i>Figure 15 : Courbe précision rappel.....</i>	56
<i>Figure 16 : Illustration des résultats respectivement de, la courbe de précision, de rappel, et Courbe de précision-rappel</i>	58
<i>Figure 17 : échantillons 1 prédits avec YOLOv11.</i>	59
<i>Figure 18 : échantillons 2 prédits avec YOLOv11.</i>	60
<i>Figure 19 : Défauts structurelles et électriques des panneaux solaires</i>	66
<i>Figure 20 : images base des données panneaux solaires.....</i>	71
<i>Figure 21 : architecture du modèle MobileNetV2.....</i>	74
<i>Figure 22 : méthode propose pour détection des défauts sur les panneaux solaires.....</i>	75
<i>Figure 23 : Matrice de confusion.....</i>	76
<i>Figure 24 : MobileNetV2 Courbe de précision et d'erreur pour l'entraînement et la validation.....</i>	79
<i>Figure 25 : matrice de confusion pour panneaux solaires</i>	80
<i>Figure 26 : résultats de Grad-cam sur les défauts des panneaux solaires</i>	81
<i>Figure 27 : méthode proposée pour PCB.....</i>	86
<i>Figure 28 : illustration des étapes de l'étude proposée dans les PCB</i>	91
<i>Figure 29 : architecture simplifier de YOLOv8.</i>	93
<i>Figure 30 : images de PCB défectueux [81].</i>	94
<i>Figure 31 : courbe de précision et rappel</i>	97
<i>Figure 32 : précision et perte pour l'entraînement et la validation.</i>	98
<i>Figure 33 : Comparaison de la précision des modelés.</i>	99
<i>Figure 34 : prédiction des défauts PCB.....</i>	100

Résumé

L'intelligence artificielle (IA) intervient aujourd'hui dans l'automatisation de l'inspection visuelle, en apprenant à un ordinateur à lire des images et à déterminer si elles répondent à des normes acceptables. Les entreprises peuvent automatiser le processus d'inspection visuelle, gagner du temps, et dans certains cas, améliorer la précision. Par exemple, de l'identification de la corrosion au sommet des éoliennes ou de l'identification des cellules défectueuses des panneaux solaires, et même le contrôle de la qualité des circuits électroniques imprimés (PCB).

Dans ce travail, une solution de détection des défauts des éoliennes, des panneaux solaires et des circuits électroniques imprimés basée sur des modèles d'apprentissage profond, léger et personnalisé appelés (NasNetMobile, MobileNetV2 et YOLO) est proposée. Les modèles lourds sont coûteux en termes de temps de calcul et demandent une grande capacité de mémoire. Pour cette raison, notre travail se concentre sur l'implémentation et l'utilisation d'un modèle simple et léger. Les tests ont montré que NasNetMobile, MobileNetV2 et YOLO permettront d'obtenir de bonnes précisions de détections, et aussi les modèles sont capables d'identifier l'anomalie et de localiser la région défectueuse dans les images de notre base des données de test en utilisant la méthode de Grad-cam.

Abstract

Artificial Intelligence (AI) is now being used to automate visual inspection, by teaching a computer to read images and determine if they meet acceptable standards. Companies can automate the visual inspection process, save time, and in some cases, improve accuracy. Examples include identifying corrosion on the top of wind turbines or identifying defective cells in solar panels or even checking the quality of printed circuit boards (PCBs). In this work, a solution for detecting defects in wind turbines, solar panels, and printed circuit boards based on lightweight and personalized deep learning models called (NasNetMobile, MobileNetV2, YOLO) is proposed. Heavy models are expensive in terms of computation time and require a large memory capacity. For this reason, our work focuses on implementing and using a simple and lightweight model. Tests have shown that NasNetMobile, MobvileNetV2 and YOLO achieved good detection accuracy, and the models are able to identify the anomaly and locate the defective region in the images of our test database using the Grad-cam me

Chapitre 1

Introduction générale

Au cours des dernières années, l'automatisation et la digitalisation sont devenues très répandues dans les processus d'inspection et de contrôle de qualité. L'automatisation peut être utilisée dans de nombreux secteurs industriels pour accroître l'efficacité, réduire les erreurs humaines et améliorer la qualité globale des produits. Les fabricants estiment que l'automatisation peut aider à réduire les coûts et à accroître la productivité. Toutes les entreprises s'efforcent d'assurer l'autonomie et l'intelligence de leurs opérations.

L'automatisation peut être employée dans multiples secteurs industriels, allant de la fabrication automobile à l'agroalimentaire, en passant par l'électronique et la pharmacie. Du point de vue des fabricants, l'automatisation offre des avantages considérables. Elle contribue non seulement à réduire les coûts opérationnels en diminuant le besoin de main-d'œuvre, mais elle permet également d'augmenter la productivité. En libérant les employés des tâches répétitives et en leur permettant de se concentrer sur des missions à plus forte valeur ajoutée, les entreprises peuvent optimiser leur fonctionnement et réagir plus rapidement aux besoins du marché.

De plus, la détection d'anomalie (AD) tente d'identifier les instances dans les données qui s'écartent d'un concept de « normalité » préalablement défini. Dans ce contexte, les écarts identifiés sont appelés « anomalies » et étiquetés « anormaux », tandis que les points des données conformes au concept de normalité sont considérés comme « normaux ». Dans le domaine de la vision par ordinateur, l'AD tente d'identifier les images anormales, et l'un de ses domaines d'application les plus prometteurs est l'inspection visuelle automatisée (IVA) des produits manufacturés.

1.1. Contexte générale

L'inspection à l'œil des équipements, des produits et des matériaux est la forme la plus ancienne et la plus simple de l'inspection visuelle. Elle est toujours utilisée aujourd'hui dans les secteurs de la fabrication, de l'énergie et médical, car il s'agit d'une méthode traditionnelle de détection des défauts. Grâce à l'amélioration des caméras de haute qualité et des drones, l'inspection visuelle a atteint un nouveau stade. Aujourd'hui, les entreprises collectent des images numériques, des produits manufacturés et d'autres machines pour effectuer des inspections visuelles. Les inspections à l'aide d'enregistrements d'images peuvent être effectuées en temps réel ou examinées ultérieurement une fois que la caméra produisant les images a été récupérée.

Grâce à cette technologie, également appelée inspection visuelle automatisée (IVA), les organisations peuvent effectuer des inspections plus rapides, plus précises et plus rentables dans un large éventail d'environnements. En recourant à des machines pour effectuer des tests visuels, les entreprises peuvent maintenir les employés en dehors des zones dangereuses et des espaces confinés, tout en bénéficiant des avantages de l'inspection visuelle.

L'inspection et la détection des défauts dans les éoliennes et les panneaux solaires sont essentielles pour garantir l'efficacité et la durabilité des systèmes d'énergie renouvelable. Les drones, en raison de leur flexibilité et de leur capacité à capturer des données de manière rapide et précise, sont de plus en plus utilisés pour ces applications.

L'emploi de drones dans l'inspection des éoliennes et des panneaux solaires représente un avantage essentiel en ce qui concerne la sécurité des employés. En supprimant le besoin d'envoyer des équipes en altitude pour des tâches dangereuses, les drones diminuent fortement les risques d'accidents liés au travail en hauteur. Mais également, les drones offrent plusieurs avantages pour l'inspection des éoliennes et des panneaux solaires : acquisition des données en temps réel (caméras haute résolution), Efficacité (en réduisant le temps nécessaire pour réaliser des inspections), Imagerie thermique (caméras et captures thermiques), Logiciels d'analyse (algorithmes de traitement et d'analyse embarquée).

Par conséquent, l'objectif de ce sujet de recherche en maîtrise est de proposer un modèle d'apprentissage profond léger et personnalisé pour la détection des défauts structurelles et électriques des surfaces des éoliennes et des panneaux solaires. Pour cela, nous utilisons Neural Architecture Search Network mobile (NasNetMobile) comme modèle d'apprentissage profond léger, car le développement de l'architecture NasNetMobile se concentre sur les plates-formes embarquées et mobiles, on a utilisé le modèle NasNetMobile pour la détection des défauts des éoliennes. Ainsi que le modèle MobileNetV2 est utilisé pour la détection des défauts structurels et électriques des panneaux solaires, enfin la version légère du modèle YOLO est utilisé pour la détection des défauts des PCB.

1.2. Originalités

Notre contribution a porté sur les éléments suivants :

- Intervention dans les architectures des modèles (NasNetMobile, MobileNetv2, YOLO11, YOLOv8) afin de les rendre plus léger et rapide pour la détection en temps réel.
- Réduction du temps de calcul.
- Amélioration des résultats de détection d'anomalies pour les PCB.
- Développement de deux modèles hybrides (NasnetMobile avec Grad-cam) et (MobileNetV2 avec Grad-cam).
- Application de la méthode (Grad-Cam) pour comprendre et interpréter le résultat de nos modèles proposé.
- Les modèles entraînés peuvent être intégré sur des systèmes embarqués tel que (des cartes électroniques).

1.3. Objectifs du sujet de recherche

Notre but est de développer un programme intelligent pour repérer les défauts structurels des éoliennes et des panneaux solaires plus la détection des défauts sur les surfaces des carte électroniques imprimée (PCB), qui fonctionne en temps réel. En remplaçant la méthode traditionnelle tout en s'assurant que notre solution proposée donne des résultats optimisés et adéquats pour répondre aux exigences des problèmes d'inspection et anomalies présentées.

- **Objectif générale :** L'inspection visuelle automatisée et intelligente pour la détection et la localisation d'anomalie.
- **Objectifs spécifiques :**
 - Identification et localisation d'anomalie structurelles et électriques sur les d'éoliennes, les panneaux solaires, et les PCB.
 - Rendre les modèles légers.
 - Classification de plusieurs anomalies parmi les défauts existantes.

1.4. Problématique

Les ressources et les méthodes existantes pour l'inspection et l'identification d'anomalie sont coûteuses et dépendent généralement des caractéristiques prédéfinies en ce qui concerne les tâches d'inspection et contrôle de qualité, de même ils demandent une intervention humaine expérimenté pour l'observation et le contrôle.

- Les principales problématiques dans l'inspection traditionnel :
 - Difficulté d'inspecter et d'observer une anomalie dans les cas complexes.
 - Les circuits PCB de petite taille rendent le processus de détection des défauts difficile et sujet aux erreurs. C'est pour ça la précision pour le modèle est cruciale.
 - Plus d'erreurs humaines.
 - Prise de temps avec un coût élevé pour l'inspection.
 - Dépend d'un employé qualifié.

1.5. Hypothèses

Dans le cadre de ce projet de recherche de maîtrise, différentes hypothèses sont proposées :

- Les données utilisées sont prises par drone (vue aérienne) pour éoliennes et panneaux solaires.
- Les données utilisées pour PCB sont prises par microscope.
- Les données utilisées représentent des images qui contiennent des défauts structurels et électriques.
- Les défauts structurels et électriques se trouvent à la surface des éoliennes, des panneaux solaires, et des PCB.

1.6. Méthodologie de recherche

Dans cette étude on s'intéresse aux éoliennes, panneaux solaires, et PCB, auxquelles des défauts structurelles et électrique sont présentes.

On commence tout d'abord par la rédaction de la revue de littérature à partir d'articles scientifiques, d'actes de conférences, des livres et d'autres sources internet afin de cadrer et souligner l'originalité de notre travail. Ensuite, on passe à la partie d'acquisition des données à partir des bases des données existantes. Ultérieurement, on effectue l'implémentation des modèles intelligents qui permettront la détection et la prédiction des défauts dans les éoliennes, panneaux solaires et les PCB. Enfin, l'évaluation des méthodes utilisés et le déploiement.

Notre approche principale pour atteindre le but et les objectifs du ce projet est constitué de quatre phases.

- La première phase est une revue de la littérature.
- Ensuite dans la deuxième phase, nous collecterons à partir des bases des données disponibles les images qui contiennent des défauts structurelles et électriques des éoliennes, panneaux solaires et PCB.
- Lors de la troisième phase, nous allons prétraiter les images des bases des données collectée, par exemple faire la normalisation, régularisation et nettoyage d'images.

- Enfin, la quatrième étape est de s'assurer de la validité des résultats en les testant et en les comparant avec les solutions proposées dans la littérature.
-
- **Contraintes :** la réalisation du modèle de détection d'anomalies intelligent nécessite des ressources matérielle et logicielles qui sont citées en dessous :
 - Un ordinateur portable puissant,
 - Environnement de développement : Cloud pour entraînement du model (azure Microsoft ou Google cloud),
 - Disponibilité des images qui contiennent des surfaces défectueuses d'éoliennes, panneaux solaires et PCB.

 - **Approche scientifique :** Ce projet de recherche s'inscrit dans le cadre d'une analyse des données pour la détection et la prévention des défaillances, à partir de laquelle on va réaliser un programme d'inspection et détection d'anomalie qui peut être déployé en temps réel pour les éoliennes et les panneaux solaires, ainsi les PCB.

 - **Démarche à suivre**

La figure ci-dessus montre les étapes et processus à suivre pour atteindre nos objectifs fixés.

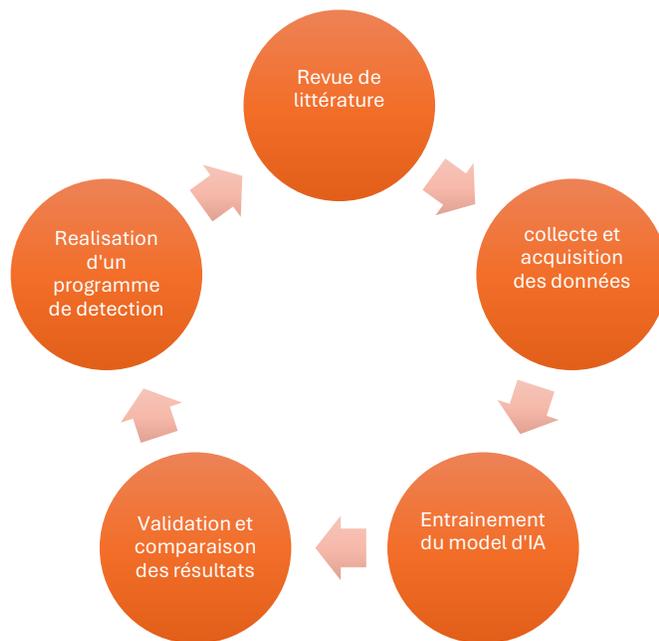


Figure 1: Démarche à suivre.

- **Cadre scientifique :** Ce projet repose en grande partie sur l'utilisation des algorithmes d'intelligence artificielle. De plus, le traitement d'images est une technique vitale qui sera utilisé afin d'effectuer le traitement des données.

Chapitre 2

Aperçu sur la vision intelligente et l'inspection visuelle automatisée

2.1. Introduction

Les technologies de vision intelligente (IVT) sont indispensables aux systèmes intelligents, car les êtres humains dépendent fortement de leur vision. Environ 80 % des informations qu'il reçoit lui parviennent par les yeux. Les technologies de la vision qui pourraient imiter la vision nous permettraient d'améliorer de nombreux domaines, notamment la robotique, la mécatronique, les systèmes d'information, les environnements de travail, etc. Les systèmes de surveillance automatique sont utiles pour la sécurité et la protection des biens et des biens publics, ainsi que pour la prévention et l'inspection des dangers et d'anomalies. Il existe également de nombreux services d'enquête qui nécessitent la surveillance de zones éloignées ou à haut risque en cas de catastrophe ou d'environnements fragiles pour les êtres humains. Il est également intéressant de disposer de systèmes capables d'inspecter et de contrôler automatiquement certaines machines sans aucun travail manuel. Les technologies de vision automatique ont fait l'objet de nombreux travaux de recherche et de développement pour contrôler et traiter les images afin de résoudre les problèmes dans les domaines susmentionnés. Ces technologies de vision émergentes comprennent le traitement des images et des signaux, la vision par ordinateur, les capteurs, la vision

des robots et les systèmes intelligents. Ces technologies englobent des systèmes complexes faisant appel à des recherches menées par plusieurs communautés de chercheurs différentes. Elles exigent des capacités de traitement et d'analyse d'images considérables et sont principalement utilisées pour extraire des informations des données des capteurs dans des domaines spécifiques tels que la sécurité, la surveillance, le contrôle qualité et l'inspection.

2.2. Vision intelligente

La vision intelligente fusionne la vision par ordinateur et l'intelligence artificielle pour permettre aux machines de comprendre et d'interpréter les données visuelles. Elle utilise des techniques telles que le traitement d'images, la détection d'objets et la classification d'images, en recourant à l'apprentissage profond pour améliorer la précision. Les principales applications couvrent divers domaines, notamment dans l'industrie où elle aide à diagnostiquer et contrôler grâce à l'analyse d'images, aussi pour l'automobile, permettant la technologie de conduite autonome grâce à la perception de l'environnement en temps réel. Dans le commerce de détail, l'utilisation de la vision intelligente dans des magasins surveille et analyse le comportement des clients.

Malgré son potentiel, il reste des défis à relever, notamment en ce qui concerne la confidentialité des données, les biais algorithmiques et la nécessité d'effectuer des tests rigoureux dans des conditions réelles. Au fur et à mesure que la technologie évolue, les tendances futures devraient inclure des progrès dans le matériel, des applications de réalité augmentée et des solutions pour les villes intelligentes, afin d'améliorer la vie urbaine grâce à des données visuelles en temps réel.

2.3. Le rôle de l'IA dans les technologies de vision intelligente

L'intelligence artificielle (IA) joue un rôle essentiel dans l'amélioration des technologies de vision intelligente, en permettant aux machines d'interpréter et de comprendre les informations visuelles avec une précision et une efficacité remarquable.

Voici les principaux aspects de la contribution de l'IA :

- Analyse et interprétation des données : Les algorithmes d'IA traitent de grandes quantités des données visuelles, identifient des modèles et donnent un sens à des images et des vidéos complexes. Cette capacité permet aux systèmes de reconnaître des objets, de suivre des mouvements et de classer des scènes.
- Modèles d'apprentissage profond : L'avènement de l'apprentissage profond, en particulier des réseaux de neurones convolutifs (CNN), a révolutionné la vision

par ordinateur. Ces modèles apprennent des caractéristiques hiérarchiques à partir des données, ce qui permet des abstractions de haut niveau et améliore des tâches telles que la classification d'images et la détection d'objets.

- **Traitement en temps réel** : Les algorithmes d'IA peuvent analyser les données visuelles en temps réel, ce qui les rend utilisables pour des applications telles que les véhicules autonomes, les systèmes de sécurité, et les systèmes industrielle, qui nécessitent des réponses immédiates à des environnements dynamiques.
- **Automatisation et efficacité** : En automatisant les tâches d'analyse visuelle, l'IA réduit le besoin d'intervention humaine, ce qui augmente l'efficacité et permet des solutions évolutives dans des secteurs tels que la fabrication, et la vente au détail.
- **Apprentissage adaptatif** : Les systèmes d'IA peuvent apprendre et s'améliorer en permanence à partir de nouvelles données, ce qui leur permet de s'adapter à des conditions changeantes ou aux préférences des utilisateurs. Cette capacité d'adaptation est cruciale pour des applications telles que le marketing personnalisé ou les diagnostics des matériaux industriels évolutifs.

- Précision accrue : L'IA minimise les erreurs humaines dans l'interprétation des données visuelles, ce qui améliore la précision dans des applications où des diagnostics précis peuvent avoir des conséquences importantes.
- Évolutivité : Les technologies d'IA peuvent facilement s'adapter à différentes applications et industries, ce qui permet de déployer des solutions de vision intelligente dans divers contextes sans avoir à procéder à une réingénierie approfondie.
- Détection des anomalies : L'IA excelle dans l'identification des anomalies dans les données visuelles, ce qui est bénéfique pour les applications de sécurité et le contrôle de la qualité dans la fabrication, en aidant à détecter rapidement des modèles inhabituels ou des défauts.

L'IA fait partie intégrante du développement et de l'efficacité des technologies de vision intelligente. En améliorant l'analyse des données, la précision et les réponses en temps réel, l'IA transforme la façon dont les machines perçoivent le monde visuel et interagissent avec lui, ouvrant la voie à des applications innovantes dans de nombreux secteurs. Au fur et à mesure que la technologie continue d'évoluer, son impact va probablement s'étendre encore plus, entraînant de nouvelles avancées et de nouvelles solutions.

La vision par ordinateur est une branche de l'IA qui permet aux ordinateurs d'interpréter des données utiles à partir d'images numériques, de vidéos et d'autres entrées visuelles, puis d'agir ou de fournir des suggestions en fonction de ces données. L'IA permet aux ordinateurs de penser. De la même manière, la vision par ordinateur permet aux ordinateurs de percevoir, d'analyser et de comprendre visuellement leur environnement.

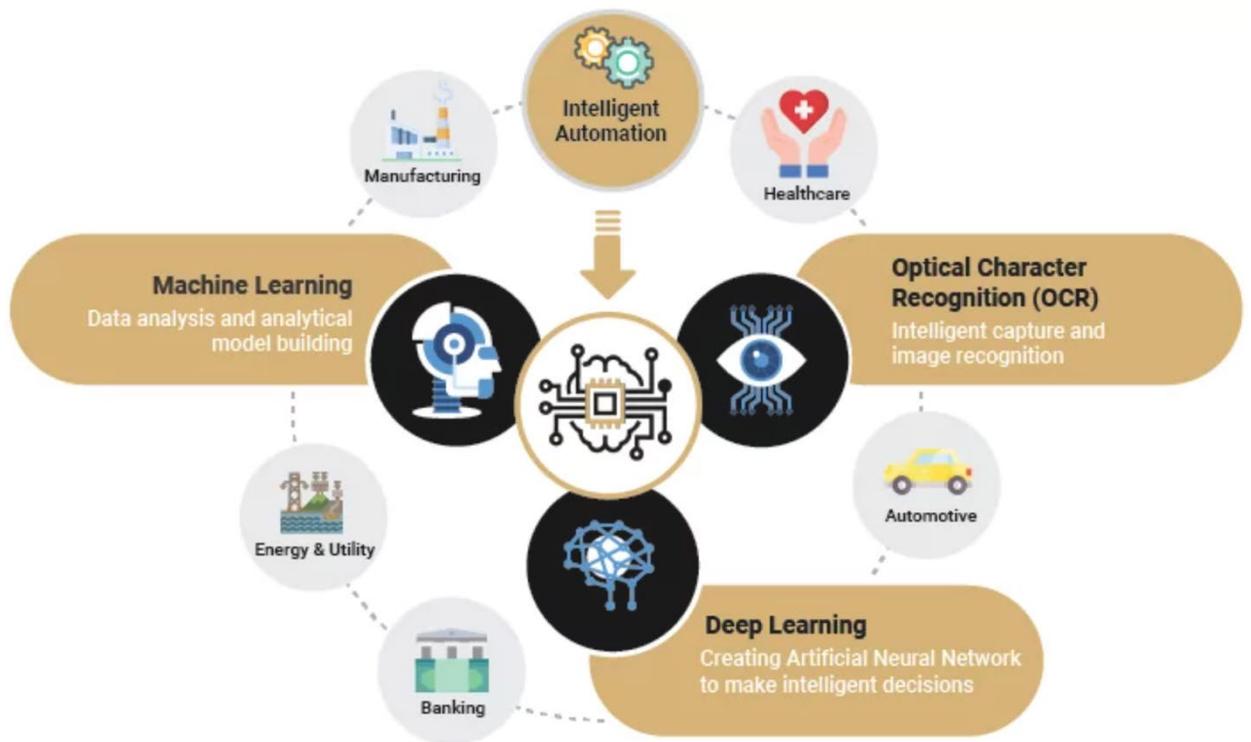


Figure 2 : Vision par ordinateur et intelligence artificielle

2.4. Composants clés de la vision intelligente

La vision par ordinateur est de plus en plus importante et performante. Elle permet aux machines modernes d'interpréter et de comprendre des données visuelles, et de prendre des décisions basées sur celles-ci. Autrement dit, la vision par ordinateur permet aux machines de réagir à de l'information visuelle, comme le font les humains grâce à leur vision. Parmi les composants clés qui assurent l'intégralité du fonctionnement d'un système de vision, on peut citer :

- Acquisition d'images : Il s'agit de l'étape initiale au cours de laquelle les données visuelles sont capturées par des caméras, des capteurs ou d'autres dispositifs d'imagerie. La qualité et le type des données collectées peuvent avoir un impact significatif sur le traitement et l'analyse ultérieurs.
- Prétraitement : À ce stade, les images capturées subissent diverses améliorations et transformations, telles que la réduction du bruit, la normalisation et le redimensionnement. Le prétraitement permet d'améliorer la qualité des données pour une meilleure analyse.
- Extraction des caractéristiques : Cette composante consiste à identifier et à isoler les caractéristiques significatives des images, telles que les bords, les textures et les formes. L'extraction des caractéristiques permet de réduire la

dimensionnalité et de mettre en évidence les informations pertinentes pour la suite du traitement.

- Modèles d'apprentissage automatique : Les algorithmes d'apprentissage automatique sont au cœur de la vision intelligente, en particulier les modèles d'apprentissage profond tels que les réseaux neuronaux convolutifs (CNN). Ces modèles apprennent à partir d'ensembles des données étiquetés pour effectuer des tâches telles que la classification d'images et la détection d'objets.
- Détection et reconnaissance d'objets : Il s'agit d'identifier et de localiser des objets dans une image. Des techniques telles que les boîtes de délimitation et la segmentation sont utilisées pour définir les limites des objets et les classer avec précision.
- Traitement en temps réel : Les systèmes de vision intelligente nécessitent souvent la capacité de traiter et d'analyser des données en temps réel. Il est donc essentiel d'optimiser les algorithmes pour gagner en rapidité sans sacrifier la précision, en particulier dans des applications telles que la surveillance et la robotique.

- Fusion des données : Il s'agit d'intégrer des données provenant de sources multiples (caméras, ou capteurs) afin d'obtenir une compréhension globale de l'environnement. La fusion des données améliore la précision et la robustesse du système de vision.
- Interface utilisateur et visualisation : Des outils de visualisation et des interfaces utilisateur efficaces sont essentiels pour interpréter les résultats et les informations tirés des systèmes de vision intelligente. Il peut s'agir de tableaux de bord, d'alertes et de représentations graphiques des données.
- Mécanismes de retour d'information : L'intégration de boucles de retour d'information permet au système d'apprendre et de s'améliorer au fil du temps. En analysant les résultats et les interactions avec l'utilisateur, le système peut affiner ses algorithmes et améliorer ses performances.

Ces composants clés fonctionnent ensemble pour créer des systèmes de vision intelligente robustes capables d'interpréter efficacement les données visuelles. Au fur et à mesure que la technologie progresse, l'intégration et l'optimisation de ces composants continueront à améliorer les capacités et les applications de la vision intelligente dans divers domaines.

2.5. Inspection visuelle automatisée

L'inspection visuelle automatisée (IVA) est devenue une technologie cruciale dans la recherche de la gestion de la qualité dans de nombreux secteurs. La capacité des systèmes d'inspection visuelle automatisée à évaluer régulièrement les produits en temps réel renforce les opérations de contrôle de la qualité, en réduisant la fréquence des défauts et en améliorant l'efficacité globale de la fabrication [1].

