

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

جامعة سعيدة د. مولاي الطاهر

كلية الرياضيات و الإعلام الآلي و الاتصالات السلكية و اللاسلكية

قسم: الإعلام الآلي



Mémoire de Master en informatique

Spécialité : Modélisation Informatique des Connaissances et du
Raisonnement

T h è m e



Détection et identification des maladies
des plantes à l'aide de l'Apprentissage
Profond



▪ Présenté par :
Guenachi Hayat

▪ Dirigé par :
Dr. Khiati Nadri

Année universitaire



2025-2026

– Remerciements –

Avant tout, je remercie Allah le Tout-Puissant de m'avoir accordé la santé, la patience, le courage et la volonté nécessaires pour mener à bien ce travail.

J'adresse mes plus sincères remerciements à mon encadreur, Mr. Khiati Nadri, pour son accompagnement, sa disponibilité, ses conseils avisés et son soutien tout au long de la réalisation de ce mémoire. Ses orientations précieuses, sa rigueur scientifique et ses encouragements constants ont été d'une grande importance dans l'aboutissement de ce travail. Je lui exprime ma profonde gratitude et mon grand respect.

J'adresse également mes sincères remerciements aux membres du jury qui me font l'honneur d'évaluer ce travail.

Mes remerciements s'adressent également à tous les enseignants du Département d'Informatique de l'Université Dr Moulay Tahar de Saïda, qui ont contribué à ma formation académique et scientifique durant tout mon cursus universitaire.

J'exprime également ma reconnaissance à toutes les personnes qui m'ont apporté leur aide, leur soutien moral ou scientifique, de près ou de loin, pour la réalisation de ce travail.

Enfin, je remercie ma famille et mes amis pour leur soutien, leur patience et leurs encouragements permanents qui m'ont permis d'avancer et d'atteindre cet objectif.

À tous, j'adresse mes plus sincères remerciements et ma profonde gratitude.

- Dédicace -

Avant toute chose, je remercie Dieu Tout-Puissant de m'avoir accordé la force, la patience et la persévérance nécessaires pour mener à bien ce travail.

Je dédie ce modeste travail à ma famille, qui a toujours été mon refuge, ma source de motivation et mon soutien inconditionnel tout au long de mon parcours académique.

À mon très cher père,

Aucun mot ne saurait exprimer pleinement ma profonde gratitude et mon immense reconnaissance envers toi. Merci pour tous les sacrifices que tu as consentis afin de m'offrir les meilleures conditions de réussite. Merci pour ton soutien constant, tes encouragements, ta confiance en moi et les valeurs que tu m'as transmises. Tu as toujours cru en mes capacités et tu as été une source de force et d'inspiration dans les moments les plus difficiles. Que ce travail soit le témoignage de mon amour, de mon respect et de ma reconnaissance éternelle.

À ma chère mère,

Pour ton amour infini, ta tendresse, tes prières sincères et ton soutien quotidien. Merci pour ta patience, ton affection et tous les efforts que tu as déployés pour mon bonheur et ma réussite. Que Dieu te protège et te récompense pour tout ce que tu as fait pour moi.

À mon cher mari,

Je t'adresse mes plus sincères remerciements pour ton amour, ta compréhension, ton soutien moral et ta présence à mes côtés tout au long de cette période. Merci pour tes encouragements, ta patience et la confiance que tu m'as accordée. Ton aide et ton affection ont été d'une valeur inestimable dans l'aboutissement de ce travail.

À mes frères et sœurs,

Pour leur affection, leur soutien et tous les moments de joie partagés. Merci d'avoir toujours été présents à mes côtés.

À tous mes amis et amies,

Pour leur amitié sincère, leurs encouragements, leur aide et les agréables moments passés ensemble durant mes années d'études. Votre présence a rendu ce parcours plus agréable et plus enrichissant.

Enfin, je dédie ce travail à toutes les personnes qui, de près ou de loin, ont contribué à ma formation, à mon éducation et à la réalisation de ce mémoire.

Avec toute mon affection, mon respect et ma profonde gratitude.

Table des matières

Introduction générale.....	1
Chapitre 1 : Intelligence Artificielle.....	3
1 Introduction.....	4
2 Intelligence Artificielle.....	4
2.1 Définition de l'intelligence artificielle	4
2.2 Historique de l'intelligence artificielle.....	4
3 Machine Learning	6
3.1 Définition de l'apprentissage automatique.....	6
3.2 Les phases de l'apprentissage automatique	6
3.3 Les types de l'apprentissage automatique.....	7
Apprentissage supervisé.....	7
Apprentissage non supervisé	8
Apprentissage par renforcement	8
3.4 Avantages et inconvénients de l'apprentissage automatique	9
4 Deep Learning.....	9
4.1 Qu'est-ce que l'apprentissage profond ?	9
4.2 Les applications de l'apprentissage profond.....	10
5 Les réseaux de neurones artificiels	10
5.1 Introduction sur les réseaux de neurones.....	10
5.2 Fonctionnement des réseaux de neurones.....	11
5.3 Réseaux de neurones convolutionnels CNN	12
5.4 L'architecture des réseaux de neurones convolutionnels.....	12
6 La Vision par ordinateur	16
6.1 Évolution et objectifs de la vision par ordinateur	16
6.2 Fonctionnement des systèmes de vision par ordinateur	16
6.3 Le traitement d'image	17
6.4 Étapes fondamentales du traitement d'image.....	18
6.5 Applications du traitement d'images	18
7 Conclusion	19
Chapitre 2 : Maladies des plantes	20
1 Introduction.....	21