Traditionnellement, l'examen visuel est un élément essentiel du contrôle de la qualité. Les inspecteurs qualifiés utilisent leurs compétences pour évaluer les produits afin de détecter les défauts. Néanmoins, cette méthodologie est vulnérable aux contraintes humaines, telles que l'épuisement et les biais cognitifs, qui peuvent nuire à la précision de l'inspection [2]. Avec l'augmentation de la quantité et de la complexité de la production, il devient impératif d'améliorer les techniques d'inspection, ce qui rend l'IVA une alternative souhaitable.

Les systèmes d'inspection par vision automatique (IVA) utilisent des caméras et des capteurs pour prendre des images haute définition de divers produits assemblés sur des chaînes de montage. Les images capturées sont ensuite analysées à l'aide de formules de calcul avancées qui permettent de repérer les défauts. L'identification de ces défauts repose sur des critères qui ont été préétablis et mis en place [3].

Dans le domaine des systèmes IVA, les techniques d'apprentissage automatique se sont révélées extrêmement influentes. Ces techniques permettent aux systèmes d'apprendre à partir de vastes bases des données contenant des images de produits acceptables et de produits présentant des défauts. En apprenant à partir de ces vastes ensembles d'informations, les systèmes IVA ont la capacité de s'adapter et d'améliorer leur capacité à repérer les défauts. Ce processus continu d'apprentissage et d'adaptation se traduit par des améliorations constantes des capacités des systèmes à détecter et à identifier les défauts des produits [4].

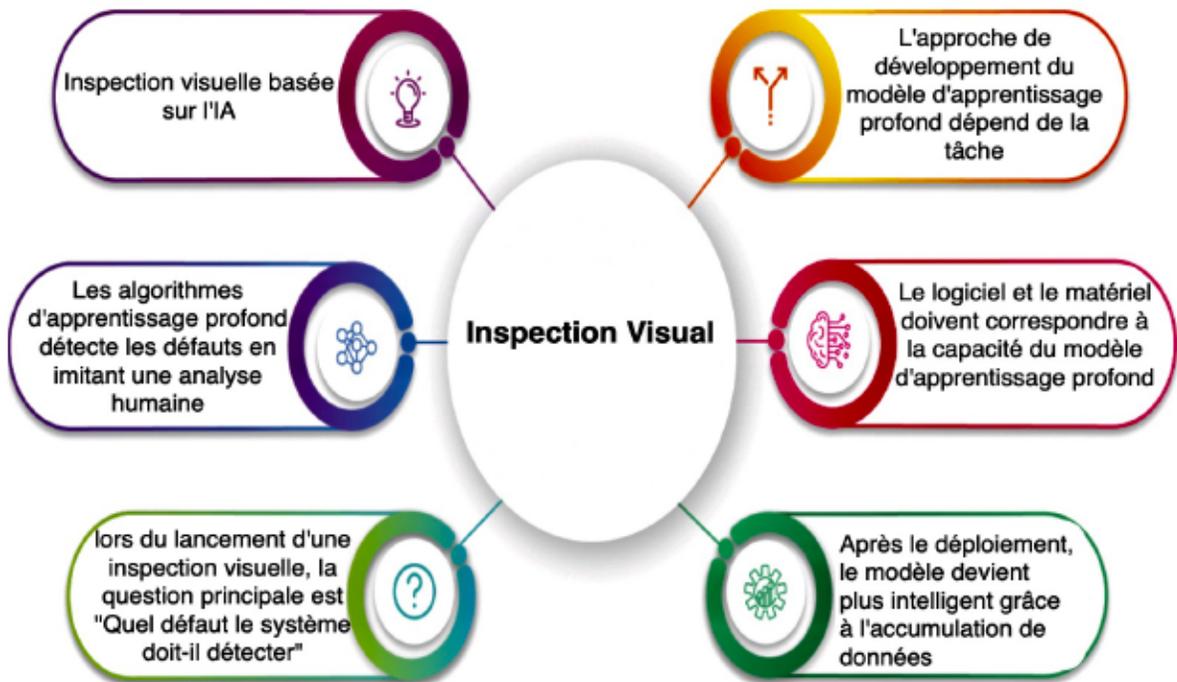


Figure 3 : Inspection visuelle pour la détection des défauts

2.6. Détections d'anomalies dans l'IVA

L'identification des anomalies dans le cadre de l'inspection visuelle automatisée (IVA) concerne la reconnaissance d'occurrences ou de modèles dans le contenu visuel qui s'écartent des normes ou stipulations accréditées. Cette procédure est essentielle pour garantir l'alignement du produit sur les conditions de qualité avant qu'il ne soit accessible au consommateur. La détection rapide des anomalies réduit le risque d'infiltration de produits défectueux sur le marché, ce qui renforce la fiabilité de la marque et la satisfaction de l'acheteur. Les fabricants ont ainsi la possibilité de s'attaquer instantanément aux problèmes émergents, ce qui réduit le risque associé aux rappels ou aux retours de produits coûteux. En outre, l'identification efficace des anomalies contribue de manière significative à l'efficacité opérationnelle globale en réduisant à la fois le gaspillage et les réparations. Les systèmes robustes d'identification des anomalies s'avèrent inestimables pour les industries qui doivent préserver la qualité malgré l'augmentation des volumes de production.

2.6.1. Méthodes utilisées

Approches d'analyse quantitative (statistiques) : Les méthodes conventionnelles utilisent des outils d'analyse quantitative pour établir des critères de qualité satisfaisante. Les éléments qui ne répondent pas à ces critères sont identifiés comme aberrants.

Apprentissage machine : Les systèmes plus sophistiqués utilisent des algorithmes d'analyse automatique des données, tels que l'apprentissage supervisée et non supervisée, pour former des modèles prédictifs sur ce qui est considéré comme un comportement « typique ». Les techniques les plus répandues sont les suivantes :

- Machine à vecteur de support (SVM) : Il s'agit d'un outil efficace pour les tâches de catégorisation où les valeurs aberrantes peuvent être différenciées des points des données réguliers.
- Réseaux neuronaux artificiels ANN : Il s'agit de modèles d'apprentissage avancés, généralement des réseaux neuronaux convolutifs (CNN), qui sont utilisés pour apprendre de manière indépendante les caractéristiques des images en vue de la détection des valeurs aberrantes.

2.7. Avantages de l'inspection visuelle automatisée

L'introduction d'une technologie d'inspection visuelle automatisée présente de nombreux avantages notables :

- Cohérence et précision : Les systèmes d'inspection visuelle automatisée (IVA) garantissent une méthode uniforme d'examen des résultats, éliminant les

incohérences qui peuvent survenir en raison de la fatigue humaine ou d'un manque d'attention [5].

- Efficacité accrue : Ces types de systèmes ont la capacité de fonctionner à des niveaux de vitesse impressionnants, ce qui réduit considérablement la durée de l'inspection et, par conséquent, stimule la capacité de production globale [6].
- Réduction des coûts : Bien que l'investissement initial dans la technologie IVA puisse être considérable, les avantages durables - notamment la diminution de la fréquence des défauts et des coûts de main-d'œuvre - peuvent conduire à des économies financières remarquables [7].
- Amélioration de la collecte des données : Les systèmes IVA contribuent à l'accumulation et à l'évaluation de vastes ensembles des données, offrant un aperçu des méthodologies de production qui peut aider à planifier des stratégies d'amélioration constante [8].

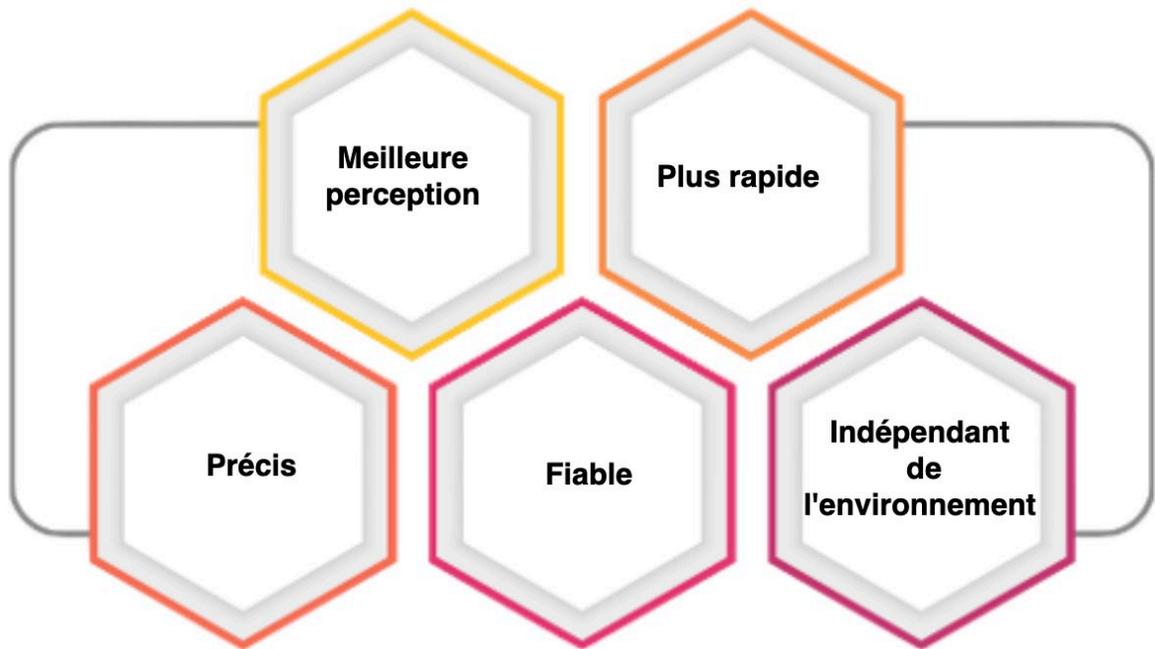


Figure 4 : Avantages de l'inspection visuelle automatisée

Dans l'inspection visuelle automatisée, les erreurs sont souvent systématiques et peuvent être rectifiées par des mises à jour logicielles ou des recalibrages. En revanche, les erreurs d'inspection manuelle peuvent être plus sporadiques et imprévisibles, et sont souvent liées au discernement ou à la supervision de l'homme.

En outre, l'un des principaux avantages de l'examen visuel automatisé (IVA) est sa capacité à détecter les défauts des matériaux dès les premières étapes de la fabrication. Grâce à l'analyse de modèles dans les données visuelles, les systèmes d'IVA sont capables de prédire et d'identifier les problèmes potentiels avant qu'ils ne s'aggravent, permettant ainsi une intervention précoce. Cette approche proactive contribue à réduire la nécessité de modifications coûteuses des matériaux et à diminuer le gaspillage, ce

qui se traduit par des avantages significatifs en termes de coûts et une meilleure utilisation des ressources.

2.8. Applications dans diverses industries

L'inspection visuelle automatisée est un processus technologiquement avancé qui utilise des caméras, des capteurs et des algorithmes pour identifier les irrégularités et les anomalies afin de garantir la conformité aux normes réglementaires, en mettant en évidence sa vitesse et sa précision supérieures à celles des inspecteurs humains. Ce système trouve des applications spécifiques dans diverses industries telles que la production de semi-conducteurs, l'automobile, la biopharmacie, entre autres, ce qui témoigne de la fonction essentielle que joue l'inspection visuelle automatisée dans le maintien de la sécurité, de l'efficacité et de la qualité dans de nombreux secteurs.

Cette technologie permet d'identifier les défauts, de garantir le respect des normes réglementaires et de renforcer les opérations de fabrication grâce à des inspections rapides, impartiales et fiables. L'essence de ce système réside dans sa capacité à assimiler et à interpréter les images à des vitesses et avec des précisions qui dépassent de loin les capacités humaines.

Certains secteurs qui utilisent l'IVA pour effectuer le contrôle de la qualité et la surveillance pour la détection des anomalies :

- Secteur manufacturier :
 - Dans le domaine de l'électronique : Dans le domaine de l'électronique :
IVA peut facilement être utilisé dans le domaine de l'électronique pour identifier les circuits imprimés contenant différents composants. L'un des avantages de cette approche est qu'elle permet de localiser des défauts tels que des soudures au mauvais endroit, des composants mal placés ou des rayures mineures sur la surface de la pièce.
 - Dans le domaine de l'industrie automobile : Dans le secteur de la fabrication automobile, les systèmes IVA aident à inspecter les pièces pour vérifier la précision métrique, les disparités de surface et l'assemblage correct. Leur fonction favorise le respect des normes de sécurité et de qualité des composants.
- Secteur pharmaceutique : Dans le secteur pharmaceutique, les systèmes IVA sont utilisés pour l'inspection des ampoules et des emballages pharmaceutiques. Ces systèmes contribuent à garantir la pureté des produits en identifiant les contaminations potentielles, en vérifiant l'exactitude de l'étiquetage et en confirmant que les produits respectent des spécifications acceptables en termes de dimensions et de niveau de remplissage.

- Construction et génie civil : Les technologies d'inspection visuelle avancée (IVA) deviennent progressivement essentielles dans le secteur de la construction pour l'examen des matériaux et des éléments, tels que les composants en béton préfabriqués. Elles permettent de garantir que les structures respectent les normes de sécurité et les protocoles de conception.
- Optique et verre : Dans le domaine de l'optique, l'IVA est utilisée pour examiner les lentilles et les surfaces en verre à la recherche d'imperfections.
- Robotique et automatisation : Les systèmes IVA sont intégrés dans des opérations robotiques pour des fonctions telles que l'identification et le positionnement d'objets sur la base d'informations visuelles. Cela améliore l'efficacité des installations de stockage et des lignes de production mécanisées.

La diversité de la technologie de l'inspection visuelle automatisée (IVA) en fait un outil puissant dans de nombreux secteurs. En améliorant la qualité des produits, en stimulant la productivité et en réduisant les imprécisions humaines, l'inspection visuelle automatisée devient de plus en plus essentielle dans les opérations contemporaines de production et de contrôle de la qualité. À mesure que les progrès techniques se poursuivent, il est probable que les utilisations possibles de l'inspection visuelle évoluent encore, stimulant la nouveauté et l'amélioration dans différents domaines.

2.9. Défis et considérations

Malgré les nombreux avantages de l'IVA, le principal obstacle reste la construction d'algorithmes solides capables de faire face à diverses situations d'inspection [9]. Toutefois, une planification judicieuse et une administration efficace permettent d'atténuer efficacement ces problèmes.

En résumé, l'inspection visuelle automatisée représente une avancée significative dans les procédures de gestion de la qualité. En assimilant cette innovation, les institutions peuvent améliorer la précision et l'efficacité de l'inspection tout en réduisant les erreurs humaines. Si les secteurs persistent à adopter et à perfectionner ces systèmes, les possibilités d'amélioration de la qualité des produits et des performances opérationnelles seront considérables [10].

2.10. Conclusion

L'inspection visuelle automatisée (IVA) est en train de révolutionner le domaine du contrôle qualité, en offrant une précision et une efficacité accrues dans divers secteurs. Son aptitude à fournir des résultats cohérents et à examiner les données instantanément permet aux entreprises d'améliorer considérablement la qualité de leurs produits. Au fur et à mesure que la prévalence des technologies IVA augmente dans les différentes industries, on peut s'attendre à des progrès significatifs en matière de qualité et de productivité. L'évolution constante de l'intelligence artificielle et des techniques de

traitement d'images élargira l'utilisation de l'IVA, ouvrant ainsi la voie à des solutions innovantes. En conclusion, le rôle de l'IVA est crucial pour atteindre une fiabilité et une compétitivité supérieures sur le marché dynamique.

Chapitre 3

Détection des défauts structurelles des éoliennes basée sur un modèle de détection d'objets légers et le deep learning

3.1. Introduction

Selon l'Agence internationale de l'énergie [11], [12], les énergies alternatives, notamment l'énergie éolienne qui représentait 11 % de toute l'énergie alternative produite en 2012 [13,14], devraient devenir le principal moteur de la capacité de production d'électricité mondiale, représentant entre 75 % et 80 % de la capacité nouvellement installée d'ici 2050.

Les éoliennes font partie intégrante de la promotion du développement durable, car elles produisent de l'énergie renouvelable et réduisent considérablement les émissions de gaz à effet de serre [15]. Le vent, en tant que source d'énergie renouvelable, est abondant et inépuisable, et constitue donc un aspect crucial de la transition vers des solutions énergétiques durables [16]. Le déploiement des parcs d'éoliens renforce l'autonomie énergétique en réduisant la dépendance à l'égard des combustibles fossiles et en augmentant la stabilité des coûts énergétiques [17]. En outre, l'industrie de l'énergie éolienne génère une myriade de possibilités d'emploi dans des domaines tels que la fabrication, l'installation et la maintenance [18]. L'énergie éolienne est également bénéfique pour la santé publique en réduisant la pollution de l'air et les risques

sanitaires associés [19]. En outre, la technologie contemporaine des éoliennes est conçue pour minimiser l'empreinte environnementale, préservant ainsi les écosystèmes locaux [20]. L'énergie éolienne peut être exploitée aussi bien dans les zones rurales que dans les zones urbaines, ce qui favorise une disponibilité équitable de l'énergie [21]. L'intégration de l'énergie éolienne dans la matrice énergétique permet d'équilibrer le progrès économique et la préservation de l'environnement [22]. En fin de compte, il est impératif d'augmenter l'infrastructure de l'énergie éolienne pour répondre aux besoins énergétiques mondiaux et atténuer le changement climatique [23].

De nombreux facteurs soulignent l'importance des énergies renouvelables dans la réalisation du développement durable :

- L'énergie solaire et l'énergie éolienne, dont les émissions de gaz à effet de serre sont négligeables ou nulles, sont les sources d'énergie renouvelable les plus importantes pour atténuer le changement climatique par rapport aux combustibles fossiles.
- Les sources d'énergie renouvelables restent les plus accessibles à l'échelle humaine. Le renouvellement incessant des ressources garantit la survie de la lumière du soleil, et du vent.
- Les pays peuvent bénéficier d'investissements dans les énergies renouvelables en réduisant leur dépendance à l'égard des combustibles fossiles importés, en améliorant leur sécurité énergétique et en établissant

une stabilité économique tout en minimisant leur dépendance à l'égard des importations.

- La création d'emplois dans des domaines tels que la fabrication, l'installation, la maintenance et autres dans l'industrie des énergies renouvelables nécessite une main-d'œuvre, ce qui pourrait conduire à une expansion économique.
- Le déploiement de technologies d'énergie renouvelable dans des régions éloignées ou mal desservies peut améliorer le niveau de vie des communautés qui ne disposent pas d'une alimentation régulière en facilitant l'accès à l'électricité.

Les éoliennes sont constituées de plusieurs composants essentiels qui convertissent collectivement l'énergie éolienne en énergie électrique. Au premier plan se trouvent les pales du rotor, qui exploitent l'énergie éolienne grâce à leur conception aérodynamique, ce qui influe considérablement sur l'efficacité énergétique [24]. La nacelle, située au sommet de la tour, contient des machines essentielles, notamment le multiplicateur et le générateur, qui convertissent l'énergie mécanique en énergie électrique [25]. La tour elle-même surélève ces composants pour capter les vents les plus forts et fournit un soutien structurel [26]. En outre, les systèmes de contrôle garantissent des performances et une sécurité optimale lorsque les conditions de vent varient, ce qui illustre l'intégration sophistiquée de la technologie dans les turbines modernes [27]. Il

est essentiel de comprendre ces composants pour améliorer la conception des turbines et maximiser la production d'énergie renouvelable.

Comment le montre la figure 5, une éolienne typique se compose d'une fondation en béton, d'une tour en acier et/ou en béton, d'une nacelle en acier et en cuivre, aussi de trois pales fabriquées à partir de matériaux composites à base de fibres de carbone ou de fibres de verre [28-30].

Les composants des éoliennes sont extrêmement sensibles, en particulier les pales qui sont essentielles au fonctionnement des éoliennes, et ont un impact considérable sur les performances et la productivité de la production d'électricité [31].

La réparation et l'entretien des éoliennes présentent des défis importants en raison de la sensibilité et de la complexité de leurs composants. Chaque éolienne se compose des systèmes complexes, notamment des pales de rotor, des boîtes de vitesse et des générateurs, qui sont conçus pour fonctionner dans des conditions difficiles [32]. Les matériaux utilisés, tels que les composites avancés pour les pales et les alliages à haute résistance pour les tours, sont essentiels pour la durabilité mais contribuent également à des coûts de réparation élevée [33]. Le remplacement de composants défectueux ou de turbines entières est une opération coûteuse, qui se chiffre souvent en centaines de milliers, voire en millions de dollars.

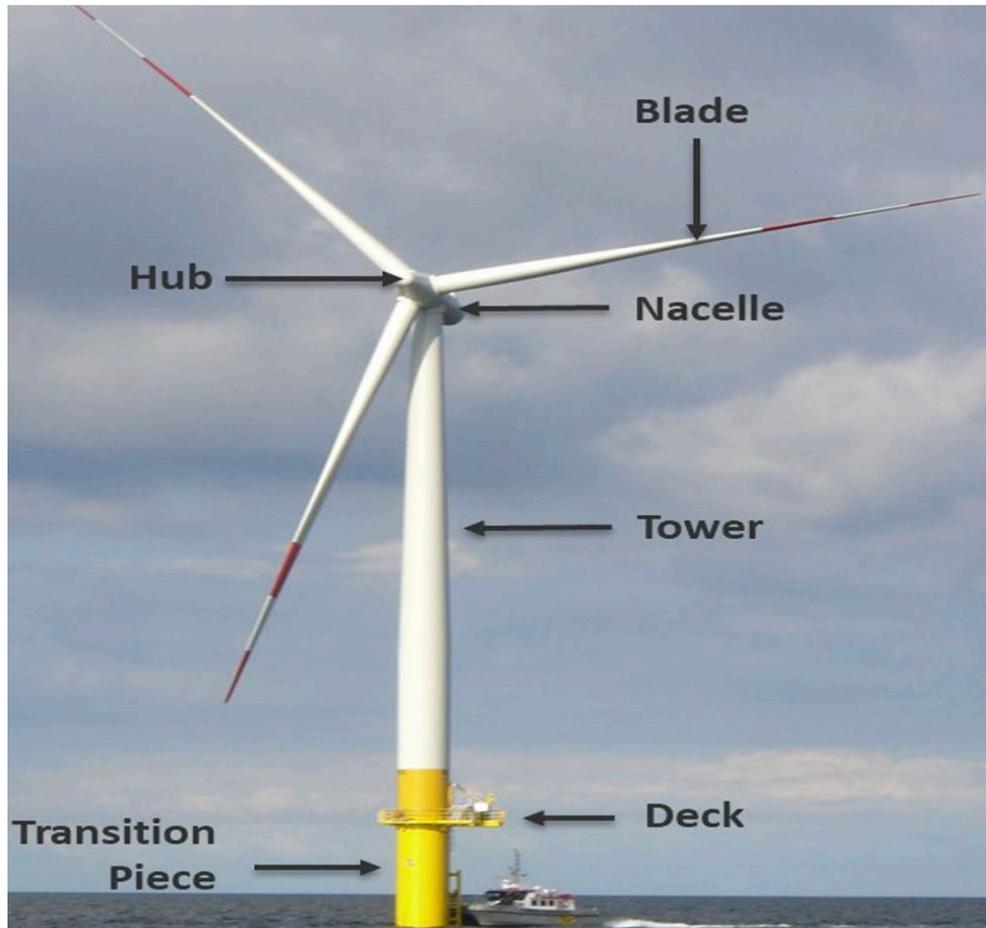


Figure 5 : Composants d'éoliennes.

En outre, la situation géographique de nombreux parcs d'éoliens, souvent situés dans des zones reculées, accroît les défis logistiques et les coûts associés aux activités de maintenance [34]. Le respect des réglementations strictes en matière de sécurité nécessite l'intervention des techniciens spécialisés, ce qui augmente encore les dépenses [35]. Les implications économiques des temps d'arrêt des turbines dus aux réparations qui sont importantes, car la perte de production a un impact direct sur le chiffre d'affaires [36].

De plus, si les avancées technologiques peuvent améliorer l'efficacité opérationnelle, elles entraînent souvent des coûts initiaux plus élevés et des complexités qui compliquent les processus de réparation [37]. Un entretien régulier et des systèmes de surveillance efficaces sont essentiels pour atténuer ces problèmes de réparation, mais ils nécessitent également des investissements dans des connaissances et des équipements spécialisés [38].

La prise en compte de ces facteurs est essentielle pour les parties prenantes qui cherchent à optimiser la viabilité économique des projets d'énergie éolienne, en soulignant la nécessité d'une planification stratégique et d'un investissement dans les pratiques de maintenance [39].

En raison de l'augmentation du nombre d'installations d'éoliennes dans le monde, de nombreux parcs d'éoliens sont désormais équipés de caméras de surveillance et travaillent sur des systèmes permettant d'identifier les défauts des turbines. L'anticipation des pannes permet d'économiser de l'argent et d'augmenter la production d'énergie. L'inspection des éoliennes est complexe et risquée pour les travailleurs, car les pièces sont coûteuses et susceptibles d'être endommagées. L'inspection des éoliennes est donc vitale. Par conséquent, afin de prévenir les pannes et de réduire les frais de réparation, l'inspection des éoliennes est essentielle. En outre l'absence de bases des données concernant les dysfonctionnements des éoliennes rend la situation difficile pour avoir un model intelligent, notre analyse de la littérature s'est concentrée sur la recherche d'un ensemble des données contenant des d'éoliennes défectueuses.

Donc, l'objectif de cette recherche est de proposer un modèle de deep learning (DL) spécialisé et léger pour détecter les défauts structurels sur les éoliennes. En première lieu, nous avons utilisé NasNetMobile model car il est conçu spécifiquement pour les plateformes embarquées et mobiles, en plus l'utilisation de l'algorithme Grad-CAM (Gradient-weighted Class Activation Mapping) pour nous aider à illustrer comment notre modèle personnalisé prédit les dommages et détecte la zone défectueuse dans l'éolien. Par la suite et après avoir élargi le nombre d'images dans la base des données et diversifier les types des défauts, nous avons utilisé la détection d'objet avec YOLOv11 pour entraîner un modèle de détection d'objet léger YOLO-lightweight.

3.2. Revue de la littérature

La montée en puissance de l'énergie éolienne met en évidence l'importance d'une détection efficace des problèmes dans les éoliennes pour maintenir leur efficacité et leur fiabilité opérationnelles. Plusieurs recherches ont examiné différentes approches pour détecter les défauts dans les pièces des éoliennes, en privilégiant la détection précoce pour réduire les temps d'arrêt et les dépenses de réparation.

Ces dernières années, divers modèles d'apprentissage profond (DL) ont été proposés comme solution pour identifier les défauts sur les ensembles des données d'éoliennes. Plus récemment, dans [40] (2024), YOLOv5 a été utilisé pour détecter les défauts de surface dans les éoliennes. Un algorithme proposé basé sur YOLOv5 amélioré a montré une amélioration de 3,1 % de la précision moyenne (mAP), la base des données

contient également diverses classes de dommages aux éoliennes, notamment (huile de surface, corrosion, fissure, blessure en surface, etc.), ajoutant que certaines images ont été collectées sur le Web.

Dwivedi et al [12] (2024) ont proposé un cadre de détection pour la surveillance des surfaces afin d'identifier les dommages structurels sur les panneaux solaires et les pales d'éoliennes, à l'aide de transformateur Vision (ViT). Le modèle ViT surpassé les autres modèles DL, notamment MobileNetV1, VGG16, Xception, EfficientNetB7 et ResNet50, avec une précision de 97 %. Cet article a atteint une bonne précision car les images utilisées pour l'éolienne ont une zone de dommages claire et importante qui aide le modèle à distinguer entre zone saine et zone défectueuse.

Pendant ce temps, les auteurs Shekaramiz et al [41] (2024) ont proposé une architecture de réseau neuronal convolutif (CNN) personnalisée pour la détection d'anomalies sur les pales d'éoliennes comparé à cinq autres CNN tels que (Xception, Resnet-50, AlexNet et VGG-19), le modèle CNN personnalisé proposé a atteint une précision de test de 96,67 %.

La détection d'objets a également été utilisée [42] (2022) pour détecter et localiser les défauts des éoliennes. XIUKANG et al ont proposé un algorithme YOLO (AFB-YOLO) amélioré, basé sur YOLOv5. Plus précisément, AFB-YOLO améliore le réseau de base. La précision moyenne (mAP) de l'AFB-YOLO était de 83,7 % et la précision de détection est améliorée de 4,0 % par rapport au modèle YOLOv5s de base.

Des réseaux de neurones profonds sont appliqués Demirci et al. [43], (2021), qui consiste en une étape Haar-AdaBoost pour la proposition de région et un classificateur de réseau neuronal convolutif (CNN) pour la détection des dommages et le diagnostic des défauts, le modèle proposé a obtenu une précision de 97 % pour 5 classes telles que (normal, fibre, défauts, fissures, défauts de revêtement, érosion des bords), le modèle surpasse les autres méthodes, notamment les modèles SVM et VGG16.

Détecter les dommages causés aux pales d'éoliennes à partir d'images de drones nécessite un modèle léger capable d'extraire efficacement les caractéristiques des images en un temps record avec une grande précision. L'objectif de ce sujet est donc de disposer d'un modèle léger capable de détecter les dommages sur les pales d'éoliennes. Pour cela, dans ce travail, nous proposons d'utiliser le modèle NasNetMobile qui est un modèle de réseau de neurones profond léger et peu coûteux pour calcul [44].

Bien que de nombreuses techniques aient été explorées pour détecter les défaillances dans les éoliennes, la littérature souligne l'importance des méthodes variées. À mesure que les technologies progressent avec le temps, la combinaison de ces approches pourrait conduire à des systèmes de surveillance plus robustes et efficaces, réduisant considérablement les coûts des entretiens et prolongeant la durée de vie opérationnelle des actifs éoliens.

3.3. Méthodologie et analyse expérimentale

Dans ce chapitre, nous suggérons deux étapes à suivre. Tout d'abord, nous avons utilisé une base des données contenant uniquement deux catégories (éoliennes défectueuses et non défectueuses). Ensuite, dans la deuxième étape, nous avons enrichi et varié notre base des données en y ajoutant d'autres images pour obtenir 2 classes de défaut différentes représentant les défauts structurels des éoliennes. Dans la suite, nous allons examiner deux étapes pour cette étude.

Cette étude a été réalisée en utilisant le langage de programmation Python et en utilisant la plateforme Google cloud avec un carte graphique Nvidia. Pour l'entraînement, 100 itérations sont prises en compte dans l'exécution. Dans cette section, un résultat est fourni sur les différentes mesures d'évaluations qui sont utilisées pour analyser les performances du modèle proposé.

3.3.1. Entraînement basé sur NasNetMobile

La base des données utilisé dans cette partie a été créé au Machine Learning and Drone Lab de l'Utah Valley University (CAI-SWTB) [41], une éolienne Primus Air Max a été déployée pour créer l'ensemble des images montrant des éoliennes défectueuses, avec une prise aérienne d'éoliennes extérieures et intérieures. Des images des pales d'éoliennes ont été prises. Au total, 6 000 pales ont été utilisées pour créer un ensemble des images des pales normales sans défauts et un ensemble des images des pales défectueuses.. Les images sont réparties en 70 % pour l'entraînement, 20 % pour la

validation et les 10 % restants pour le test. La figure 6 ci-dessus présente quelques exemples d'images de notre base des données avec différents défauts.

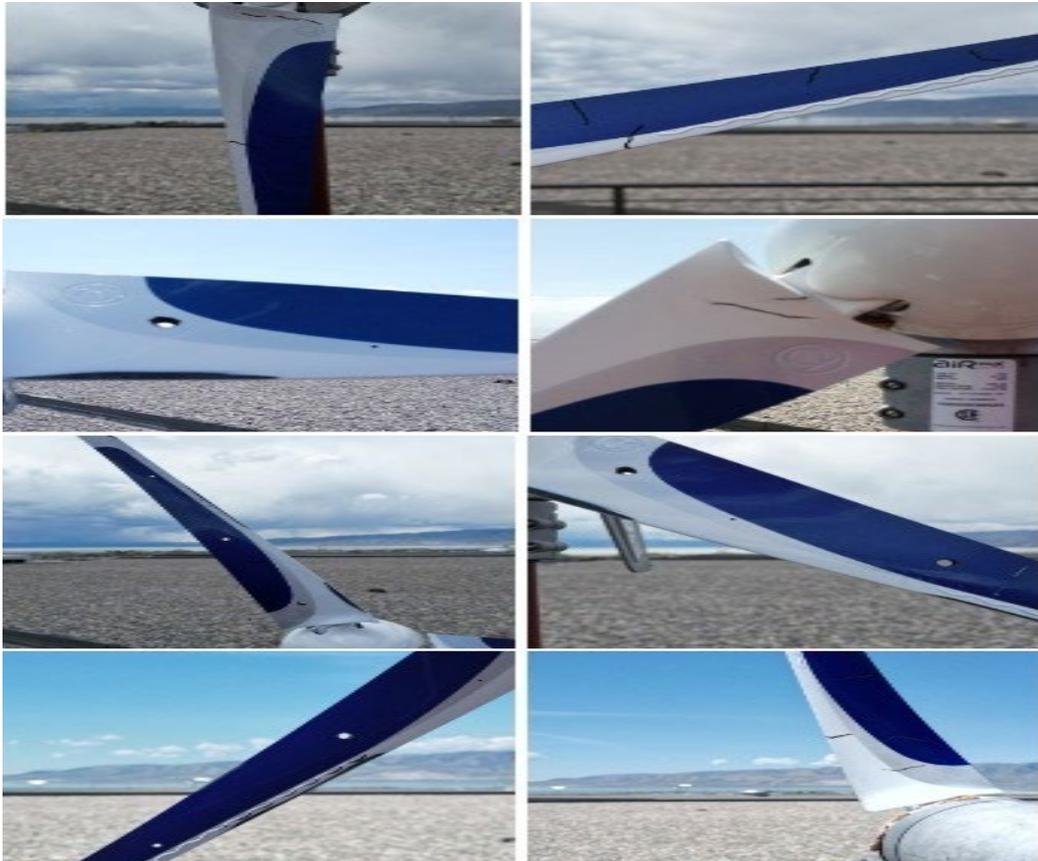


Figure 6 : Images d'éoliennes de la base des données 1 [41].

3.3.1.1 Augmentation des images

Les images de base des données ne sont pas assez grandes pour permettre la généralisation du modèle du DL sur les images. Pour résoudre le problème, nous avons utilisé la technique d'augmentation des données à l'aide de (la bibliothèque python keras ImageDataGenerator), la technique d'augmentation permet d'enrichir la base des

données avec plusieurs autres images en créant de nombreuses variantes des images existantes, cela fournit aussi un jeu des données plus important pour l'entraînement et permet à un modèle de rencontrer des caractéristiques plus diverses. En effectuant certaines techniques de traitement d'image telles que le redimensionnement, la rotation, le zoom, le retournement horizontal, le décalage en hauteur, ces techniques ont été appliquées pour générer des nouvelles images pendant l'entraînement.

3.3.1.2 Modèle d'apprentissage profond NasNetMobile

La recherche d'architecture neuronale (NAS) est une technique de DL dans le domaine des réseaux neuronaux artificiels (ANN). NasNetMobile est l'une des variantes légères de l'architecture (NAS). Elle a été proposée par l'équipe Google brain en 2016 et se compose de trois éléments : l'espace de recherche, la stratégie de recherche et l'estimation des performances. L'espace de recherche implique la recherche des performances convoluées, entièrement connectées, max-pooling, etc. puis la vérification de la connexion entre les couches à travers lesquelles des architectures de réseau réalisables complètes sont formées. La stratégie de recherche implique l'utilisation de la recherche aléatoire et de l'apprentissage renforcé pour échantillonner la population de candidats à l'architecture de réseau en recevant des récompenses de performance du modèle enfant (précision maximale, gestion du temps). Parallèlement, l'objectif principal de l'estimation des performances est de réduire les ressources informatiques ou la régulation temporelle de l'architecture du réseau, de sorte que les

performances sont estimées à la position de la stratégie de recherche lors de la réception des récompenses de performance du modèle enfant.

Dans ce travail proposé, nous avons modifié ce modèle et nous l'avons ensuite entraîné avec des images qui représentent des défauts des éoliennes. Une couche entièrement connectée a été supprimée au cours du processus d'ajustement et une nouvelle couche a été ajoutée, qui n'incluait que des classes sélectionnées des défauts structurelles des éoliennes. Ensuite, le modèle modifié a été entraîné afin d'avoir un nouveau modèle [45], [46]. L'architecture du NasNetMobile est illustrée dans la figure ci-dessous.

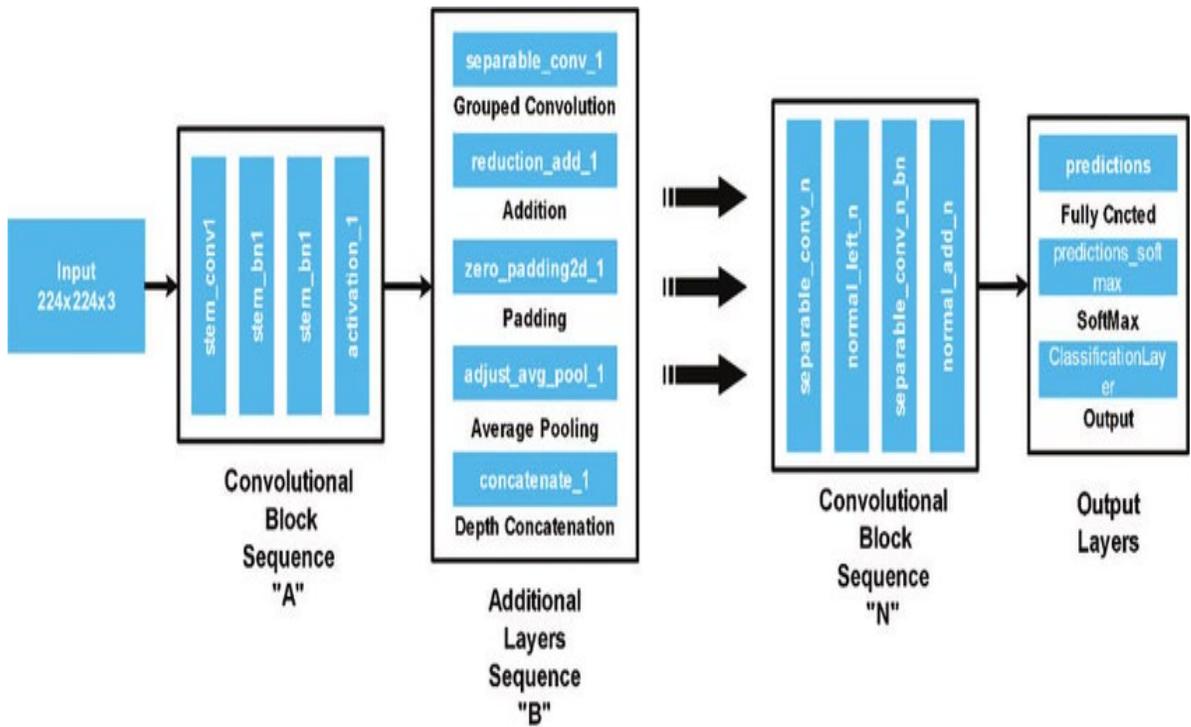


Figure 7 : L'architecture de NasNetMobile.

La Figure suivante montre notre solution proposée de détection des défauts des éoliennes avec le modèle léger NasNetMobile.

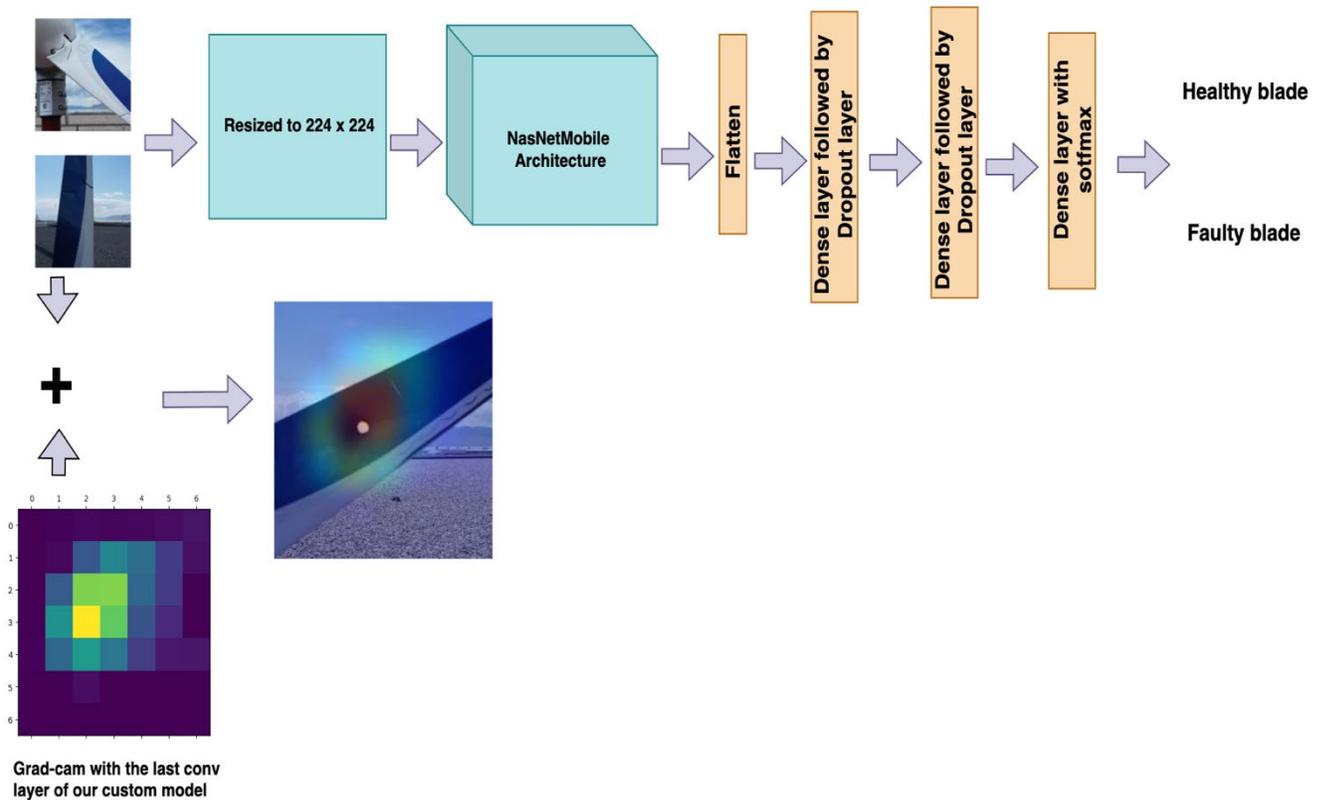


Figure 8 : solution proposée pour la détection des défauts des éoliennes

3.3.1.3 Réglage des hyperparamètres

Pour améliorer et réduire le temps de calcul dans l'étape d'entraînement [47], les images des éoliennes sont redimensionnées à 224×224 pixels, qui seront utilisées ensuite comme entrées pour notre modèle NasNetMobile considéré, car les images sont de tailles différentes. D'autres hyperparamètres sont ajustés pour obtenir de meilleures

performances dans l'entraînement du modèle, notamment le taux d'apprentissage = 0,001, l'optimiseur = Adam, et l'utilisation d'une fonction de rappel pour réduire le taux d'apprentissage si l'erreur de validation ne diminue pas.

3.3.1.4 Méthodes pour l'évaluation du modèle

L'évaluation du modèle est une étape nécessaire pour la réalisation du projet. Cela nous aide à évaluer si le modèle sélectionné contribuera à prédire correctement la cible dans le contexte des nouvelles données. Nous allons débiter par définir quelques notions avant de passer à la définition des métriques.

- **Matrice de confusion (Confusion Matrix) :** Dans les problèmes de classification, il est nécessaire de comparer les résultats prédits avec la réalité pour évaluer leur degré de performance. La matrice de confusion permet de mettre en évidence les prédictions correctes et incorrectes, tout en indiquant les types d'erreurs commises.

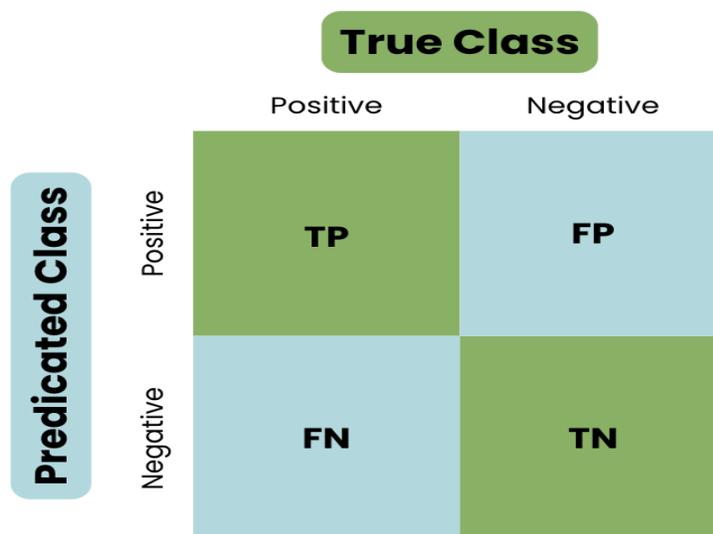


Figure 9 : Matrice de confusion.

- **True Positive (Vrai positif)**: Ce sont les prédictions qui forment un match avec la valeur réelle. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y'a un défaut » et la prédiction est : « il y'a un défaut ».
- **False Negative (Faux négatif)** : la prédiction est négative alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y a un défaut » et la prédiction est : « il n'y a pas de défaut ».
- **False Positive (Faux positif)** : la prédiction est positive alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il y'a un défaut ».
- **True Negative (Vrai négatif)** : La prédiction et la valeur réelle sont négatives. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il n'y a aucun défaut ».

Cependant, nous allons définir nos métriques pour évaluer les performances du modèle, en se basant sur les notions citées précédemment.

Précision : La précision d'un modèle DL indique l'exactitude de ses prédictions pour la classe cible. Parmi toutes les classes que nous avons prédites comme positives, combien sont réellement positives. Elle se traduit par l'opération suivante :

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Rappel : Le rappel indique si un modèle DL peut localiser chaque objet de la classe cible. Parmi tous les cas positifs, quel pourcentage est prédit positif ? La sensibilité (parfois appelée rappel) mesure la capacité du modèle à prédire les positifs. Cela signifie qu'elle examine les vrais positifs et les faux négatifs (qui sont des positifs qui ont été prédits à tort comme négatifs). Elle se traduit par l'opération suivante :

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

Accuracy: Il n'existe pas de mot français équivalent avec précision à la mesure « Accuracy », elle reste très différente de la précision avec laquelle cette mesure est souvent confondue. L'accuracy mesure à quel point les résultats sont proches de la valeur vraie ou connue. Parmi toutes les classes (positives et négatives), combien d'entre elles avons-nous prédit correctement. Elle est calculée pour la totalité du modèle. Elle se traduit par l'opération suivante :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

3.3.1.5 Résultats

La figure 10 présente les résultats de l'erreur d'entraînement (training loss) et la précision du modèle utilisé (NasNetMobile) après 100 itérations d'entraînement. D'après la courbe, nous voyons que l'erreur de validation initiale est supérieure à 0,7, mais après vingt étapes, l'erreur diminue en dessous de 0,3. D'un autre côté, la précision de validation initiale se situe entre 0,725 et 0,75, mais après 5 itérations, la précision de validation augmente soudainement jusqu'à près de 0,88. Il existe donc une tendance positive vers l'amélioration de la précision de la classification et la réduction d'erreur. Le modèle dans itération 100 converge avec une précision de près de 93 % et une erreur inférieure à 0,2.

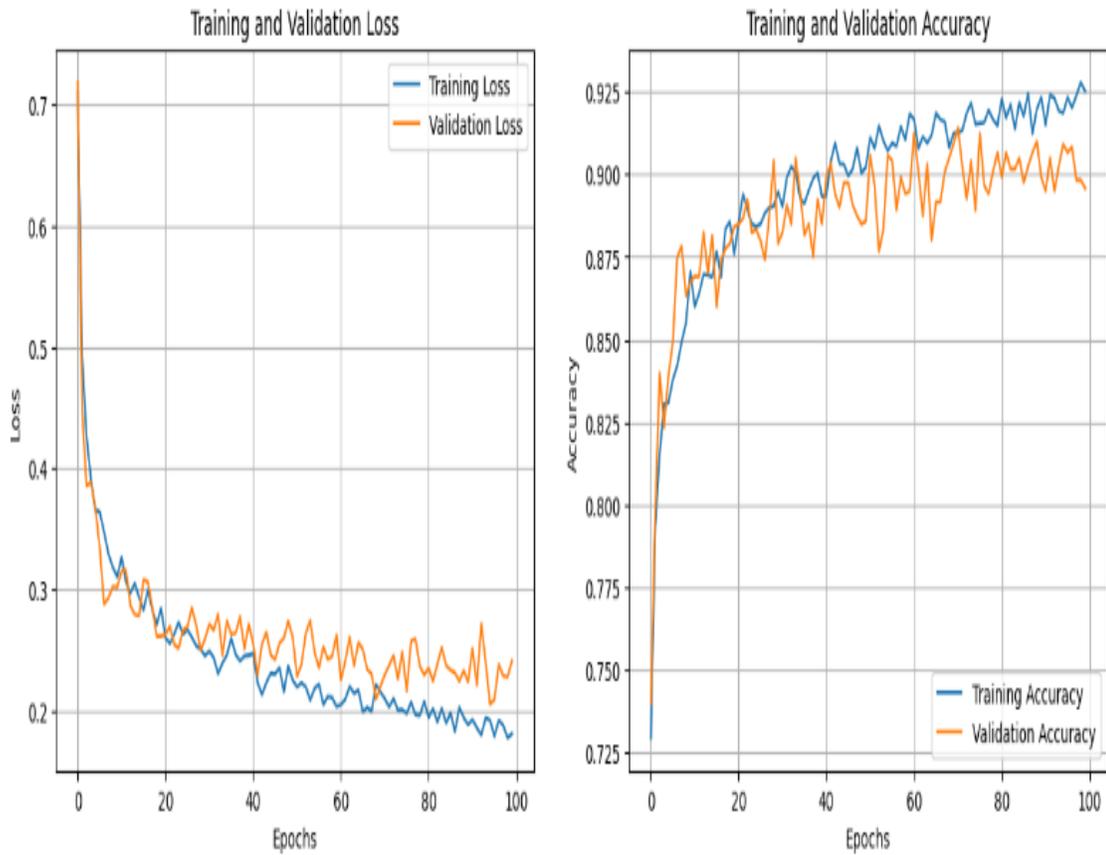


Figure 10 : Courbe de précision et d'erreur pour l'entraînement et la validation

D'après les résultats obtenus présentés sur la figure 11, nous voyons clairement que NasNetMobile donne une bonne précision de classification des défauts avec (93%) et un bon rappel (90%), de plus la sensibilité élevée obtenue de 99% il s'agit de la capacité de notre modèle personnalisé à identifier positivement une éolienne avec une pale endommagée, et une spécificité élevée de 99 % il s'agit de la capacité de notre modèle personnalisé à classer une éolienne sans pale endommagée comme négative.

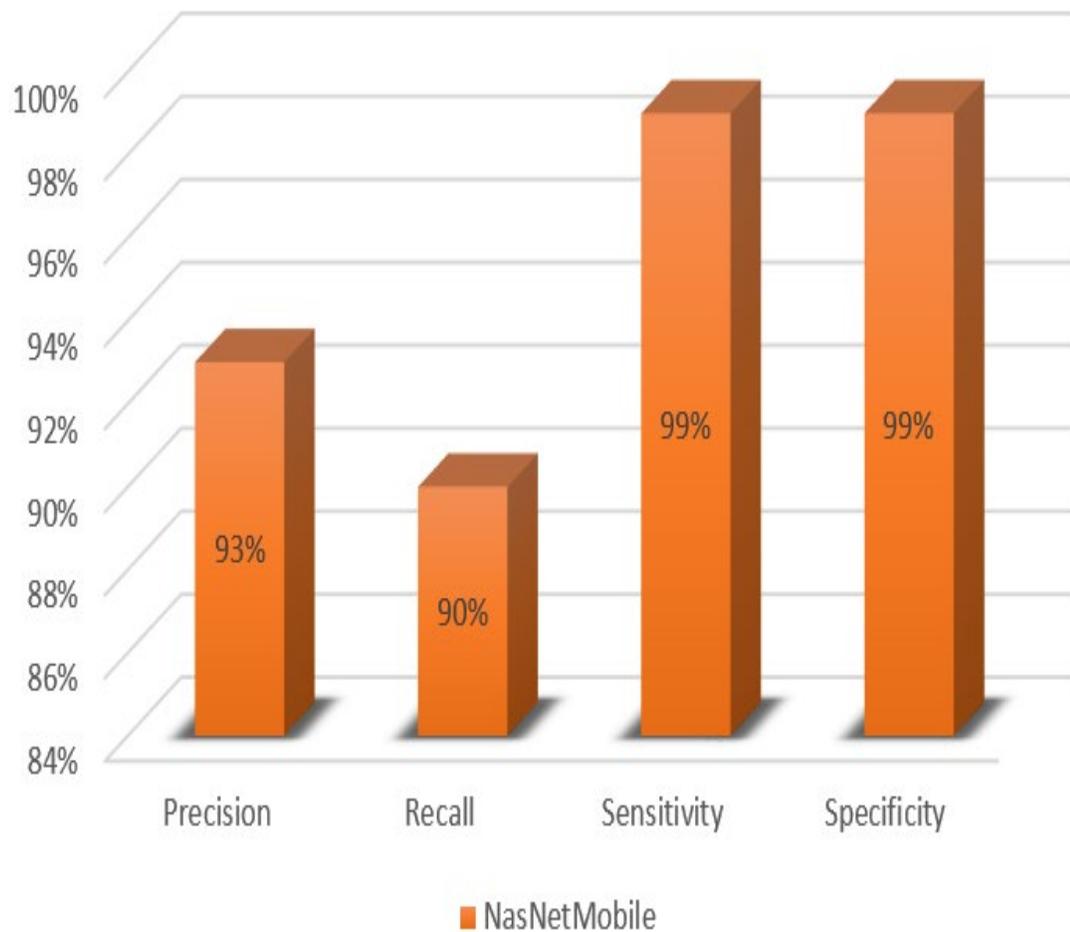


Figure 11 : Résultat de la précision, rappel, sensibilité et spécificité

La figure 12 montre la matrice de confusion calculée pour avec le TP, FP, TN et FN pour l'ensemble des données de test et de validation. A partir de la matrice de confusion, on peut voir que le nombre de FP et FN sont très faibles par rapport au TN et TP, qui indique que les images sont correctement classées.

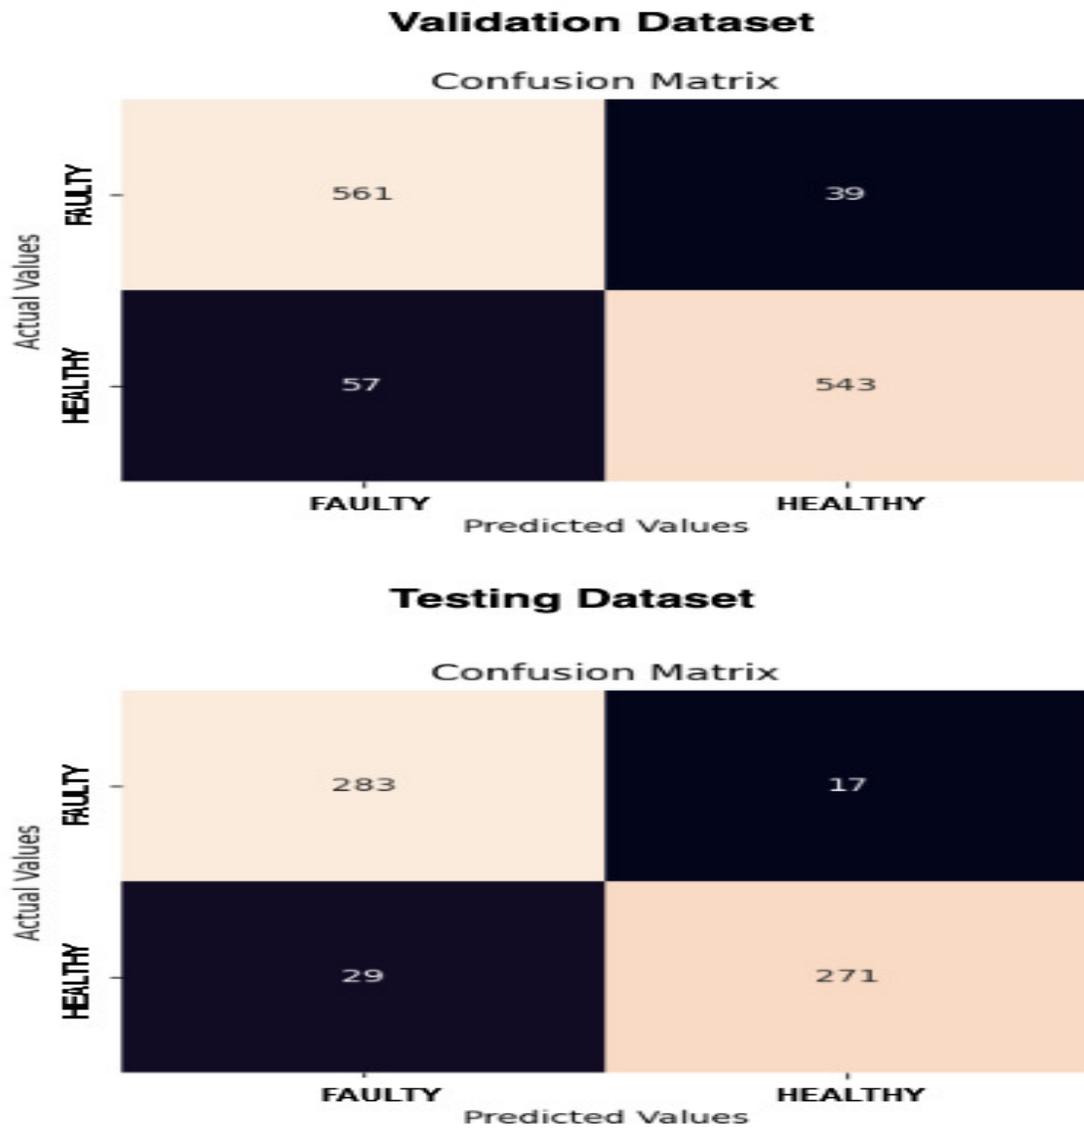


Figure 12 : Matrice de confusion pour la validation et le test

Pour expliquer les résultats de notre modèle formé, nous avons utilisé l'algorithme (Grad-CAM) pour mettre en évidence les régions d'intérêt dans les images comme indiqué dans la figure 13. Ainsi, selon le résultat de Grad-cam, notre modèle

NasNetMobile personnalisé proposé peut détecter efficacement la pale d'éolienne dans l'image et identifier la zone défectueuse dans la pale, ce qui est le but de cette recherche.

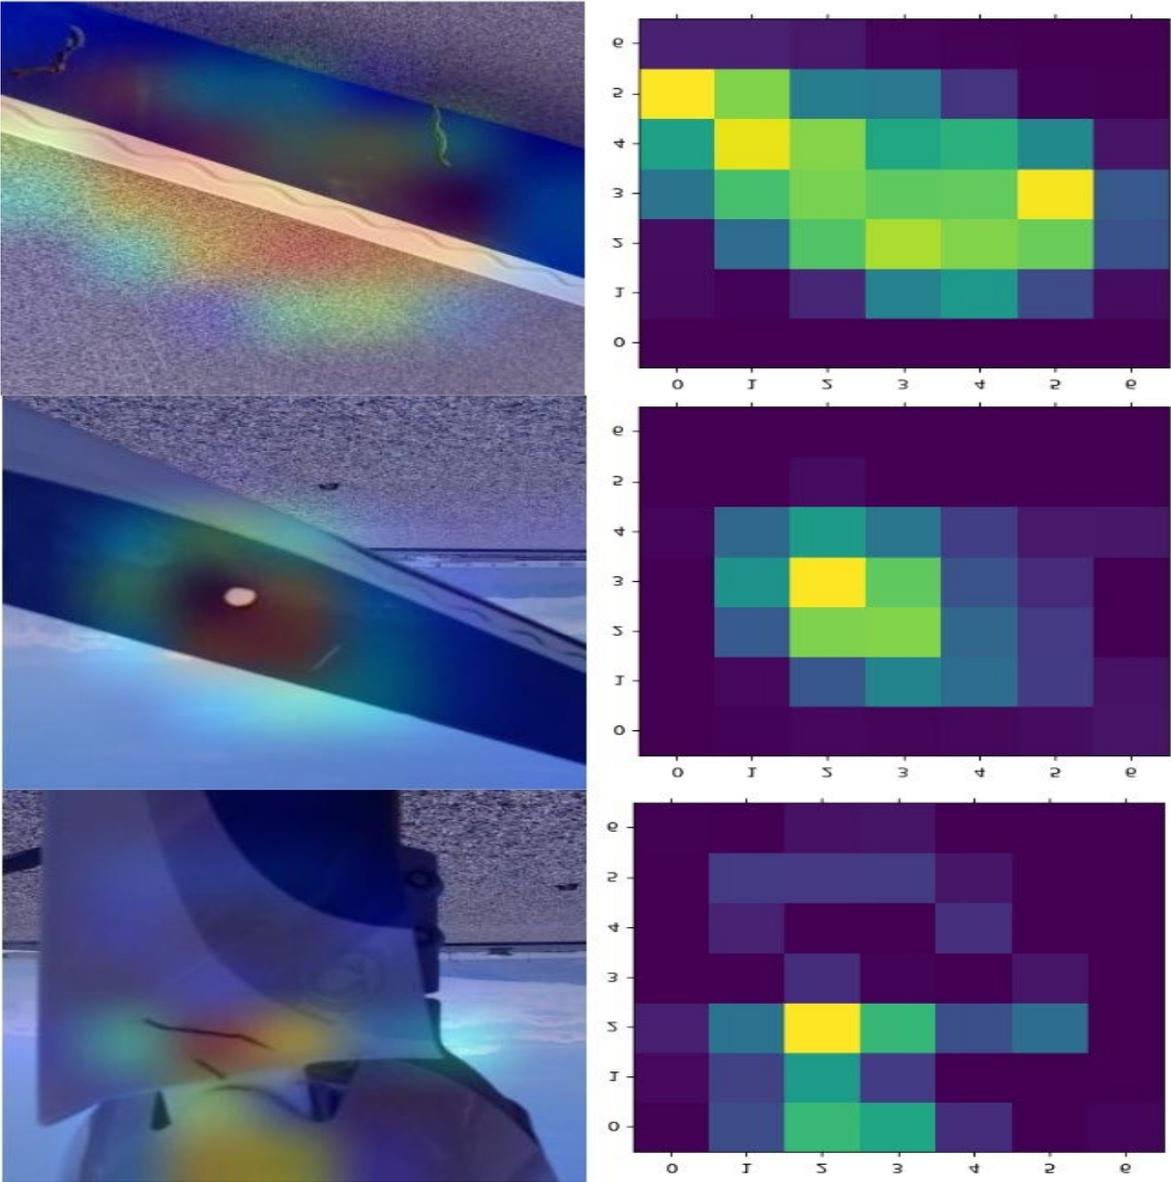


Figure 13 : Visualisation de Grad-cam testé sur des images d'éoliennes défectueuses

Enfin, dans cette première étape, notre travail présente un modèle léger pour la détection et la localisation des défauts dans les pales à l'aide d'images d'éoliennes défectueuses collectées par un drone. Il comprend la capacité de détecter les pales et la zone défectueuse. Cela a été fait en utilisant un modèle léger personnalisé appelé NasNetMobile qui a montré un bon résultat par rapport à d'autres apprentissages profonds basés sur des modèles lourds dans la détection des défauts. D'autre part, Grad-Cam a démontré comment notre modèle personnalisé peut identifier la pale et localiser la région défectueuse.

3.3.2. Entraînement basé sur YOLOV11

Cette étude a été réalisée en utilisant le langage de programmation Python et en utilisant la plateforme Google cloud avec un carte graphique Nvidia. Avec une durée d'entraînement plus de trois heures. Un résultat est présenté dans cette section concernant les différentes mesures d'évaluation qui sont utilisées pour analyser les performances du modèle proposé.

Cette section présente les résultats de YOLOv11 pour la détection et la localisation des défauts dans les éoliennes. Pour le processus d'entraînement, le développement du modèle a été réalisé sur la plateforme en ligne Google, en utilisant le langage python et ses bibliothèques pour le traitement d'images.

3.3.2.1 Base des données

Un ensemble des données sur les dommages à la surface des éoliennes, divisées en images de 586 x 371 pixels avec des annotations au format YOLO. L'ensemble des données se compose de 3000 images contiennent deux classes : la saleté et les défauts (Fissure, Érosion, Peinture).

La figure suivante montre quelques images de la base des données.



Figure 14 : images base des données 2.

3.3.2.2 Le modèle YOLOv11

YOLOv11 introduit plusieurs améliorations par rapport aux versions précédentes. Tout d'abord, il offre une précision accrue grâce à des techniques avancées pour la détection d'objets, notamment ceux de petite taille. De plus, sa vitesse d'inférence a été optimisée, permettant des traitements en temps réel. L'architecture modulaire facilite également la personnalisation en fonction des besoins spécifiques. Rendant l'adaptation à des ensembles de données plus petits plus efficace. Il prend en charge des données multimodales, élargissant ainsi ses applications. Enfin, des techniques sont intégrées pour mieux gérer les biais liés aux classes déséquilibrées.

3.3.2.3 Mesures d'évaluation

Intersection sur Union (IoU) : il s'agit d'une mesure permettant d'évaluer les performances du modèle de détection d'objets en mesurant la précision de la localisation et en calculant les erreurs de localisation. Permet de faire la distinction entre une détection correcte et une détection incorrecte. L'intersection sur l'union repose sur l'indice de Jaccard, qui est un coefficient de similarité entre deux ensembles de données. Pour déterminer où ces deux boîtes englobantes se croisent, il calcule la proportion de chevauchement et d'union entre la boîte englobante candidate créée et la boîte englobante de vérité. L'équation suivante représente l'IoU :

$$\text{IoU} = \frac{\text{Area of Intersection}}{\text{Area of Union}} \quad (4)$$

La précision moyenne moyenne (mAP) : cette métrique a été utilisée pour comparer la précision. La métrique mAP s'appuie sur le seuil d'intersection sur union (IoU) pour la prédiction, également comme métrique nous pouvons utiliser mAP@50 (mAP calculé au seuil IOU de 0,5). La formule mAP est basée sur la précision et le rappel, en utilisant la mesure des vrais positifs (TP), des vrais négatifs (TN), des faux positifs (FP) et des faux négatifs (FN), où TP, TN, FP et FN sont obtenus à partir des équations ci-dessous :

$$Precision = \frac{TP}{TP + FP} , Recall = \frac{TP}{TP + FN} \quad (5)$$

Courbe précision-rappel : l'axe des x de cette courbe correspond au rappel, l'axe des y correspond à la précision, et chaque point de la courbe représente différentes valeurs de seuil.

Score F1 : Le score F1 est une mesure d'évaluation largement utilisée qui fournit une mesure équilibrée de la précision, en prenant en compte à la fois la précision et le rappel. L'équation du score F1 est la suivante :

$$F1\ score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

3.3.2.4 Résultats

La figure suivante montre les mesures de rappel, de précision, de mAP@50 et de mAP@50-95 sur 200 itérations d'entraînement de notre solution proposée.

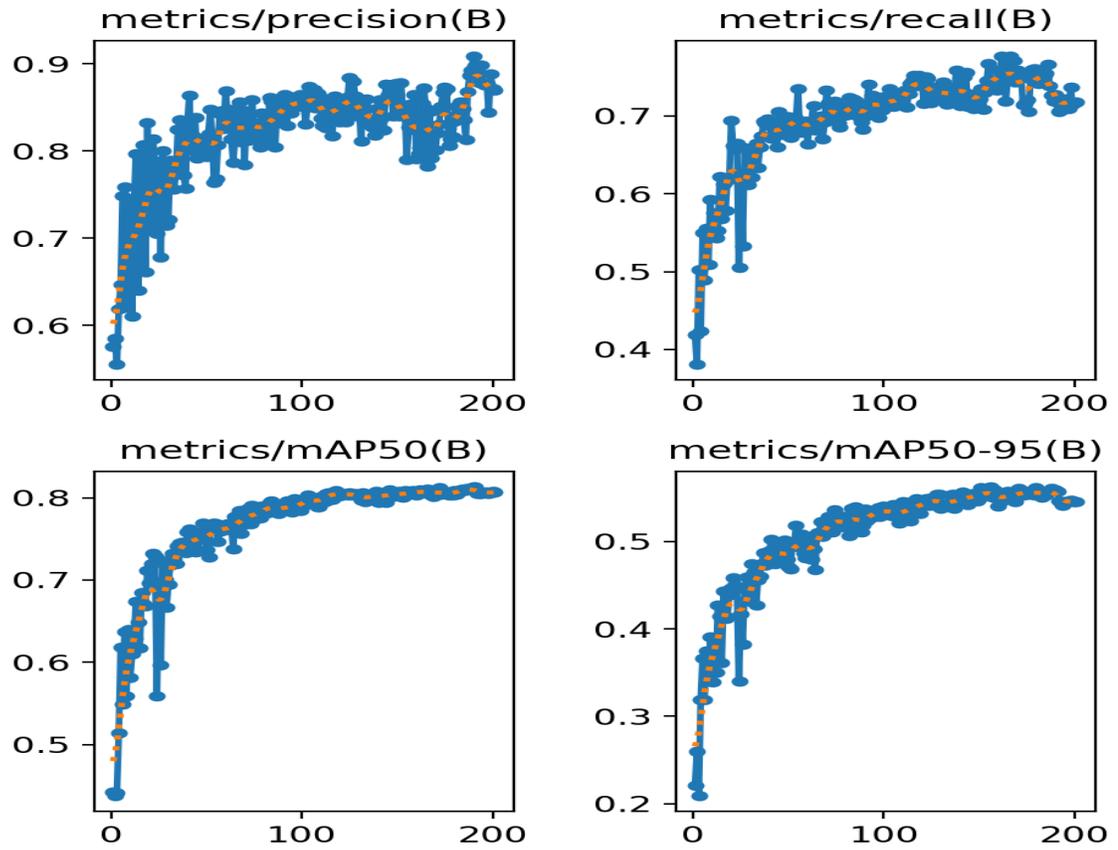
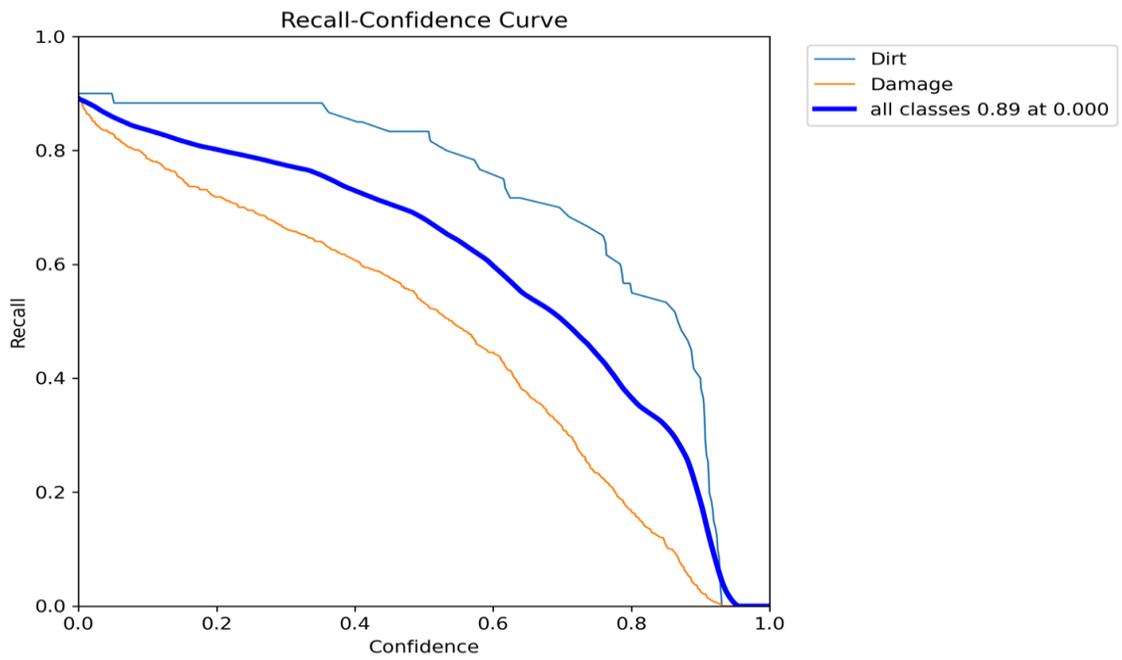
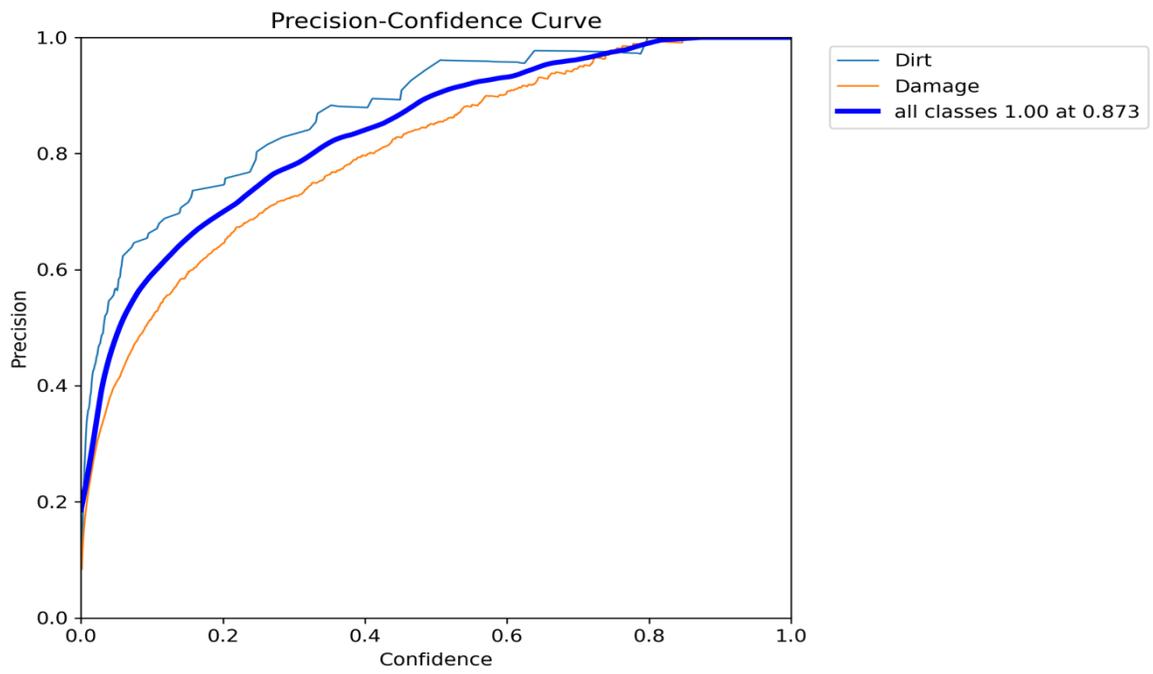


Figure 15 : Courbe précision rappel.

Les figures suivantes qui représentent respectivement la précision, rappel, et précision-rappel, ces figures montrent également que notre modèle présente de meilleures performances dans la détection des défauts. À partir des résultats présentés dans cette étude, nous démontrons que notre modèle a obtenu des bonnes performances.



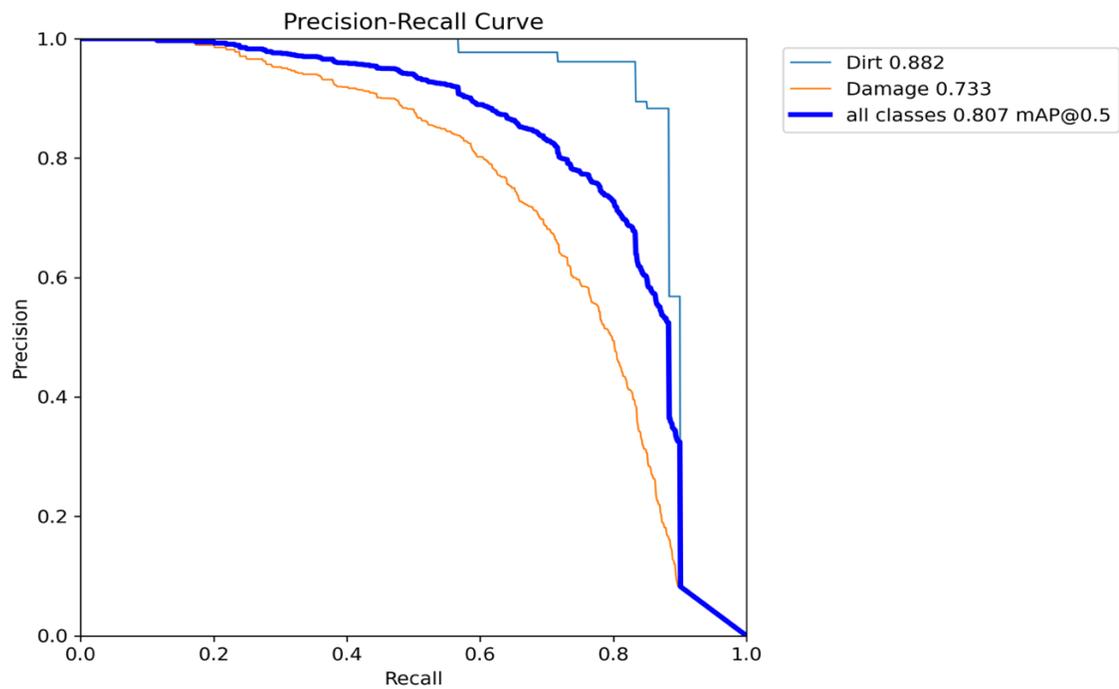


Figure 16 : Illustration des résultats respectivement de, la courbe de précision, de rappel, et Courbe de précision-rappel.

Enfin, les figures 17 et 18 montrent des échantillons prédits pour les ensembles des données utilisés, en utilisant notre modèle entraîné YOLOv11 léger.

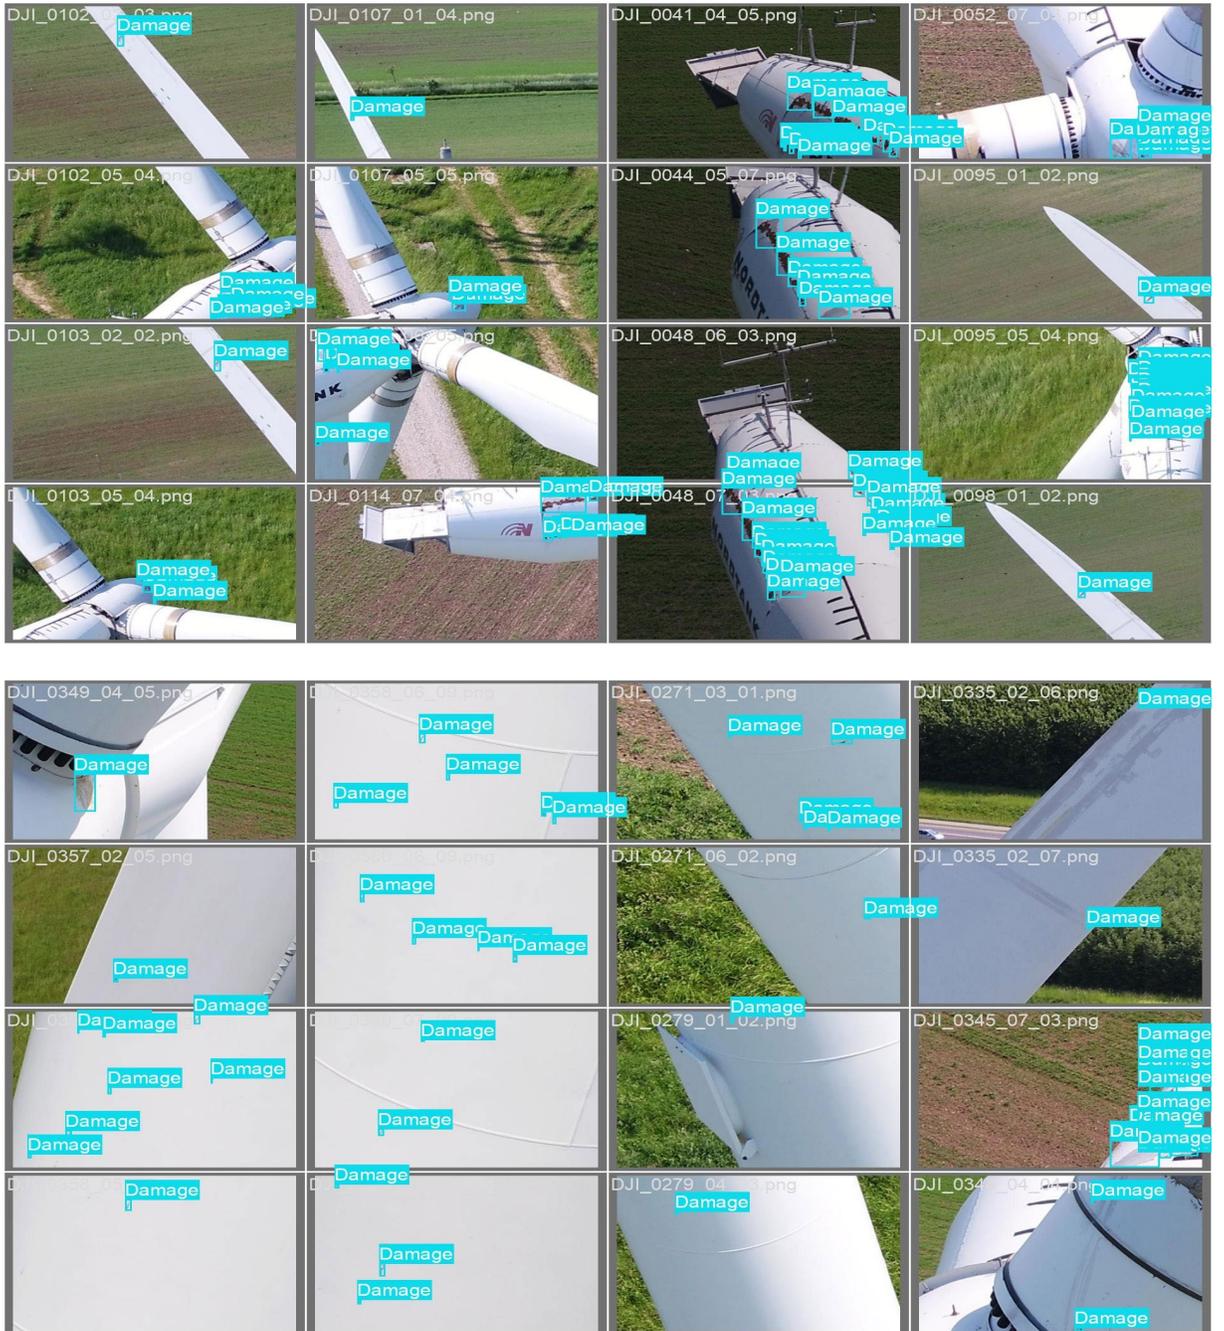


Figure 17 : échantillons 1 prédits avec YOLOv11.

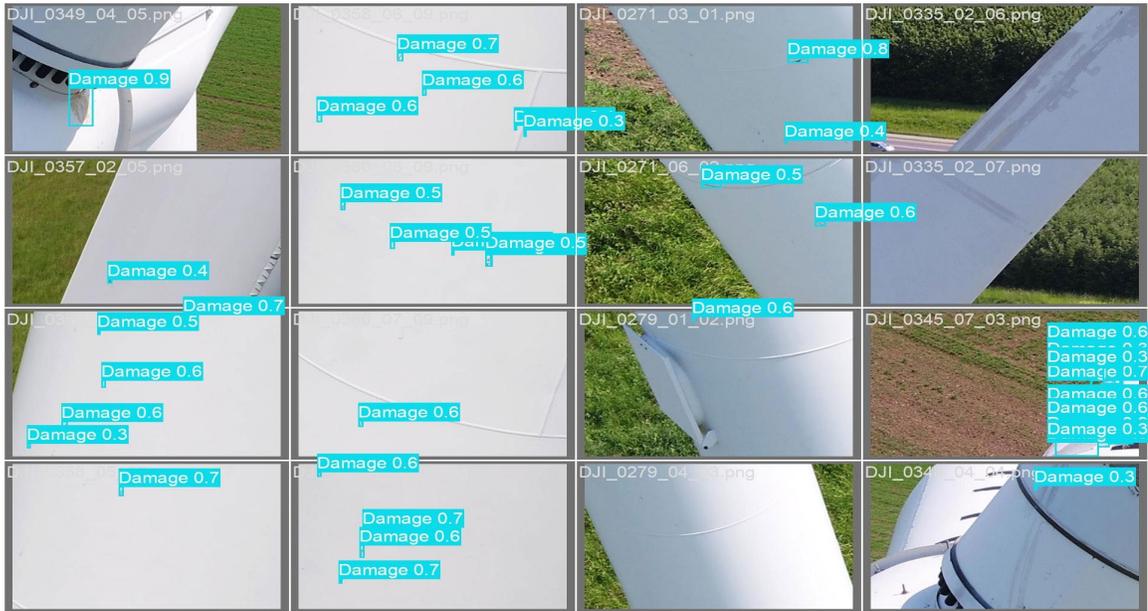


Figure 18 : échantillons 2 prédits avec YOLOv11.

Comme le montre le tableau ci-dessus, en comparant les résultats des études antérieures citées dans la section des travaux connexes, notre modèle YOLOv11 et NasNetMobile avec Grad-cam, ont donné de bons résultats.

Tableau 1 : Comparaison des résultats

Modèle proposé	Précision	Accuracy
Modèle CNN [41]	/	96.67%
AFB-YOLO [42]	83.4%	/
VGG avec SVM [43]	/	97%
Notre modèle NasNetMobile avec Grad-cam	/	94%
Notre modèle YOLOv11	91%	/

3.4. Conclusion

Ce travail a présenté une solution hybride pour la détection et la localisation des défauts sur les éoliennes, qui représente notre contribution au problème d'inspections dans les énergies renouvelables. Jusqu'à présent, et comme perspectives nous pouvons améliorer notre solution et obtenir de bonnes performances, en utilisant des images plus adaptées. Dans ce travail, nous avons utilisé YOLOv11 qui est la dernière version de YOLO comme détecteur d'objets en utilisant des images aériennes comme entrée pour détecter et inspecter. Mais d'autre part, nous avons vous aussi que juste en utilisant un modèle de DL pour classification et la méthode Grad-cam nous avons pu avoir de bons

résultats de classification et localisation des défauts des éoliennes, En conclusion les deux méthodes ont donnés de bons résultats. Ainsi l'utilisation de NasNetMobile et Grad-cam permet de faire une localisation et classification rapide, mais aussi le modèle YOLOv11 permet d'embarquer et utilise la solution dans des drones en temps réel afin d'inspecter les lieux des éoliennes et panneaux solaires.

Chapitre 4

Détection des dommages structurelles et électriques des panneaux solaires basée sur l'apprentissage profond

4.1. Introduction

L'énergie solaire est une excellente option pour produire de l'électricité, car elle est durable et ne produit aucun déchet [48], Les panneaux solaires photovoltaïques sont une source d'énergie renouvelable couramment utilisée pour produire de l'électricité à petite et à grande échelle [49]. Avec les progrès de la technologie photovoltaïque, l'accent est mis de plus en plus sur la conservation afin de réduire les dépenses d'électricité en comptant uniquement sur les rayons du soleil comme combustible. La présence de terre à l'extérieur des panneaux solaires entrave l'absorption de la lumière du soleil, ce qui entraîne une diminution notable de la quantité d'électricité générée par l'installation du panneau solaire [50,51]. La diminution de l'efficacité des panneaux solaires est causée par une réduction de la production, ce qui entraîne une augmentation de la dégradation des modules. L'efficacité de la conversion de la lumière du soleil en électricité est cruciale, ce qui entraîne une demande croissante de progrès dans les systèmes photovoltaïques. D'après [52], la baisse de puissance annuelle causée par l'accumulation de poussière se situe généralement entre 5 % et 30 %. Le contrôle du

taux de dépôt de saleté est un défi sur les sites d'installation de panneaux solaires en raison de sa fréquence et de son imprévisibilité. Le recours à des agents de nettoyage naturels tels que la neige, le vent et la pluie n'est pas fiable et n'est pas aussi efficace. Également, des éléments tels que la terre, la poussière, la neige, les fientes d'oiseaux, les dépôts de ciment de construction, les fissures et l'ombre des plantes ou de l'herbe envahissantes diminuent considérablement l'efficacité et la longévité des panneaux solaires [53]. L'entretien efficace des panneaux solaires est crucial pour optimiser la production d'énergie sur une période de 20 à 25 ans [54]. Généralement, la surveillance de la production d'énergie ne suffit pas à identifier la cause profonde de la diminution de la production d'énergie des panneaux solaires et à mettre en œuvre les actions préventives nécessaires.

En outre, l'impact financier de l'élimination de la saleté des panneaux solaires lors d'une maintenance imprévue est considérable [55]. Il est donc important de contrôler régulièrement l'état de la poussière des panneaux solaires pour garantir une production d'énergie optimale [50].

Les dommages externes sur les panneaux solaires peuvent réduire considérablement leur efficacité et leur durée de vie. Les causes les plus fréquentes : la surtension en anglais (hotspots), qui signifie les zones de température élevée qui affecte une cellule d'un panneau solaire en consommant de l'énergie plutôt qu'en la générant, aussi les problèmes électriques internes, comme les problèmes liés aux connexions, câblages et les courts-circuits, ces problèmes peuvent être observé à l'extérieur souvent sous forme des points chauds. Ces complications peuvent causer une détérioration

supplémentaire ou une défaillance totale du panneau. Pour réduire ces risques, il est essentiel de maintenir un entretien et une surveillance réguliers [56].

La figure 19 montre quelques dommages structurels les plus fréquentes, la cause de ces dommages peut être, des dommages mécaniques au module solaire photovoltaïque (bris de verre, collisions, mauvaise fixation), ainsi qu'une partielle ombrage causée par les arbres ou la végétation.

L'accumulation de saletés et de poussières sur les modules peut entraîner une diminution considérable de l'efficacité car elle perturbe l'absorption, la diffusion et la réflexion de la lumière solaire entrante.

Ces saletés sont constituées de poussières minérales, de particules de champignons et d'autres agents polluants.

Les systèmes photovoltaïques du monde entier sont de plus en plus confrontés à ces problèmes croissants en raison de la réduction de l'intensité de la lumière qui atteint la partie active des cellules solaires.

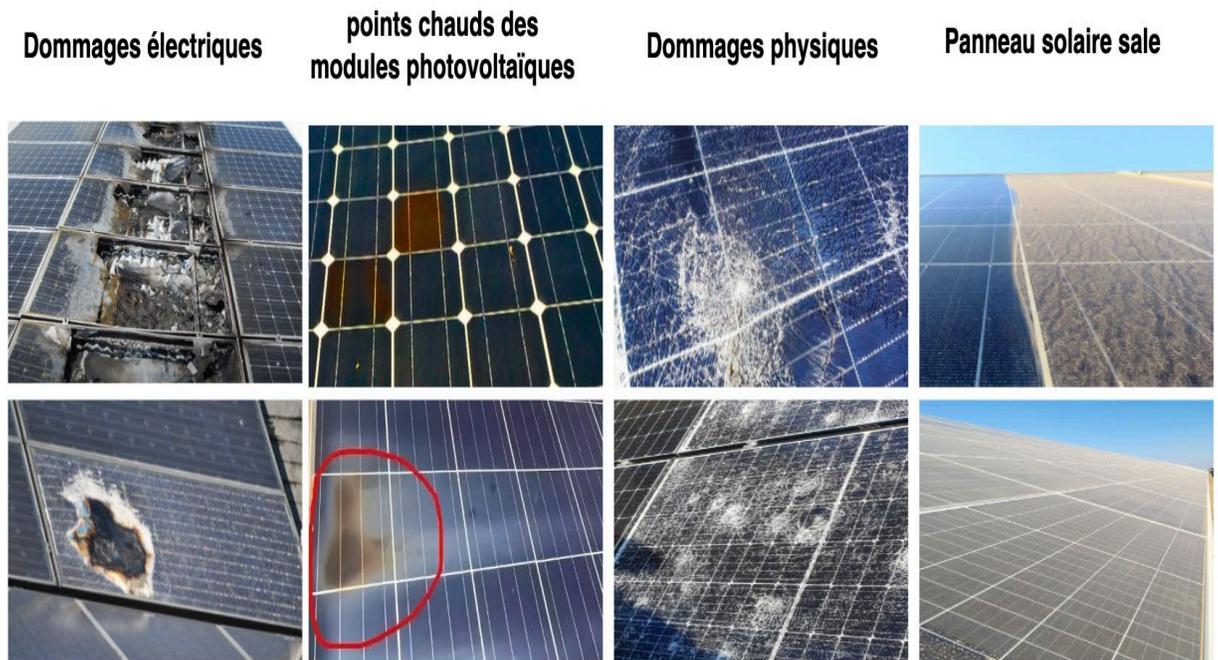


Figure 19 : Défauts structurelles et électriques des panneaux solaires

Dans ce contexte, l'objectif de cette recherche est de proposer un modèle spécialisé et léger, c'est-à-dire spécialisé pour détecter les défauts structurels et électriques sur les panneaux solaires et aussi léger qui ne demande pas beaucoup de calculs en secondes CPU (Unités de calcul) pour le rendre capable d'être embarqué sur un drone, pour ce faire on a utilisé une méthode basée sur le DL. Nous avons utilisé le modèle MobileNetV2 avec la Grad-cam,

4.2. Revue de la littérature

Les méthodes de DL ont montré de grands avantages dans l'analyse d'images complexes et la détection de distinctions nuancées, particulièrement pour garantir la

précision de l'identification des défauts des panneaux solaires dans un environnement changeant. Même si les techniques d'apprentissage profond ont fait de grands progrès dans l'identification de certains défauts, elles présentent encore des lacunes lorsqu'il s'agit de tâches telles que la reconnaissance de défauts multiples, l'adaptation aux changements environnementaux et la détection de petits défauts dans des arrière-plans complexes, comme la détection de défauts dans les déserts et les toits, peut présenter divers défis qui ont un impact sur l'identification des défauts de différentes manières. Les gouttelettes d'eau qui se reflètent dans les zones pluvieuses peuvent tromper l'algorithme de détection des défauts, cachant potentiellement les vrais défauts sur les panneaux photovoltaïques dans les conditions désertiques. Ces facteurs augmentent considérablement le défi de la détection, nécessitant des algorithmes non seulement pour identifier les défauts mais aussi pour combattre les interférences provenant d'arrière-plans complexes. Récemment, L'apprentissage profond, en particulier les réseaux neuronaux convolutifs (CNN), est fréquemment utilisé pour identifier les imperfections des panneaux solaires. Des modèles pré-entraînés tels que VGG-16, VGG-19, Inceptionv3, ResNet50 et Xception ont été utilisés pour identifier les défauts des modules photovoltaïques (PV) [12].

La croissance rapide des centrales photovoltaïques exige une maintenance fiable et un diagnostic des défauts des modules photovoltaïques. Les réseaux neuronaux convolutifs sont couramment utilisés pour la détection automatique des défauts dans les cellules photovoltaïques, mais leurs paramètres importants posent des problèmes de

mise en œuvre pratique. Un nouveau modèle léger pour la détection des défauts dans les cellules photovoltaïques, basé sur la recherche d'architecture neuronale et la distillation des connaissances, est proposé dans ce travail [57] (2024). Le modèle atteint des performances de pointe avec une précision de 91,74 % et 1,85 million de paramètres, ce qui convient à un déploiement industriel.

(ViT), l'un des derniers modèles d'apprentissage profond (DL) basé sur l'attention en vision par ordinateur, est proposé dans ce travail [12] (2024) pour classer les défauts de surface. Le modèle ViT surpassé d'autres modèles d'apprentissage profond, notamment MobileNet, VGG16, Xception, EfficientNetB7 et ResNet50, atteignant des scores de précision élevés supérieurs à 97 % pour les actifs des centrales éoliennes et solaires.

Cet article [58] (2023) présente PV-YOLO, qui remplace le réseau CSPDarknet53 de YOLOX par un réseau basé sur un transformateur PVTv2 afin d'améliorer l'extraction des caractéristiques des détails des bords. Le mécanisme d'attention CBAM améliore les caractéristiques et détecte mieux les petits objets. L'attribution optimisée des étiquettes et la fonction de perte SIOU améliorent la distribution des échantillons et la convergence du réseau. Les expériences montrent des performances supérieures avec un mAP de 92,56 %, soit 10,46 % de plus que YOLOX, en particulier pour les petites cibles. Une conception légère et des modèles de tailles multiples sont proposés pour divers scénarios de détection.

Dans cette étude [59] (2023), les auteurs ont développé un algorithme d'apprentissage automatique qui détecte les irrégularités dans les systèmes d'énergie solaire avec un taux de précision de 90 %. La stratégie utilise les données de performances passées pour identifier les problèmes à un stade précoce, ce qui facilite la maintenance et maximise la production d'énergie. En utilisant l'imagerie thermique embarquée sur un drone, Dans cet article [60] (2023) les chercheurs ont identifié avec succès des problèmes de surchauffe dans les panneaux solaires avec un taux de précision de 95 %. Cette approche améliore l'efficacité de la surveillance dans les fermes solaires extensives, permettant des actions de maintenance en temps opportun. L'article [61] (2023) présente un modèle d'apprentissage profond qui a identifié avec succès des fissures avec une précision de 92 % grâce à l'imagerie thermique. Ce niveau élevé de précision permet de détecter les problèmes de manière précoce, ce qui entraîne une réduction des dépenses de maintenance et une augmentation de la fiabilité des systèmes solaires.

Un algorithme YOLO v5 amélioré est proposé [62] (2022) pour détecter les défauts dans les cellules solaires. Il intègre une convolution déformable, un mécanisme d'attention ECA-Net et une tête de prédiction des défauts minuscules pour améliorer la précision à différentes échelles. L'algorithme utilise également l'amélioration des données, l'algorithme de la boîte d'ancrage et la fonction de perte pour optimiser les performances. Les résultats expérimentaux montrent un mAP de 89,64 %, soit 7,85 % de plus que l'original, avec une vitesse de 36,24 FPS pour la détection en temps réel.

Cette [63] étude (2020) examine l'impact de différents types de poussière sur l'efficacité des panneaux solaires. Les résultats indiquent une diminution notable de la production d'énergie, avec des baisses de performance variant de 15 à 30 % selon le type de poussière. Les auteurs suggèrent des approches de nettoyage individualisées pour réduire ces effets.

Dans cette section, nous avons vu que certaines études ont utilisé des techniques d'apprentissage profond pour l'identification et la localisation des défauts. Dans notre étude, nous proposons d'utiliser MobileNetV2 avec la méthode Grad-cam comme modèle d'apprentissage profond pour la détection et la localisation de six catégories distinctes qui incluent (goutte d'oiseau, propreté, poussière, dommages électriques, dommages physiques et recouvert de neige) L'objectif de cette étude est d'utiliser notre modèle MobileNetV2 modifié comme réseau de neurones convolutif léger pour la détection des défauts sur les panneaux solaires.

4.3. Méthodologie et analyse expérimentale

Dans cette recherche, nous avons utilisé une base des données contenant six catégories des défauts dans les panneaux solaires, saleté de d'oiseau, propreté panneaux sans problème, poussière, dommages électriques, dommages physiques, et panneaux recouverts de neige).

Cette étude a été réalisée en utilisant le langage de programmation Python et en utilisant la plateforme Google cloud avec un carte graphique Nvidia. Pour l'entraînement, 100 epochs sont prises en compte dans l'exécution.

4.4. Base des données

La bases des données utilisées dans cette étude a été télécharger sur le site web kaggle, l'ensemble des images montrant des panneaux solaires avec plusieurs défauts structurelles et électriques. Au total, 877 images avec six classes des défauts. Les images sont réparties en 80 % pour l'entraînement, 10 % pour la validation et les 10 % restants pour le test. La figure 20 ci-dessus présente quelques exemples d'images de notre base des données avec différents défauts.



Figure 20 : images base des données panneaux solaires

4.5. Augmentation des images

Les images de base des données ne sont pas assez grandes pour permettre la généralisation du modèle du DL sur les images. Pour résoudre le problème, nous avons utilisé la technique d'augmentation des données à l'aide de (la bibliothèque python keras ImageDataGenerator), la technique d'augmentation permet d'enrichir la base des données avec plusieurs autres images en créant de nombreuses variantes des images existantes, cela fournit aussi un jeu des données plus important pour l'entraînement et permet à un modèle de rencontrer des caractéristiques plus diverses. En effectuant certaines techniques de traitement d'image telles que le redimensionnement, la rotation, le zoom, le retournement horizontal, le décalage en hauteur, ces techniques ont été appliquées pour générer de nouvelles images pendant l'entraînement.

4.6. Modèle d'apprentissage profond MobileNetV2

MobileNetV2 est un modèle léger d'apprentissage profond conçu pour des applications de vision mobile et embarquée. Il s'appuie sur l'architecture de son prédécesseur, MobileNetV1, en introduisant des améliorations telles que les résidus inversés. Ces changements améliorent l'efficacité et la performance tout en minimisant la taille et les exigences computationnelles du modèle.

Les avantages de MobileNetV2 comprennent :

- Conception légère : Réduit l'utilisation de la mémoire et la puissance de traitement, ce qui le rend adapté aux appareils mobiles.
- Vitesse : Temps d'inférence plus rapide par rapport aux modèles plus lourds, facilitant les applications en temps réel.
- Flexibilité : Prend en charge des niveaux de complexité variables grâce à des multiplicateurs de largeur et de résolution ajustables.

Comparé à des modèles existants comme VGG ou ResNet, MobileNetV2 atteint une précision compétitive avec significativement moins de paramètres, ce qui en fait un excellent choix pour des environnements à ressources limitées. Son accent sur l'efficacité et la performance le rend particulièrement avantageux pour des tâches telles que la classification d'images et la détection d'objets sur des appareils mobiles (drone).

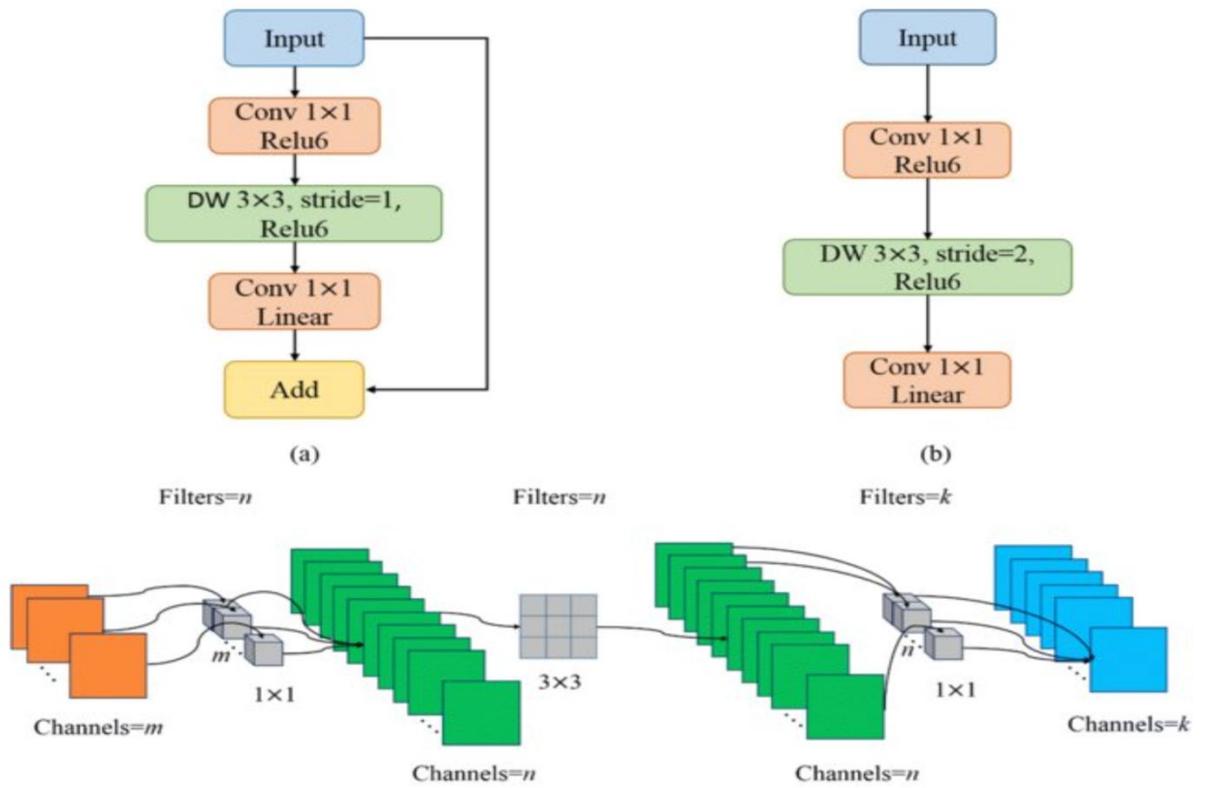


Figure 21 : architecture du modèle MobileNetV2.

La Figure suivante montre notre solution proposée de détection des défauts des panneaux solaires avec le modèle léger MobileNetV2.

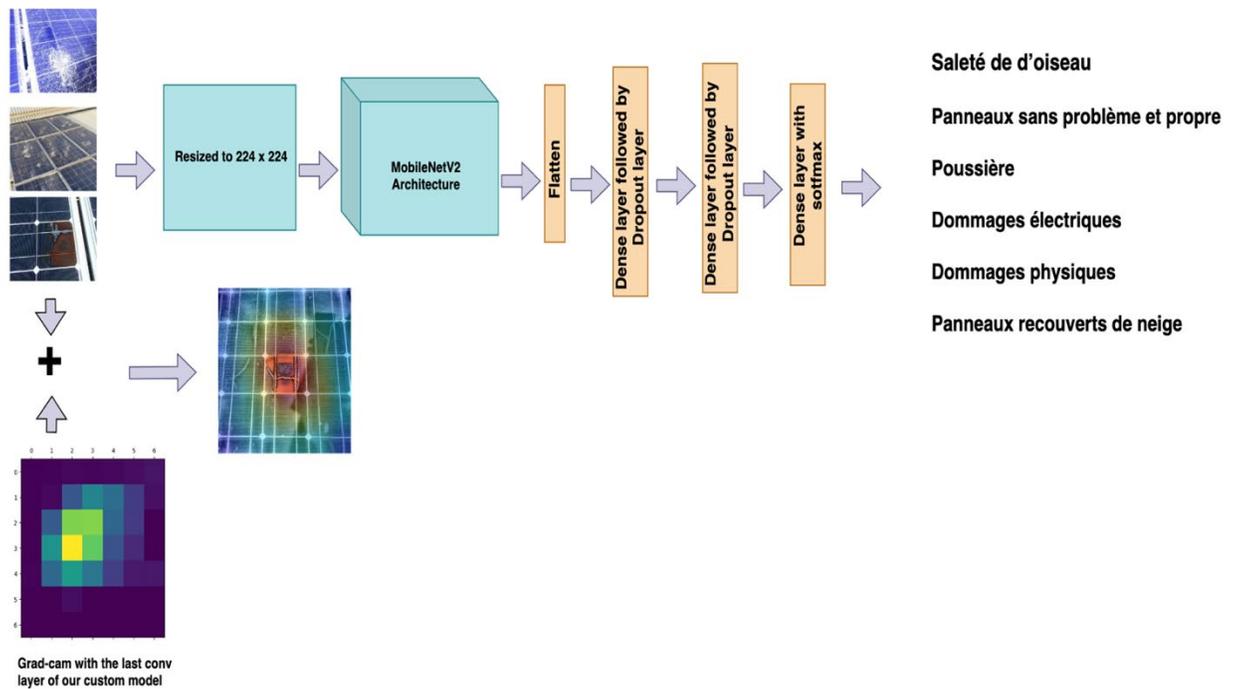


Figure 22 : méthode propose pour détection des défauts sur les panneaux solaires

4.7. Réglage des hyperparamètres

Pour améliorer et réduire le temps de calcul dans l'étape d'entraînement, les images des panneaux solaires sont redimensionnées à 224×224 pixels, qui seront utilisées ensuite comme entrées pour notre modèle MobileNetV2 considérés, car les images sont de tailles différentes. D'autres hyperparamètres sont ajustés pour obtenir de meilleures performances dans l'entraînement du modèle, notamment le taux d'apprentissage = 0,001, l'optimiseur = Adam, et l'utilisation d'une fonction de rappel pour réduire le taux d'apprentissage si l'erreur de validation ne diminue pas.

4.8. Méthodes pour l'évaluation du modèle

L'évaluation du modèle est une étape nécessaire pour la réalisation du projet. Cela nous aide à évaluer si le modèle sélectionné contribuera à prédire correctement la cible dans le contexte de nouvelles données. Nous allons débiter par définir quelques notions avant de passer à la définition des métriques.

- **Matrice de confusion (Confusion Matrix)** : Dans les problèmes de classification, il est nécessaire de comparer les résultats prédits avec la réalité pour évaluer leur degré de performance. La matrice de confusion permet de mettre en évidence les prédictions correctes et incorrectes, tout en indiquant le type d'erreurs commises.

		True Class	
		Positive	Negative
Predicated Class	Positive	TP	FP
	Negative	FN	TN

Figure 23 : Matrice de confusion.

- **True Positive (Vrai positif):** Ce sont les prédictions qui forment un match avec la valeur réelle. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y'a un défaut » et la prédiction est : « il y'a un défaut ».
- **False Negative (Faux négatif) :** la prédiction est négative alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y a un défaut » et la prédiction est : « il n'y a pas de défaut ».
- **False Positive (Faux positif) :** la prédiction est positive alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il y'a un défaut ».
- **True Negative (Vrai négatif) :** La prédiction et la valeur réelle sont négatives. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il n'y a aucun défaut ».

Cependant, nous allons définir nos métriques pour évaluer les performances du modèle, en se basant sur les notions citées précédemment.

Précision : La précision d'un modèle DL indique l'exactitude de ses prédictions pour la classe cible. Parmi toutes les classes que nous avons prédites comme positives, combien sont réellement positives. Elle se traduit par l'opération suivante :

$$\text{Precision} = \frac{TP}{TP+FP} \quad (7)$$

Rappel : Le rappel indique si un modèle DL peut localiser chaque objet de la classe cible. Parmi tous les cas positifs, quel pourcentage est prédit positif ? La sensibilité (parfois appelée rappel) mesure la capacité du modèle à prédire les positifs. Cela signifie qu'elle examine les vrais positifs et les faux négatifs (qui sont des positifs qui ont été prédits à tort comme négatifs). Elle se traduit par l'opération suivante :

$$\text{Recall} = \frac{TP}{TP+FN} \quad (8)$$

Accuracy: Il n'existe pas de mot français équivalent avec précision à la mesure « Accuracy », elle reste très différente de la précision avec laquelle cette mesure est souvent confondue. L'accuracy mesure à quel point les résultats sont proches de la valeur vraie ou connue. Parmi toutes les classes (positives et négatives), combien d'entre elles avons-nous prédit correctement. Elle est calculée pour la totalité du modèle. Elle se traduit par l'opération suivante :

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

4.9. Résultats

La figure 24 présente les résultats de l'erreur d'entraînement (training loss) et la précision (accuracy) du modèle utilisé (MobileNetV2) après 100 itérations

d'entraînement. D'après la courbe, nous voyons que l'erreur de validation initiale est supérieure à 0,6, mais après vingt étapes, l'erreur diminue en dessous de 0,1. D'un autre côté, la précision de validation initiale se situe à 0,4, mais après 40 étapes, la précision de validation augmente soudainement jusqu'à près de 0,89. Il existe donc une tendance positive vers l'amélioration de la précision de la classification et la réduction d'erreur. Le modèle dans l'itération 100 converge avec une précision de près de 96 % et une erreur inférieure à 0,05.

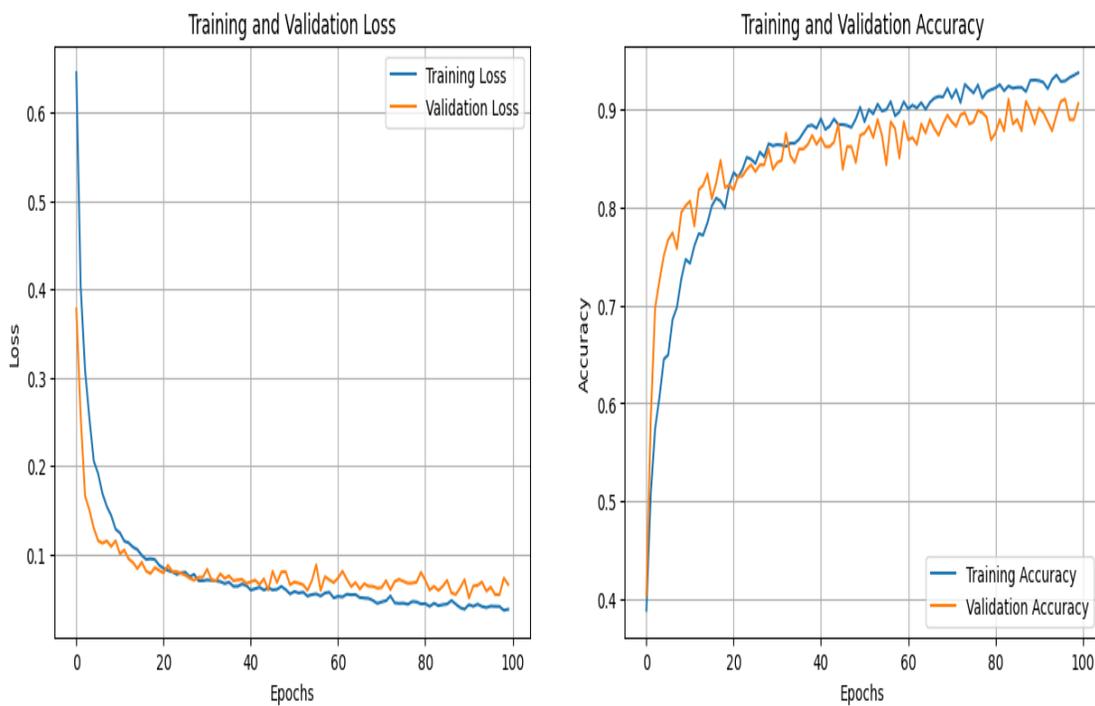


Figure 24 : MobileNetV2 Courbe de précision et d'erreur pour l'entraînement et la validation

La figure 25 montre la matrice de confusion calculée pour avec le TP, FP, TN et FN pour l'ensemble des données de test. A partir de la matrice de confusion, on peut voir que le nombre de FP et FN par rapport au TN et TP, qui indique que l'erreur est presque négligeable, et les images sont correctement classées.

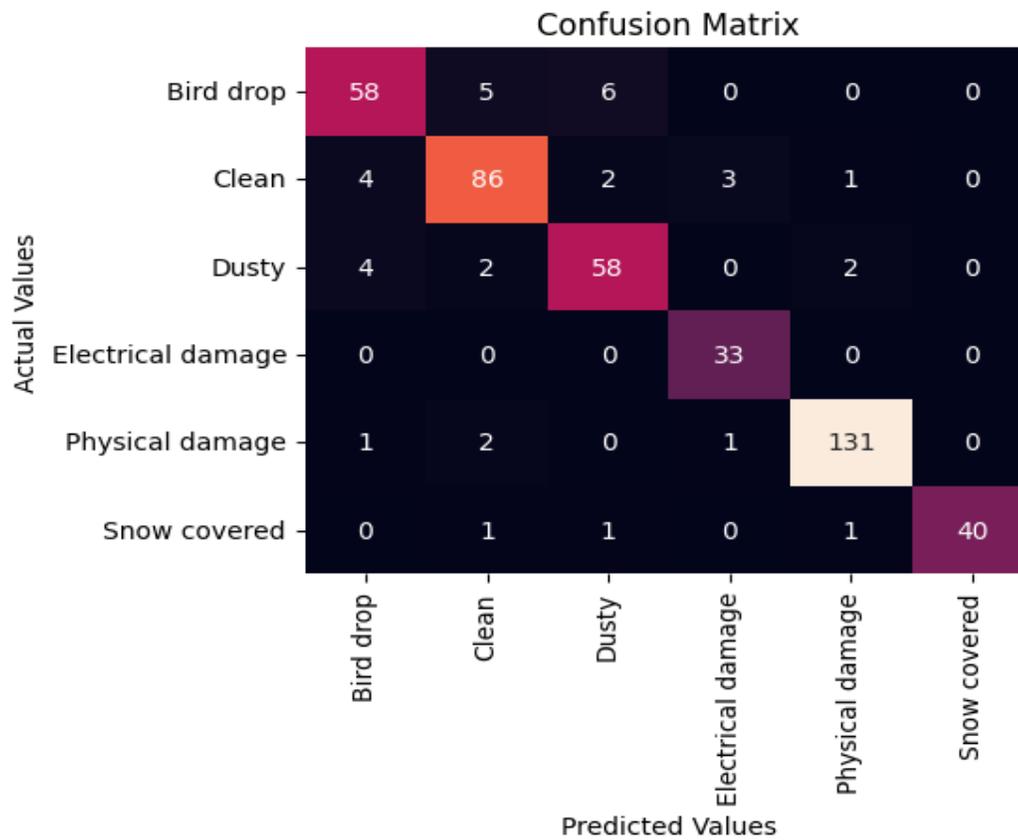


Figure 25 : matrice de confusion pour panneaux solaires

Pour expliquer les résultats de notre modèle formé, nous avons utilisé l'algorithme (Grad-CAM) pour mettre en évidence les régions d'intérêt dans les images comme

indiqué dans la figure 26. Ainsi, selon le résultat de Grad-cam, notre modèle MobileNetV2 personnalisé proposé peut détecter efficacement les panneaux solaires dans l'image et également identifier la zone défectueuse des panneaux solaires, ce qui est le but de cette étude.

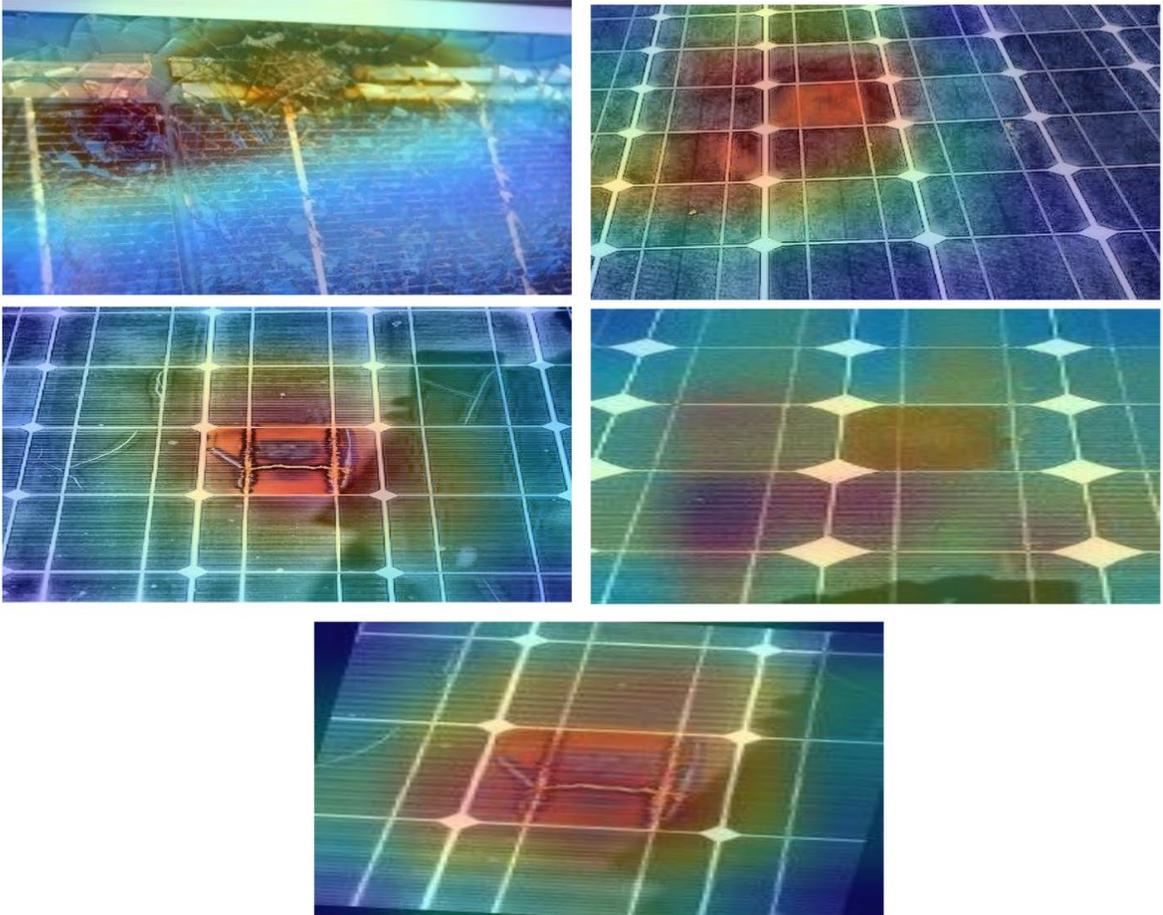


Figure 26 : résultats de Grad-cam sur les défauts des panneaux solaires

Comme le montre le tableau ci-dessus, en comparant les résultats des études antérieures citées dans la section des travaux connexes, notre modèle MobileNetV2 avec Grad-cam, propose de bons résultats.

Tableau 2 : Comparaison entre les modèles

Modèle propose	Accuracy
ViT [12]	98.6%
MobileNet [12]	88.3%
ResNet50 [12]	96.6
Notre modèle MobileNetV2 avec Grad-cam	96%

4.10. Conclusion

Enfin, ce travail présente un modèle léger pour la détection et la localisation des défauts sur les panneaux solaires défectueuses collectées. Cela a été fait en utilisant un modèle léger personnalisé appelé MobileNetV2 qui a montré un bon résultat par rapport à d'autres apprentissages profonds basés sur des poids lourds dans la détection des défauts. D'autre part, Grad-Cam a démontré comment notre modèle personnalisé peut identifier et localiser la région défectueuse sur les panneaux solaires.

Chapitre 5

Détection des défauts des carte à circuits imprimés (PCB) en temps réel

5.1. Introduction

Les cartes à circuits imprimés (PCB) sont les principaux composants de tous les appareils électroniques, notamment les ordinateurs, les machines industrielles, les véhicules, les smartphones et, surtout, les équipements médicaux. Le nombre d'appareils électroniques fabriqués chaque année montre l'importance et la grande quantité des PCB utilisés et fabriqués, notamment avec l'émergence de l'internet des objets (IoT) et de la communication à distance. Par conséquent, à mesure que la demande des produits électroniques augmente, la production précise de PCB devient de plus en plus cruciale.

Le rôle des PCB est de réaliser la connexion interne entre les composants électroniques par le biais de la conductivité électrique. Cependant, tout dommage ou défaut dans ces cartes peut provoquer des interruptions ou l'arrêt du fonctionnement de l'appareil. En outre, la défaillance des cartes à circuits imprimés peut entraîner des problèmes majeurs. Un circuit imprimé défectueux peut provoquer un incendie, mettant en péril la sécurité des personnes et des équipements. Par conséquent, les tests effectués avant

la production peuvent également prévenir les dommages causés aux machines et aux travailleurs par des défauts de conception [64].

En fonction de la technique de détection, l'inspection des défauts des circuits imprimés peut être classée en deux catégories : les méthodes avec ou sans contact. La méthode avec contact évalue la conductivité électrique du circuit, mais elle ne permet pas de détecter des défauts importants dans son aspect extérieur. L'approche sans contact peut faire appel à des méthodes optiques telles que l'inspection par rayons X, l'imagerie par ultrasons et l'imagerie thermique. [65]-[67]. Ces techniques offrent un taux de détection et une précision excellente, mais nécessitent un équipement coûteux et du temps, et peuvent potentiellement endommager le circuit imprimé.

L'inspection manuelle est la principale méthode utilisée dans l'inspection traditionnelle des circuits imprimés, où il est essentiel de détecter avec précision les défauts tels que les courts-circuits, les circuits ouverts, les épérons, le cuivre parasite, les morsures de souris (Petits défauts de cuivre) et les trous manquants. Néanmoins, le processus d'inspection manuelle présente des inconvénients, notamment le fait qu'il prend beaucoup de temps, qu'il est source de fatigue et qu'il peut donner lieu à des erreurs, les résultats de l'inspection variant en fonction de l'inspecteur [68]. Récemment, les techniques d'apprentissage profond ont été de plus en plus répandues dans le domaine des images, les algorithmes d'apprentissage profond se révélant plus précis et plus rapides que les méthodes traditionnelles d'apprentissage automatique [69]. À mesure

que la puissance de calcul et les technologies d'intelligence artificielle continuent d'évoluer, la vision artificielle est de plus en plus appréciée en tant qu'outil crucial pour l'identification des défauts dans l'industrie [70]. La vision artificielle basée sur l'apprentissage profond, telle que la détection d'objets, a été largement appliquée en raison de sa forte généralisation, de son apprentissage robuste, de l'extraction automatique de caractéristiques et de sa capacité à gérer l'occlusion, les changements d'échelle et les variations d'arrière-plan [72]-[74].

La méthode de détection des défauts des circuits imprimés par vision industrielle proposée pour l'inspection et le contrôle de la qualité est sans contact et ne nécessite pas d'intervention manuelle. Il suffit de sélectionner une caméra et une source lumineuse appropriées pour capturer des images de la surface du circuit imprimé, puis d'utiliser le détecteur des défauts pour identifier et classer les défauts éventuels. La grande efficacité de détection de cette méthode peut apporter des avantages significatifs à l'industrie manufacturière.

Le diagramme ci-dessus de la figure 27 illustre le cadre proposé utilisant la vision par ordinateur via la détection d'objets. Ce cadre peut aider les entreprises de fabrication électronique à prendre des décisions et à vérifier la qualité du produit.

En conséquence, nous proposons dans l'étude de ce chapitre une détection en temps réel des anomalies des circuits imprimés. Cette étude se concentre principalement sur l'amélioration des performances du modèle de détection d'objets en temps réel capable

d'identifier et de localiser avec précision les défauts dans les circuits imprimés en situation réelle à l'aide d'un ensemble des données contenant six catégories de défauts de circuits imprimés. L'expérience acquise dans le cadre de ce travail montre une amélioration dans la détection d'objets en temps réel pour les PCB. Le modèle proposé peut aider les entreprises de fabrication électronique à prendre des décisions et à vérifier la qualité du produit.

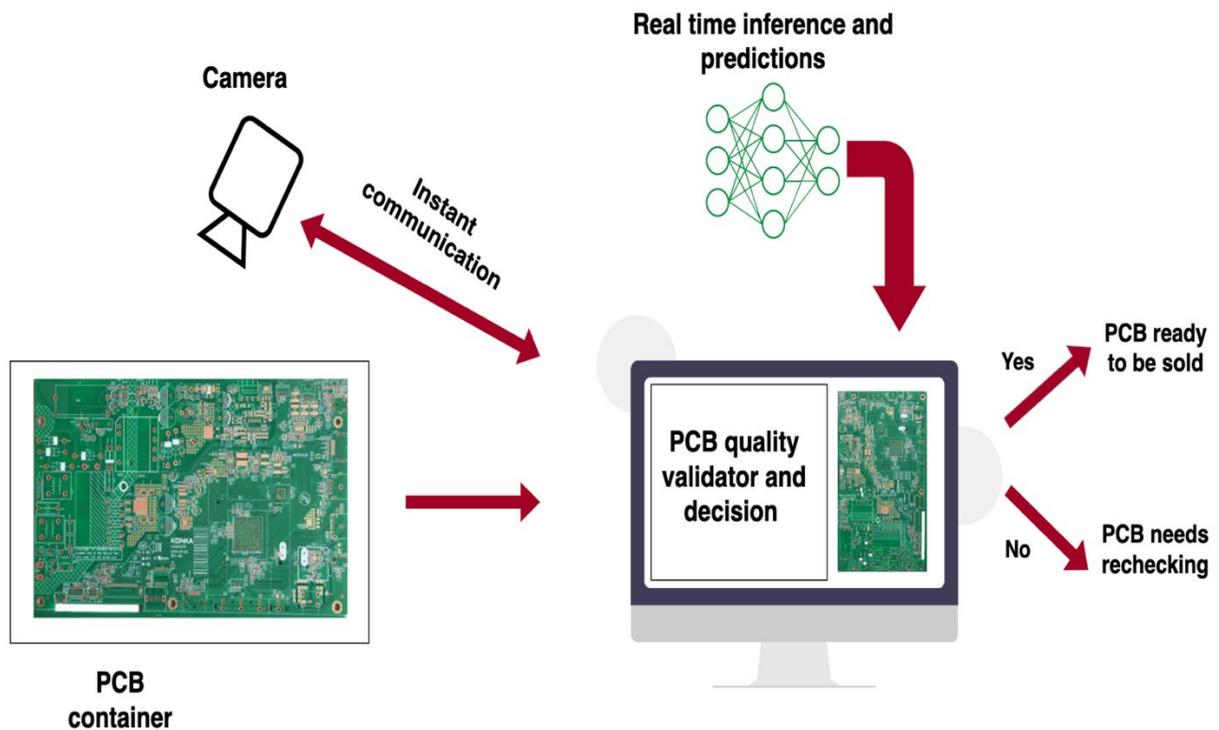


Figure 27 : méthode proposée pour PCB

5.2. Revue de la littérature

Le contrôle de la qualité de la production est indispensable pour garantir le bon fonctionnement des produits électroniques. Dans le cadre de l'inspection traditionnelle des circuits imprimés, les défauts de surface sont principalement détectés par une inspection visuelle manuelle. Toutefois, cette approche est difficile à mettre en œuvre et ne donne pas de bons résultats, car les circuits imprimés présentent de nombreux petits défauts qui ne sont pas toujours facilement visibles et qui exigent une attention particulière de la part de l'inspecteur humain.

Ces dernières années, la vision industrielle est devenue de plus en plus populaire pour la détection des défauts de surface, en particulier dans des tâches telles que le contrôle de la qualité et l'inspection des circuits imprimés. Il s'agit d'identifier les anomalies et les défauts des circuits imprimés, en particulier au cours de leur processus de production. Dans cette section, nous nous efforçons de présenter un résumé concis de la recherche sur la détection des défauts de surface des PCB.

Le domaine de la recherche a montré un intérêt croissant pour la vision artificielle basée sur l'apprentissage profond, en particulier pour la détection d'objets, en raison de sa forte capacité d'apprentissage et de ses avantages dans la gestion de l'occlusion, des changements d'échelle et des variations de l'arrière-plan [72]-[80]. Yuan et al [81] (2024). Ils ont proposé un nouveau réseau basé sur YOLOv5 amélioré, appelé YOLOHorNetMCBAM-CARAFE (YOLO-HMC), pour identifier les défauts des circuits imprimés de petite taille. Dans un premier temps, la section backbone utilise

HorNet pour extraire les caractéristiques. En outre, un module d'attention à blocs convolutifs multiples (MCBAM) est utilisé pour améliorer la capacité du modèle à détecter les défauts. L'expérience de YOLO-HMC sur la détection des défauts des circuits imprimés a montré que le modèle atteignait une précision moyenne (mAP) de 98,6 %.

Un autre travail basé sur la détection d'objets [69] (2024). Les auteurs ont proposé un réseau appelé (CDI-YOLO) pour la détection des défauts des circuits imprimés basé sur YOLOv7-tiny, en introduisant le mécanisme d'attention coordonnée (CA) pour améliorer le réseau backbone et le réseau de neck (cou) de YOLOv7-tiny. Pour minimiser les coûts de calcul et accélérer le processus de la boîte englobante (IoU), ils ont utilisé respectivement DSConv [12] et Inner-CIoU [77]. Les résultats ont montré que le détecteur des défauts des circuits imprimés proposé atteignait un mAP de 98,3 %.

Dans cette étude [78] (2024). Les auteurs présentent une version améliorée du modèle YOLO, connue sous le nom de YOLO-Biformer, afin d'améliorer les performances du réseau dans l'identification des défauts de surface sur les PCB. Initialement, YOLO-Biformer comprend un module d'attention mixte pour distinguer l'importance des différents canaux, améliorant ainsi l'identification des caractéristiques des petits défauts. En outre, le modèle incorpore une pyramide convolutive sophistiquée à espace creux pour retenir un maximum de détails de l'image et d'informations interconnectées. Enfin, la capacité du réseau à différencier les défauts présentant des caractéristiques

similaires est améliorée par l'utilisation de la fonction de perte Enhanced Intersection Over Union-FocalLoss. Les résultats de cette étude ont montré que le modèle proposé augmente la précision moyenne de 4,1 %, ce qui permet d'atteindre un taux de 98,9 % mAP@0.5.

Cette recherche [79] (2024). Elle présente un modèle de détection des petits défauts appelé TDD-YOLO et suggère une approche de formation par compression pour former sur des images à faible résolution et tester sur des images à haute résolution. TDD-YOLO utilise la méthode W-IoU (wise intersection over union) pour réévaluer la perte de régression des boîtes d'ancrage et améliorer l'adaptation du modèle aux boîtes d'ancrage, réduisant ainsi les faux négatifs. Enfin, la stratégie d'apprentissage par compression utilise différents taux de compression d'images pour réduire la complexité des calculs et améliorer la précision. L'étude a atteint un mAP@50 de 97,8 %.

L'article [80] publié en 2024 présente LW-YOLO, un modèle dérivé de YOLOv8 et conçu pour être léger. Le modèle LW-YOLO a atteint une précision moyenne (mAP) de 96,4 % à un seuil d'intersection sur l'union (IoU) de 0,5 %, surpassant YOLOv8 de 2,2 points de pourcentage.

Pour répondre aux exigences de la fabrication de cartes électroniques, en termes de réduction du délai de détection. L'utilisation de la détection d'objets est donc la méthode la plus efficace pour résoudre ce problème. Il est essentiel de disposer d'un modèle capable de traiter rapidement les images en temps réel et de détecter les anomalies lorsque l'on traite des images en continu. YOLO est l'un des modèles de CNN en temps réel les plus efficaces à cet égard. Il s'agit d'un détecteur d'objets en une seule étape qui

effectue simultanément la prédiction de la boîte englobante et la classification des objets. Pour explorer et suggérer des performances améliorées en matière de reconnaissance en temps réel des défauts de surface des circuits imprimés, nous avons utilisé YOLOv8, la huitième version de la série YOLO. Ainsi, dans ce travail, nous avons utilisé un ensemble des données de 6 catégories étiquetées représentant les anomalies de surface des PCB. En outre, nous avons adapté la petite version de YOLOv8 (Yolov8n) en tant que détecteur, qui est comparé à différentes méthodes citées dans ce chapitre (en termes de précision de reconnaissance d'objet). Par conséquent, dans cette étude, nous avons utilisé un ensemble des données contenant 6 anomalies catégorisées sur les surfaces de PCB. En outre, nous avons utilisé la plus petite variation de YOLOv8 (Yolov8n) comme détecteur et nous avons comparé le modèle à différentes méthodes mentionnées dans ce chapitre en termes de précision de reconnaissance d'objet.

5.3. Modèle propose de détection des défauts de PCB

Le diagramme de la figure suivante illustre les étapes de l'étude proposée. Dans un premier temps, les images originales sont prétraitées à l'aide de la technique d'augmentation des données, qui consiste à générer divers nouveaux échantillons des données afin d'offrir au modèle proposé un large éventail de nouveaux échantillons. Cet ensemble des données est divisé en partitions pour l'entraînement, la validation et le test. Ensuite, les images des PCB défectueuses sont utilisées pour entraîner notre modèle YOLOV8 léger (YOLOv8n). Ensuite, les performances du modèle sont

évaluées à l'aide des mesures d'évaluation afin de garantir sa précision pour les inférences et les prédictions en temps réel. L'objectif de notre recherche actuelle est d'améliorer la détection et la localisation des surfaces des PCB défectueuses en présentant un nouveau résultat de taux de détection.

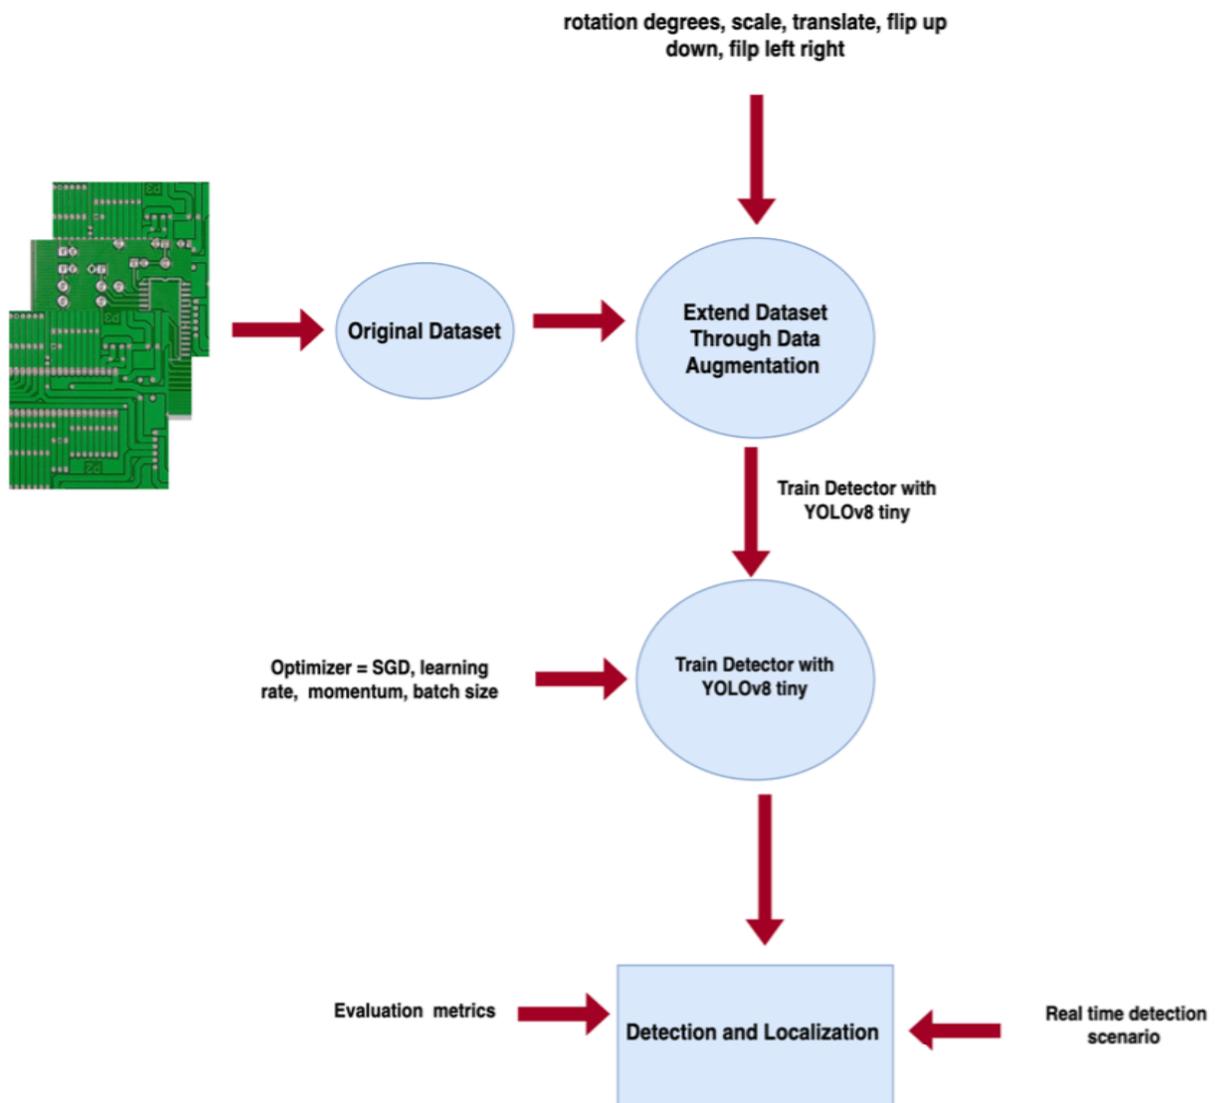


Figure 28 : illustration des étapes de l'étude proposée dans les PCB

5.3.1. Détection des défauts des PCB basé sur le modèle YOLOv8 léger

Le modèle YOLOv8 est composé de l'entrée, du backbone (la colonne vertébrale), le neck (cou), le head (tête), et la sortie. Dans un premier temps, l'algorithme traite l'image d'entrée en utilisant des techniques telles que le calcul adaptatif de l'ancrage et le remplissage adaptatif des niveaux de gris dans la phase de prétraitement. En outre, les éléments clés du réseau YOLOv8 sont le réseau du backbone et le module du cou (neck), qui utilisent la convolution et l'extraction de caractéristiques pour extraire des caractéristiques des différentes tailles de l'image d'entrée. Ces parties intègrent un CNN basé sur une version personnalisée de l'architecture CSPDarknet53 [81], ce qui permet de représenter l'entrée sous la forme d'une carte de caractéristiques. Enfin, nous utilisons la section tête pour effectuer la tâche de détection [80]. La figure ci-dessus illustre l'architecture simplifier de YOLOv8.

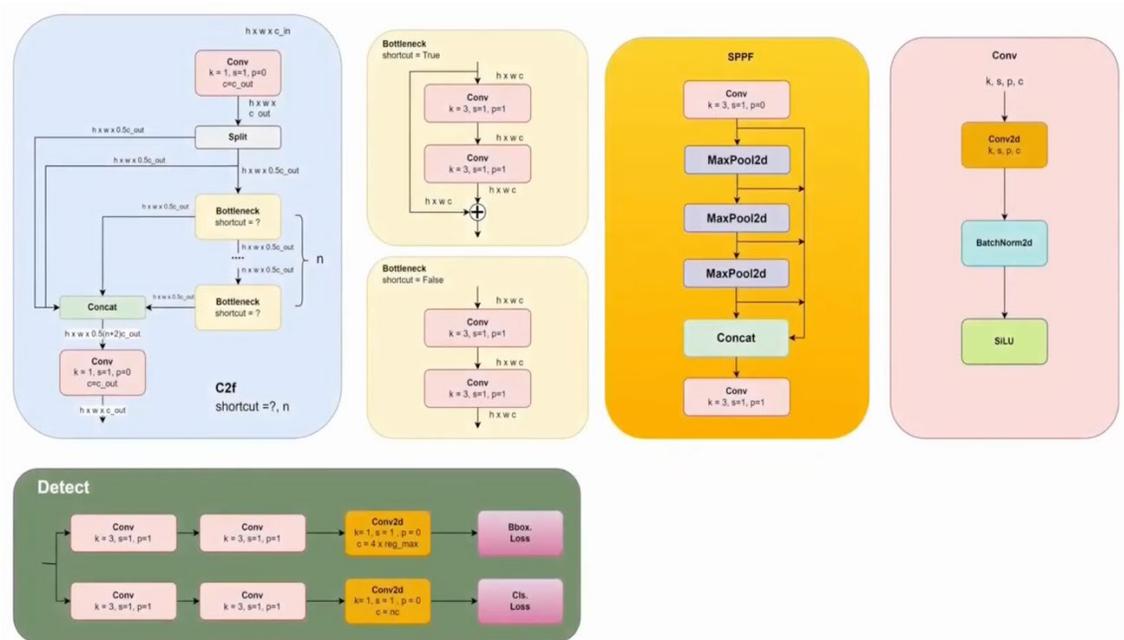


Figure 29 : architecture simplifier de YOLOv8.

5.3.2. Acquisition et traitement des données

Dans cette partie, l'ensemble des données utilisé provient du laboratoire sur l'interaction homme-robot de l'université de Pékin [81]. L'ensemble des données est augmenté et divisé pour l'entraînement, la validation et le test, qui consistent respectivement en 8534 images d'entraînement, 1066 images de validation et 1068 images de test, avec une dimension d'image de 600x600, contenant six défauts de PCB de différentes classes.

Pour améliorer les performances du modèle et sa généralisation, nous avons mis en œuvre l'augmentation des données YOLOv8 intégrée en ligne afin d'éviter le surajustement, ce qui permet d'obtenir des prédictions plus précises et d'accroître la

robustesse du modèle. La figure suivante montre des échantillons de l'ensemble des données des images des PCB défectueuses utilisées. Comme le montre la figure suivante, nous avons zoomé sur les régions défectueuses de l'image car les défauts sont très petits pour l'œil humain.

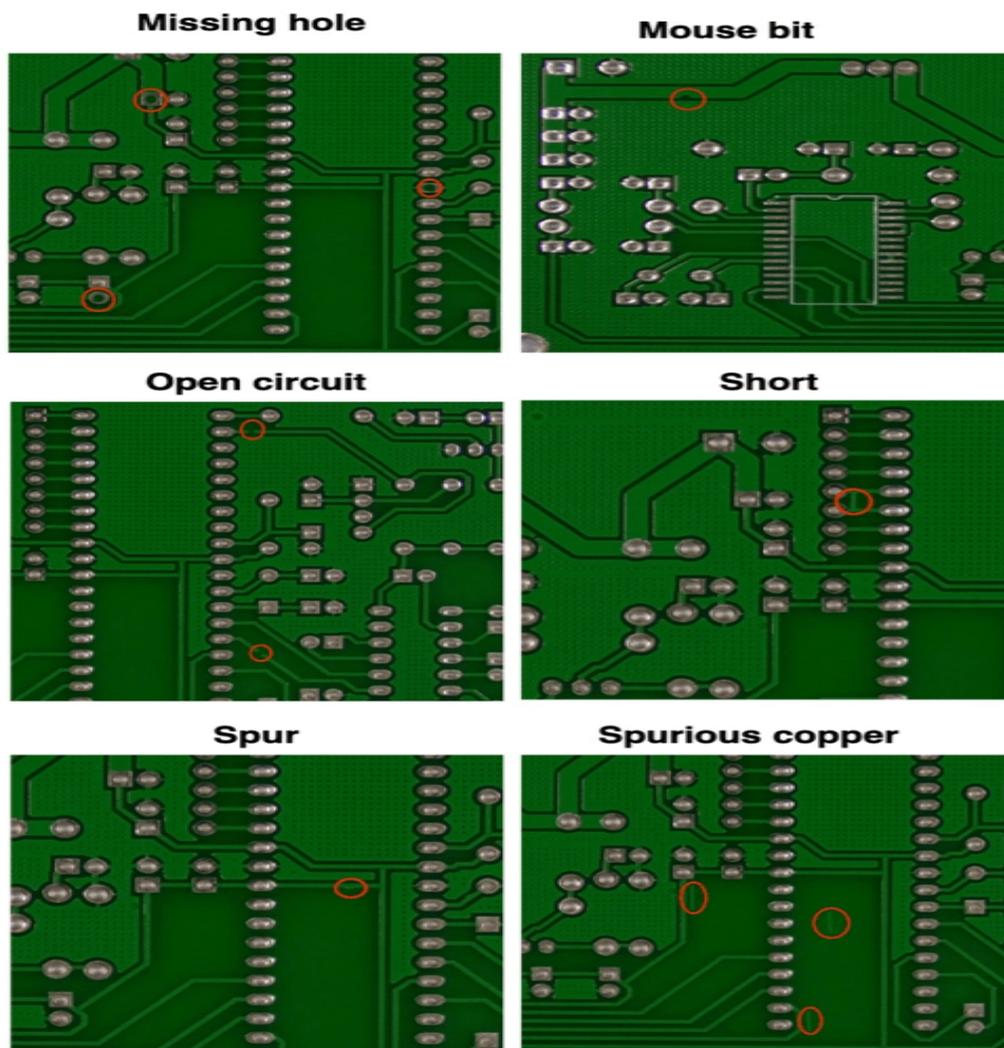


Figure 30 : images de PCB défectueux [81].

5.3.3. Définition des hyperparamètres

Cette recherche a été menée avec Python 3.10.12, et Keras 2.15.0 sur google Colab cloud avec un GPU Nvidia L4. Et 150 iterations sont considérées pour la phase d'entraînement. Afin de réduire le temps de traitement et d'améliorer la vitesse d'apprentissage, les images des PCB défectueuses sont redimensionnées à 480×480 pour le détecteur YOLOv8n. Des paramètres supplémentaires sont réglés pour améliorer les performances d'apprentissage du modèle comme suit : taux d'apprentissage = 0,01, momentum = 0,937, ces hyper paramètres sont réglés pour bénéficier de la robustesse de l'optimiseur SGD qui est utilisé pour l'apprentissage de notre détecteur.

5.3.4. Mesures d'évaluation

Intersection sur Union (IoU) : il s'agit d'une mesure permettant d'évaluer les performances du modèle de détection des objets en mesurant la précision de la localisation et en calculant les erreurs de localisation. Elle permet de différencier une identification précise d'une identification imprécise. L'indice de Jaccard, un coefficient de similarité entre deux ensembles des données est utilisé dans l'intersection sur l'union. Pour déterminer où ces deux boîtes de délimitation se croisent, il calcule la proportion du chevauchement et de l'union entre la boîte de délimitation candidate créée et la boîte de délimitation de la vérité terrain. L'équation suivante représente l'intersection sur l'union :

$$IoU = \frac{Area\ of\ Intersection}{Area\ of\ Union} \quad (10)$$

La précision moyenne (mAP) : la métrique mAP a été utilisée pour comparer la précision entre les réseaux mentionnés. La métrique mAP dépend du seuil Intersection over Union (IoU) pour les prédictions, et une autre métrique connue sous le nom de mAP@50 peut être utilisée (mAP calculée au seuil IOU 0,5). La formule mAP repose sur le calcul de la précision et du rappel en utilisant les vrais positifs (TP), les vrais négatifs (TN), les faux positifs (FP) et les faux négatifs (FN). Les valeurs TP, TN, FP et FN sont obtenues à partir des équations ci-dessous :

Courbe de précision-rappel : Le rappel est représenté sur l'axe horizontal de la courbe, tandis que la précision est représentée sur l'axe vertical, chaque point de la courbe indiquant une valeur seuil différente.

$$Precision = \frac{TP}{TP + FP} , Recall = \frac{TP}{TP + FN} \quad (11)$$

Score F1 : Le score F1 est une mesure d'évaluation largement utilisée qui fournit une mesure équilibrée de la précision, en tenant compte à la fois de la précision et du rappel. L'équation du score F1 est la suivante :

$$F1\ score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

5.4. Résultats

Cette section présente les résultats obtenus par notre modèle de détection YOLOv8n pour la reconnaissance et la localisation des défauts des circuits imprimés. La figure de

précision et rappel montre les mesures de rappel, de précision, de $mAP@50$ et de $mAP@50-95$ sur 150 itérations d'entraînement de la solution proposée. Après seulement 50 itérations, notre modèle a atteint une précision de $mAP@50$ et un rappel supérieur à 90 %, ainsi avec une $mAP@50-95$ supérieur à 50 %. Par ailleurs, la figure 31 d'entraînement montre qu'après 50 itérations, la perte de classification à l'entraînement et la perte de classification à la validation étaient inférieures à 1, et la perte de boîte à l'entraînement et la perte de boîte à la validation étaient inférieures à 1,5. Par conséquent, ces résultats démontrent que l'apprentissage de notre modèle sur l'ensemble des données est supérieur, atteignant une précision élevée et une erreur minimale.

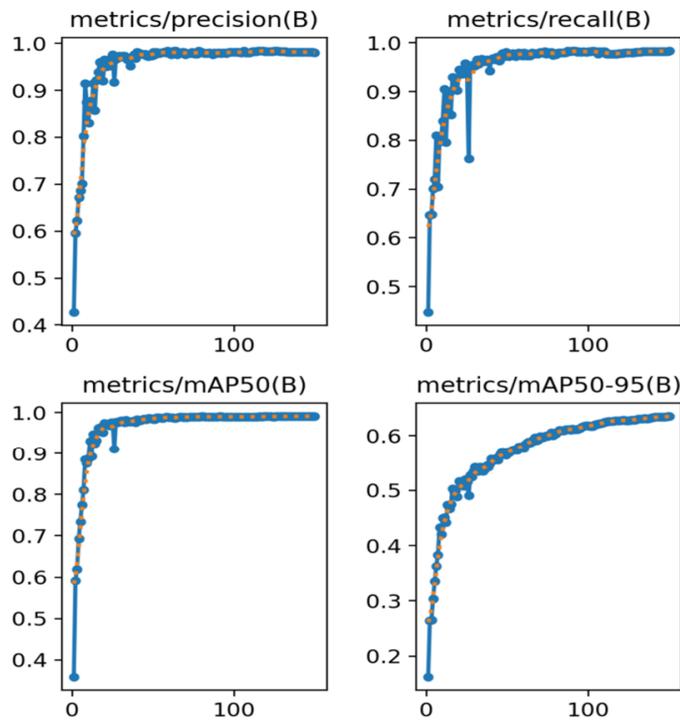


Figure 31 : courbe de précision et rappel

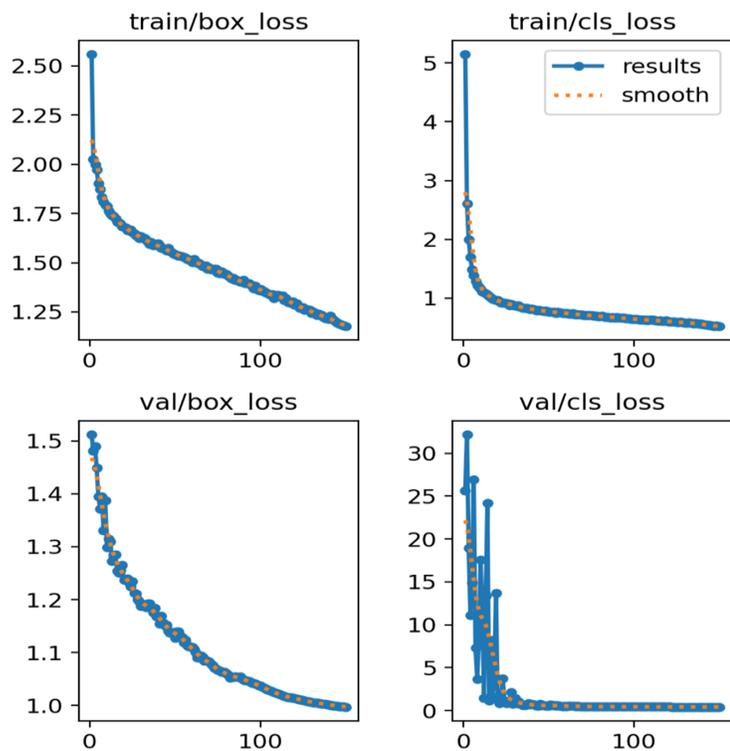


Figure 32 : précision et perte pour l'entraînement et la validation.

Tableau 3: résultats des métriques

Precision	98.44%
Recall	98.42%
mAP@50	99.08
mAP@50-95	63.54%

Comme le montre la figure 33, en comparant les résultats des études antérieures citées dans la section des travaux connexes, notre modèle YOLOv8n-tiny surpasse tous les autres modèles comparés en termes de précision avec une $mAP@50$ de 99,08 % et une $mAP@50-95$ de 63,54 %.

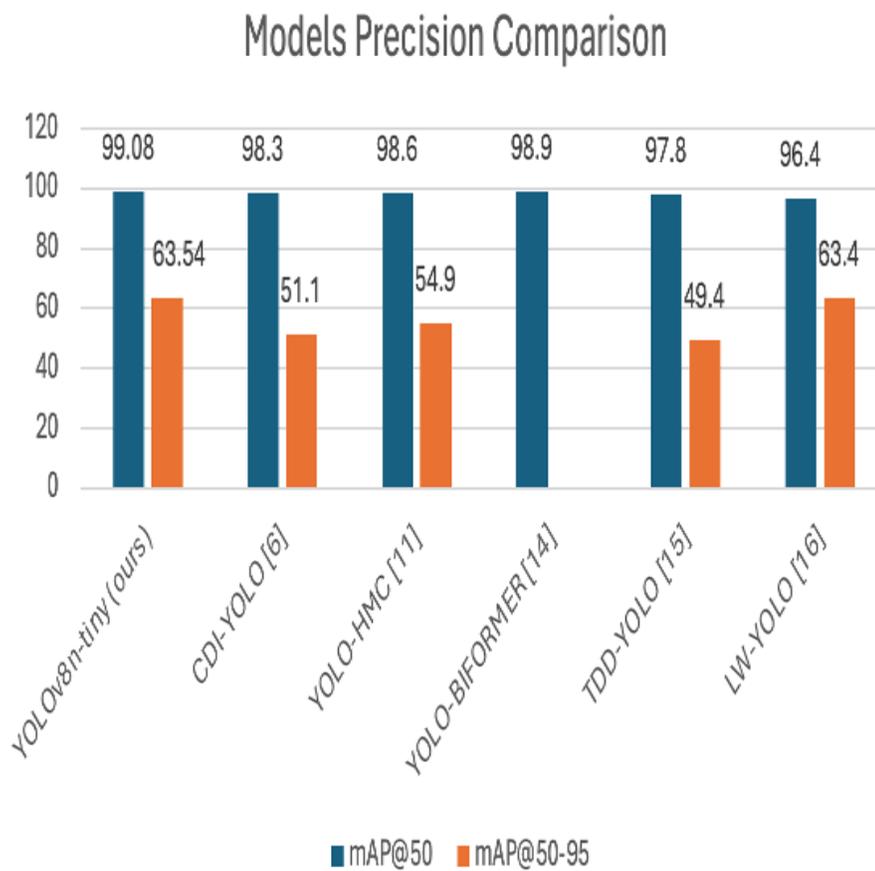


Figure 33 : Comparaison de la précision des modèles.

Enfin, la figure 34 montre notre modèle de prédiction des défauts des circuits imprimés et de localisation des petits défauts dans ces circuits.

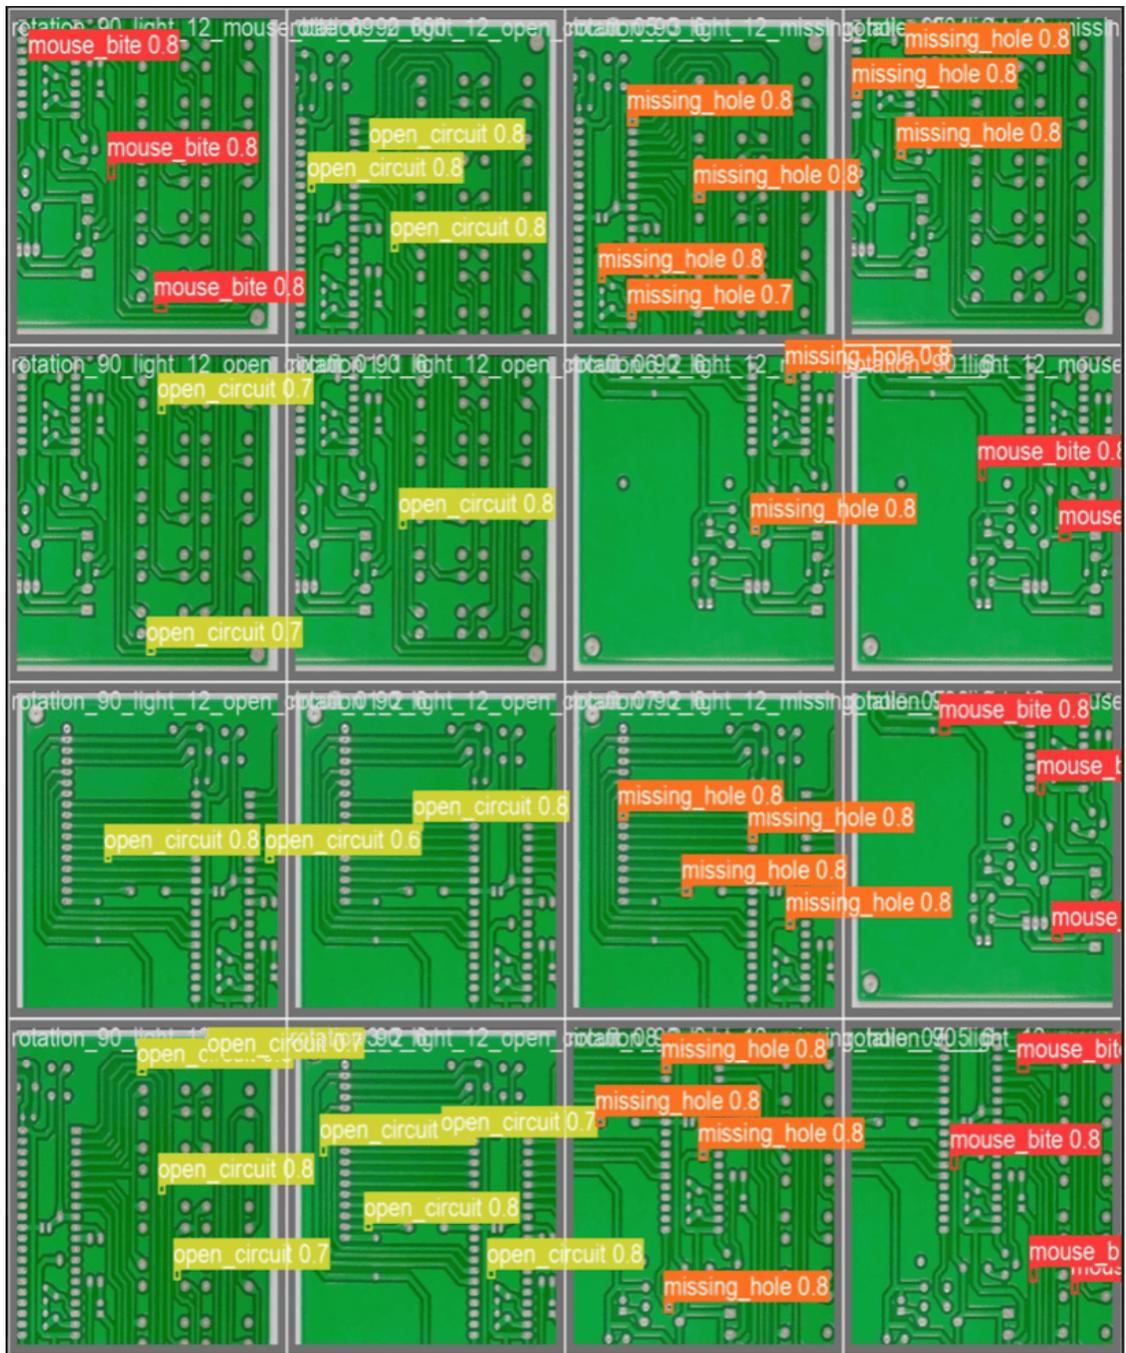


Figure 34 : prédiction des défauts PCB

5.5. Conclusion

Cette recherche a introduit un modèle léger de détection des défauts des PCB. Notre modèle YOLOv8n a montré des meilleures performances que certaines méthodes existantes, comme le montre la section des résultats. De plus, nous avons prouvé que notre modèle répond aux besoins de précision et du temps réel pour détecter les petits défauts sur les surfaces des PCB en atteignant un mAP@50 de 99,08 %. En perspective, nous avons l'intention de développer cette étude à l'avenir en étendant la solution à d'autres classes de petits défauts et à différentes cartes. En conséquence, les résultats de cette étude aideront, dans nos recherches futures, à améliorer notre méthode et à l'étendre à d'autres problèmes de PCB.

Conclusion générale

Entreprises d'aujourd'hui. La diminution des coûts de réparation et la prédiction des pannes sont essentielles pour les entreprises modernes, car elles permettent d'anticiper les problèmes avant qu'ils ne deviennent critiques, réduisant ainsi les interventions d'urgence coûteuses. Cela optimise l'utilisation des ressources humaines et matérielles, améliorant la productivité. De plus, en maintenant les équipements en bon état, les entreprises renforcent leur engagement envers la durabilité et minimisent leur impact environnemental. En particulier, dans le contexte d'inspection et surveillance des éoliennes et des panneaux solaires. L'IVA permet :

- Efficacité Améliorée: L'automatisation permet de réaliser des inspections à grande échelle rapidement et efficacement, réduisant le temps nécessaire pour détecter des défauts ou des anomalies.
- Réduction des Coûts: En remplaçant les inspections manuelles par des systèmes automatisés, les entreprises peuvent diminuer les coûts de main-d'œuvre et les dépenses liées aux erreurs humaines.
- Sécurité: L'utilisation de drones et de systèmes d'inspection automatisés permet de surveiller des sites difficiles d'accès ou dangereux sans mettre en danger la vie des employés.

- **Précision et Fiabilité:** Les systèmes d'inspection visuelle automatisée utilisent des technologies avancées, comme la vision par ordinateur et l'intelligence artificielle, pour détecter des défauts avec une grande précision.
- **Analyse des Données:** Ces systèmes collectent des données précieuses qui peuvent être analysées pour améliorer la performance des installations.
- **Durabilité et Impact Environnemental:** En assurant un fonctionnement optimal des énergies renouvelables, l'inspection visuelle automatisée contribue à minimiser l'impact environnemental.

Ce mémoire a exploré l'utilisation des méthodes d'apprentissages profond (NasNetMobile, MobileNetV2, YOLOv8, YOLOv11) pour prédire les défaillances et identifier les emplacements des défauts structurelles et électriques dans les éoliennes, les panneaux solaires, et les PCB. L'étude s'est déroulée en trois phases principales.

Initialement, dans le chapitre 3, on a utilisé et modifier l'architecture du model NasNetMobile pour prédire et classifier les défauts sur les éoliennes, ensuite appliquer la méthode Grad-cam pour localiser les défauts sur les éoliennes. Dans la deuxième phase on a élargi notre base des données avec d'autre images des éolienne défectueuses en raison pour appliquer la détection d'objet (défauts) avec YOLOv11. Les résultats ont montré que YOLOv11 donne de bonne précision avec jusqu'à 91%, aussi l'application de Grad-cam avec NasNetMobile permet de localiser avec efficacité l'emplacement des défauts sur les éoliennes avec une précision de 94%.

Deuxièmement, dans le chapitre 4, on a utilisé et modifier l'architecture du model MobileNetV2 pour prédire et classifie six défauts sur les panneaux solaires, les résultats ont montré une bonne précision avec 96%.

Troisièmement, le chapitre 5, le model YOLOv8 est utilisé afin de détecter les défauts sur les surfaces des PCB et comme résultats la précision a atteint 99%

En conclusion, le but général de cette recherche est de réaliser un programme multitâche qui permet de faire une inspection autonome. Pour cela, les résultats des modèles entraînés qui sont proposés dans cette recherche montrent qu'on peut les utiliser pour la prédiction et la détection des anomalies structurelles et électriques dans les éoliennes, les panneaux solaires et les PCB en temps réelle, à cause de leur rapidité et efficacité. Mais également la possibilité de les embarquer dans des cartes électroniques embarquées.

Bibliographie

- [1] Zhang, L., Yang, J., & Zhao, X. (2020). Recent advances in automated visual inspection: From classic methods to deep learning approaches. *Journal of Quality in Maintenance Engineering*, 26(4), 573–593.
- [2] Leach, P., Martin, J., & Smith, D. (2018). Human factors in visual inspection: Challenges and solutions. *Journal of Quality Control*, 29(5), 345–358.
- [3] Gupta, S., & Singh, R. (2021). Automatic visual inspection systems: Principles and applications. *International Journal of Advanced Manufacturing Technology*, 114(1–2), 1–12.
- [4] Chen, T., & Xie, Y. (2019). Defect detection in manufacturing: A survey of state-of-the-art techniques. *Journal of Manufacturing Processes*, 35, 547–558.
- [5] Huang, T., Zhang, L., & Wang, S. (2020). The role of AI in enhancing quality control systems. *Quality Assurance Review*, 12(1), 67–78.
- [6] Wang, J., Xu, Z., & Chen, Y. (2019). Enhancing production efficiency through automated inspection. *Journal of Production Technology*, 33(4), 230–240.
- [7] Patel, V., & Kumar, S. (2022). Cost-benefit analysis of implementing automated inspection systems. *International Journal of Engineering Management*, 18(2), 101–115.
- [8] Lee, J., Kim, H., & Park, Y. (2021). Data-driven approaches in visual inspection: A comprehensive review. *Data Science in Industry*, 6(4), 289–304.
- [9] Zhao, L., Huang, K., & Yang, J. (2023). Overcoming challenges in automated visual inspection implementation. *Technology in Industry Review*, 15(2), 89–102.
- [10] Smith, A., & Jones, B. (2024). The future of quality assurance: Trends in automated systems. *Manufacturing Insights*, 10(1), 55–67.
- [11] OECD. (2008). *World energy outlook 2008*.
- [12] Dwivedi, D., Babu, K. V. S. M., Yemula, P. K., Chakraborty, P., & Pal, M. (2024). Identification of surface defects on solar PV panels and wind turbine

blades using attention-based deep learning model. *Engineering Applications of Artificial Intelligence*, 131, 107836.

- [13] Fang, K., Zhou, Y., Wang, S., Ye, R., & Guo, S. (2018). Assessing national renewable energy competitiveness of the G20: A revised Porter's diamond model. *Renewable and Sustainable Energy Reviews*, 93, 719–731.
- [14] Du, Y., Zhou, S., Jing, X., Peng, Y., Wu, H., & Kwok, N. (2020). Damage detection techniques for wind turbine blades: A review. *Mechanical Systems and Signal Processing*, 141, 106445.
- [15] Author, A. (2021). Wind energy and greenhouse gas reduction. *Journal of Renewable Energy*, 14(3), 215–225.
- [16] Author, B. (2022). The role of wind power in sustainable energy. *Energy Sources Review*, 19(2), 98–108.
- [17] Author, C. (2020). Energy independence through wind turbines. *International Journal of Energy Economics*, 10(1), 34–45.
- [18] Author, D. (2019). Employment opportunities in the wind energy sector. *Journal of Clean Technology*, 16(4), 110–120.
- [19] Author, E. (2023). Health benefits of wind energy. *Environmental Health Perspectives*, 9(3), 60–70.
- [20] Author, F. (2021). Wind turbines and ecosystem impact. *Journal of Environmental Management*, 12(5), 245–255.
- [21] Author, G. (2022). Wind energy access in underserved communities. *Journal of Sustainable Development*, 18(2), 145–155.
- [22] Author, H. (2023). Balancing economic development with wind energy. *Global Energy Journal*, 7(3), 201–210.
- [23] Author, I. (2023). Harnessing wind power for a sustainable future. *Renewable Energy Journal*, 11(2), 150–160.
- [24] Burton, J., Sharpe, D., Jenkins, N., & Bossanyi, E. (2011). *Wind energy handbook*. Wiley.
- [25] Manwell, M. J., McGowan, J. G., & Rogers, A. L. (2009). *Wind energy explained: Theory, design and application*. Wiley.
- [26] Mackay, D. J. (2008). *Sustainable energy - Without the hot air*. UIT Cambridge.
- [27] International Renewable Energy Agency (IRENA). (2019). *Wind energy: A global perspective*. IRENA.
- [28] Guezuraga, B., Zauner, R., & Pölz, W. (2012). Life cycle assessment of two different 2 MW class wind turbines. *Renewable Energy*, 37(1), 37–44.
- [29] Tremeac, B., & Meunier, F. (2009). Life cycle analysis of 4.5 MW and 250 W wind turbines. *Renewable and Sustainable Energy Reviews*, 13(8), 2104–2110.
- [30] Vestas Wind Systems A/S. (2005). *Life cycle assessment of offshore and onshore sited wind power plants based on Vestas V90-3.0 MW turbines*.
- [31] Asghar, B., & Liu, X. (2018). Adaptive neuro-fuzzy algorithm to estimate effective wind speed and optimal rotor speed for variable-speed wind turbine. *Neurocomputing*, 272, 495–504.

- [32] Smith, J., et al. (2021). Challenges in wind turbine maintenance. *Journal of Renewable Energy*, 25(4), 323–335.
- [33] Johnson, R. (2022). Material costs in wind turbine construction. *Energy Materials Research*, 12(2), 150–162.
- [34] Chang, L. (2023). Logistical challenges of remote wind farms. *International Journal of Energy Economics*, 18(1), 45–56.
- [35] Patel, S. (2022). Safety regulations in wind energy maintenance. *Journal of Occupational Safety*, 10(3), 78–89.
- [36] Brown, A. (2023). Economic impacts of turbine downtime. *Renewable Energy Economics*, 14(5), 201–215.
- [37] Wilson, T. (2021). Technological innovations in wind energy. *Journal of Clean Technology*, 16(2), 112–124.
- [38] Lee, D. (2020). The role of monitoring systems in wind turbine efficiency. *Energy Systems Review*, 9(1), 34–45.
- [39] Carter, H. (2023). Strategic planning for wind energy maintenance. *Global Energy Journal*, 8(4), 98–107.
- [40] Lei, M., Wang, X., Wang, M., & Cheng, Y. (2024). Improved YOLOv5 based on multi-strategy integration for multi-category wind turbine surface defect detection. *Energies*, 17(8), 1796.
- [41] Altice, E., Nazario, M., Davis, M., Shekaramiz, M., Moon, T. K., & Masoum, M. A. (2024). Anomaly detection on small wind turbine blades using deep learning algorithms. *Energies*, 17(5), 982.
- [42] Ran, X., Zhang, S., Wang, H., & Zhang, Z. (2022). An improved algorithm for wind turbine blade defect detection. *IEEE Access*, 10, 122171–122181.
- [43] Radhika, K., Devika, K., Aswathi, T., Sreevidya, P., Sowmya, V., & Soman, K. (2020). Performance analysis of NASNet on unconstrained ear recognition. In *Nature inspired computing for data science* (pp. 57–82).
- [44] Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8697–8710).
- [45] Radhika, K., Devika, K., Aswathi, T., Sreevidya, P., Sowmya, V., & Soman, K. (2020). Performance analysis of NASNet on unconstrained ear recognition. In *Nature inspired computing for data science* (pp. 57–82).
- [46] Amiruddin, P., & Kadir, R. E. A. (2020). CNN architectures performance evaluation for image classification of mosquito in Indonesia. In *2020 International Seminar on Intelligent Technology and Its Applications (ISITIA)* (pp. 223–227). IEEE.
- [47] Saponara, S., & Elhanashi, A. (2021). Impact of image resizing on deep learning detectors for training time and model performance. In *International Conference on Applications in Electronics Pervading Industry, Environment and Society* (pp. 10–17). Springer.
- [48] Ogbolumani, O. A., & Nwulu, N. (2020). Integrated appliance scheduling and optimal sizing of an autonomous hybrid renewable energy system for

- agricultural food production. In *Advances in Manufacturing Engineering: Selected articles from ICMMPPE 2019* (pp. 651–660). Springer Singapore.
- [49] Dwivedi, D., Yemula, P. K., & Pal, M. (2023). Evaluating the planning and operational resilience of electrical distribution systems with distributed energy resources using complex network theory. *Renewable Energy Focus*, 46, 156–169.
- [50] Shairi, N. A. S., Ghoni, R., & Ali, K. (2020). Solar panel dust monitoring system. *Engineering Heritage Journal*, 4(2), 44–45.
- [51] Qasem, H., Mnatsakanyan, A., & Banda, P. (2016). Assessing dust on PV modules using image processing techniques. In *2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)* (pp. 2066–2070). IEEE.
- [52] Mazumder, M. K., et al. (2015). Environmental degradation of the optical surface of PV modules and solar mirrors by soiling and high RH and mitigation methods for minimizing energy yield losses. In *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)* (pp. 1–6). IEEE.
- [53] Ayyagari, K. S., et al. (2022). Simultaneous detection and classification of dust and soil on solar photovoltaic arrays connected to a large-scale industry: A case study. In *2022 18th International Conference on the European Energy Market (EEM)* (pp. 1–6). IEEE.
- [54] Al Mansur, A., Amin, M. R., & Islam, K. K. (2019). Determination of module rearrangement techniques for non-uniformly aged PV arrays with SP, TCT, BL and HC configurations for maximum power output. In *2019 International Conference on Electrical, Computer and Communication Engineering (ECCE)* (pp. 1–5). IEEE.
- [55] Alnasser, T. M., Mahdy, A. M., Abass, K. I., Chaichan, M. T., & Kazem, H. A. (2020). Impact of dust ingredient on photovoltaic performance: An experimental study. *Solar Energy*, 195, 651–659.
- [56] Joseph, A. S. D. T., Aditya, M. K. P. D. S., & Arvind, R. N. A. V. I. K. K. (2021). Causes and effects of external electrical damage in solar photovoltaic panels. *International Journal of Renewable Energy Research*, 11(1), 378–386.
- [57] Zhang, J., Chen, X., Wei, H., & Zhang, K. (2024). A lightweight network for photovoltaic cell defect detection in electroluminescence images based on neural architecture search and knowledge distillation. *Applied Energy*, 355, 122184.
- [58] Yin, W., Lingxin, S., Maohuan, L., Qianlai, S., & Xiaosong, L. (2023). PV-YOLO: Lightweight YOLO for photovoltaic panel fault detection. *IEEE Access*, 11, 10966–10976.
- [59] Garg, H., Sharma, R. K., & Gupta, P. (2023). Machine learning-based approach for detecting anomalies in photovoltaic systems. *Journal of Cleaner Production*, 345, 131068.
- [60] Rashid, A., Khan, M. J., & Zubair, L. A. (2023). Using drone-based thermal imaging for solar panel defect detection. *Energy Reports*, 9, 245–258.

- [61] Bhatia, M., Kumar, A., & Jain, S. (2023). Automated detection of cracks in solar panels using deep learning techniques. *Renewable Energy*, 205, 191–201.
- [62] Zhang, M., & Yin, L. (2022). Solar cell surface defect detection based on improved YOLO v5. *IEEE Access*, 10, 80804–80815.
- [63] Alnasser, T. M., Mahdy, A. M., Abass, K. I., Chaichan, M. T., & Kazem, H. A. (2020). Impact of dust ingredient on photovoltaic performance: An experimental study. *Solar Energy*, 195, 651–659.
- [64] PCBs. (n.d.). *PCB Testing Methods Guide*. Retrieved from <https://www.mclpcb.com/blog/pcb-testing-methods-guide/>
- [65] Malge, P., & Nadaf, R. (2014). A survey: Automated visual PCB inspection algorithm. *International Journal of Engineering Research and Technology*, 3(1).
- [66] Malge, P. S., & Nadaf, R. S. (2014). PCB defect detection, classification and localization using mathematical morphology and image processing tools. *International Journal of Computer Applications*, 87(9).
- [67] Buchi, G., Cugno, M., & Castagnoli, R. (2020). Smart factory performance and industry 4.0. *Technological Forecasting and Social Change*, 150, 119790.
- [68] Chen, I.-C., Hwang, R.-C., & Huang, H.-C. (2023). PCB defect detection based on deep learning algorithm. *Processes*, 11(3), 775.
- [69] Xiao, G., Hou, S., & Zhou, H. (2024). PCB defect detection algorithm based on CDI-YOLO. *Scientific Reports*, 14(1), 7351.
- [70] Chang, Y., Xue, Y., Zhang, Y., Sun, J., Ji, Z., Li, H., Wang, T., & Zuo, J. (2024). PCB defect detection based on PSO-optimized threshold segmentation and SURF features. *Signal, Image and Video Processing*, 1–10.
- [71] Singha, S., & Aydin, B. (2021). Automated drone detection using YOLOv4. *Drones*, 5(3), 95.
- [72] Li, L., Zhang, S., & Wang, B. (2021). Plant disease detection and classification by deep learning—a review. *IEEE Access*, 9, 56683–56698.
- [73] Zhao, Z.-Q., Zheng, P., Xu, S.-t., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212–3232.
- [74] Yuan, M., Zhou, Y., Ren, X., Zhi, H., Zhang, J., & Chen, H. (2024). YOLOHMC: An improved method for PCB surface defect detection. *IEEE Transactions on Instrumentation and Measurement*.
- [75] Nascimento, M. G. d., Fawcett, R., & Prisacariu, V. A. (2019). DSConv: Efficient convolution operator. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 5148–5157).
- [76] Zhang, H., Xu, C., & Zhang, S. (2023). Inner-IoU: More effective intersection over union loss with auxiliary bounding box. *arXiv preprint arXiv:2311.02877*. <https://arxiv.org/abs/2311.02877>
- [77] Wang, X., Zhang, H., Liu, Q., Gong, W., Bai, S., & You, H. (2024). YOLO’s multiple strategy PCB defect detection model. *IEEE MultiMedia*.

- [78] Zhou, W., Li, C., Ye, Z., He, Q., Ming, Z., Chen, J., Wan, F., & Xiao, Z. (2024). An efficient tiny defect detection method for PCB with improved YOLO through a compression training strategy. *IEEE Transactions on Instrumentation and Measurement*.
- [79] Yuan, Z., Tang, X., Ning, H., & Yang, Z. (2024). LW-YOLO: Lightweight deep learning model for fast and precise defect detection in printed circuit boards. *Symmetry*, 16(4), 418.
- [80] Wang, C.-Y., Liao, H.-Y. M., Wu, Y.-H., Chen, P.-Y., Hsieh, J.-W., & Yeh, I.-H. (2020). CSPNet: A new backbone that can enhance learning capability of CNN. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 390–391).
- [81] Ding, R., Dai, L., Li, G., & Liu, H. (2019). TDD-Net: A tiny defect detection network for printed circuit boards. *CAAI Transactions on Intelligence Technology*, 4(2), 110–116.

ANNEX A

****Grad-CAM (Gradient-weighted Class Activation Mapping) **** est une technique utilisée pour visualiser les régions d'une image qui ont conduit à la décision d'un réseau de neurones dans une tâche de classification.

Voici la méthode de fonctionnement de l'algorithme Grad-CAM :

DEBUT

ENTREE :

Image x
Modèle CNN entraîné f
Classe cible c

// Étape 1 : Passage avant (Forward Pass)

Passer l'image x à travers le modèle f pour obtenir la prédiction de la classe c :

$y_c = f(x)$

// Extraire les cartes de caractéristiques A^k de la dernière couche convolutionnelle

A^k = Cartes de caractéristiques de la dernière couche convolutionnelle du modèle f

// Étape 2 : Passage arrière (Backward Pass)

Calculer le gradient du score de la classe y_c par rapport à A^k :

Gradients = $\partial y_c / \partial A^k$

// Étape 3 : Moyenne globale des gradients (Global Average Pooling)

// Calculer les poids α_k pour chaque canal k en moyennant les gradients

POUR chaque canal k dans A^k :

$\alpha_k = (1 / (H * W)) * \text{SOMME}(\partial y_c / \partial A^k_{\{ij\}} \text{ pour } i = 1 \text{ à } H, j = 1 \text{ à } W)$

// Étape 4 : Pondérer les cartes de caractéristiques

Initialiser la carte de chaleur Grad-CAM $L^c = 0$

POUR chaque canal k :

$L^c += \alpha_k * A^k$

// Étape 5 : Appliquer l'activation ReLU

$L^c = \text{ReLU}(L^c)$

// Étape 6 : Agrandir la carte de chaleur (thermique) à la taille de l'image originale

Heatmap = Agrandir (L^c) pour correspondre aux dimensions de l'image x

SORTIE : Heatmap (visualisation spécifique à la classe)

FIN

ANNEX B

Algorithme simplifié pour l'architecture **YOLO (You Only Look Once)**, qui est un modèle de détection d'objets. L'idée principale de YOLO est de diviser l'image en une grille et de prédire les boîtes englobantes, les classes d'objets et les scores de confiance pour chaque cellule de la grille.

Algorithme de YOLO :

1. **Prétraitement de l'image :**
 - Redimensionner l'image d'entrée à une taille fixe $w \times h$ (dans notre cas : 640×640).
 - Normaliser les pixels de l'image entre 0 et 1.
2. **Passage dans le réseau :**
 - L'image est passée dans un réseau de neurones convolutifs (CNN) qui génère une carte de caractéristiques de taille $S \times S \times (B \times 5 + C)$, où :
 - S: nombre de cellules dans la grille (ex. 13×13 \ ou 19×19).
 - B: nombre de boîtes englobantes par cellule.
 - 5 : chaque boîte englobante contient 4 coordonnées de la boîte + 1 score de confiance.
 - C : nombre de classes d'objets.
3. **Prédictions de boîtes et de classes :**
 - Pour chaque cellule de la grille, le réseau prédit B boîtes englobantes, leur score de confiance et les probabilités des classes.
 - Chaque boîte est caractérisée par :
 - (x,y): centre de la boîte (par rapport à la cellule de la grille).
 - w,h : largeur et hauteur de la boîte.
 - c : score de confiance (probabilité que la boîte contient un objet).
 - Chaque cellule prédit également une probabilité pour chaque classe d'objet.
4. **Application de la fonction sigmoïde :**
 - Appliquer la fonction sigmoïde pour obtenir des valeurs de probabilité entre 0 et 1 pour les boîtes et les classes.
5. **Filtrage des prédictions (seuil de confiance) :**
 - Pour chaque boîte, multiplier le score de confiance par la probabilité de chaque classe pour obtenir la probabilité finale de chaque classe dans chaque boîte.
 - Supprimer les boîtes avec un score de confiance inférieur à un seuil prédéfini.
6. **Suppression des doublons (NMS - Non-Maximum Suppression) :**

- Appliquer **Non-Maximum Suppression (NMS)** pour éliminer les boîtes englobantes redondantes qui se chevauchent fortement (c'est-à-dire lorsque l'IOU (Intersection over Union) est supérieur à un seuil donné).

7. **Post-traitement :**

- Les boîtes finales et les classes d'objets sont renvoyées comme sorties du modèle.
- Ces prédictions incluent les coordonnées des boîtes englobantes et les classes associées à chaque objet détecté dans l'image.

ANNEX C

Voici les algorithmes des modèles : **MobileNetV2** et **NASNetMobile**.

MobileNetV2 :

1. **Prétraitement de l'image :**
 - Redimensionner l'image à une taille fixe (par exemple, 224x224).
 - Normaliser les pixels (scalés entre 0 et 1).
2. **Passage dans le réseau :**
 - Utilisation de blocs **inverted residuals** avec **depthwise separable convolutions**.
 - Chaque bloc se compose de 3 couches : **pointwise convolution**, **depthwise convolution**, et **pointwise convolution** (pour réduire les paramètres).
3. **Classification :**
 - Après avoir traversé les blocs, l'image est passée à une couche **fully connected** (FC) et une fonction d'activation **Softmax** pour obtenir les prédictions de classes.

NASNetMobile :

1. **Prétraitement de l'image :**
 - Redimensionner l'image à 224x224 pixels.
 - Normaliser les pixels.
2. **Passage dans le réseau :**
 - Architecture basée sur les **réseaux neuronaux architecturaux** (NAS) avec un **bloc de cellules** optimisé par recherche.
 - Utilisation de convolutions classiques et de **depthwise separable convolutions**.
3. **Classification :**
 - Après plusieurs couches convolutives, les caractéristiques sont extraites par une couche FC.
 - **Softmax** pour la classification des classes.