2 L'agriculture et l'importance de la santé des plantes	21
3 Les maladies des plantes	22
3.1 Maladies fongiques	23
3.2 Maladies bactériennes	24
3.3 Maladies virales.....	24
4 Les approches et les techniques pour la détection des maladies des plantes.....	25
4.1 Méthodes traditionnelles	25
4.2 Méthodes basées sur l'intelligence artificielle	26
5 Conclusion	26
Chapitre 3 : Etat de L'art.....	28
1 Introduction.....	29
2 Travaux connexes	29
2.1 Mohanty et al. (2016)	29
2.2 Sladojevic et al. (2016)	30
2.3 Ferentinos (2018)	30
2.4 Too et al. (2019)	31
2.5 Zhang et al. (2018).....	31
2.6 Brahimi et al. (2017)	32
2.7 Howard et al. (2017) – MobileNet.....	32
2.8 Tan and Le (2019) – EfficientNet	33
3 Analyse comparative	33
3.1. Comparaison des datasets utilisés	34
3.2. Comparaison des contributions scientifiques	35
4 Limites des travaux existants	36
5 Conclusion	37
Chapitre 4 : Conception Et Implémentation.....	38
1 Introduction.....	39
2 Conception	39
2.1 CNN Baseline	40
2.1.1 Définition	40
2.1.2 Étapes du modèle CNN Baseline	40
2.2 ResNet50	42
2.2.1 Définition	42
2.2.2 Étapes du modèle ResNet50	42
2.3 EfficientNet	43
2.3.1 Définition	43

2.3.2 Étapes du modèle EfficientNet.....	43
3 Implémentation.....	45
3.1 Mise en place et la configuration de l'environnement	45
Langage python :	45
Visual Studio Code (VS Code) :	45
3.2 Les bibliothèques utilisées	46
TensorFlow :	46
Keras :	46
NumPy :	47
Scikit-learn.....	47
Matplotlib :	47
Pandas	47
Pillow	48
Streamlit	48
OpenCV (Open Source Computer Vision Library).....	48
Altair	48
3.3 Dataset utilisé	49
PlantVillage Dataset	49
4 Le choix des modèles.....	49
4.1 Etude comparative	50
4.1.1 Courbes d'entraînement (Accuracy / Loss)	50
4.1.2 Analyse des résultats.....	52
5 Conclusion	56
Conclusion générale et perspectives.....	57
Bibliographie.....	58

Liste des figures

Figure 1 : Les types de machine learning	7
Figure 2 : Avantages et inconvénients de machine Learning	9
Figure 3 : La relation entre l'intelligence artificiel et machine learning et deep learning	10
Figure 4 : neurone biologique et neurone artificiel	11
Figure 5 : Un réseau de neurones artificiel.....	12
Figure 6 : L'architecture d'un réseau de neurones convolutif (CNN).....	13
Figure 7 : Représentation sur la couche convolutive	14
Figure 8 : Les types de pooling	14
Figure 9 : La couche fully connected	15
Figure 10: Les domaines d'application de vision par ordinateur	17
Figure 11: Exemples de feuilles représentant des plantes malades - PlantVillage ensemble de données [29]	22
Figure 12: Le triangle des maladies des plantes	23
Figure 13: Feuille de tomate atteinte d'une maladie bactérienne (tache bactérienne).....	24
Figure 14: Exemple de maladie virale (virus de la mosaïque).	25
Figure 15: Différents types de maladies des plantes [35]	25
Figure 16: Organigramme général du modèle de détection et d'identification des maladies des plantes	40
Figure 17: Architecture de CNN BASELINE pour la détection des maladies des plantes.....	41
Figure 18: Architecture de RESNET50 pour la détection des maladies des plantes.....	43
Figure 19: Architecture de EFFICIENTNET pour la détection des maladies des plantes.....	44
Figure 20: Logo Python.....	45
Figure 21: logo VS Code.	45
Figure 22: logo TensorFlow	46
Figure 23: Logo Keras.....	46
Figure 24: Logo de la bibliothèque Scikit-learn	47
Figure 25: Logo de la bibliothèque Matplotlib.....	47
Figure 26: Logo de la bibliothèque Pandas	47
Figure 27: Logo de la bibliothèque Pillow.	48
Figure 28: Logo du framework Streamlit.....	48
Figure 29: Logo de la bibliothèque OpenCV	48
Figure 30: Logo de la bibliothèque Altair.	48
Figure 31: Exemple d'image du dataset PlantVillage — Maladie des feuilles de tomate (Tomato Leaf Disease)	49
Figure 32: Exemple de détection de la maladie du mildiou sur une feuille de tomate par le modèle de Deep Learning	50
Figure 33: Évolution des performances d'entraînement et de validation de modèle CNN Baseline.....	51
Figure 34: Évolution des performances d'entraînement et de validation de modèle EfficientNet	51
Figure 35 : Évolution des performances d'entraînement et de validation de modèle ResNet50	52
Figure 36: Comparaison des métriques de performance des modèles CNN Baseline, ResNet50 et EfficientNet.	53
Figure 37: Comparaison de l'accuracy des modèles évalués	54

Figure 38: Comparaison de la précision des modèles évalués.....	54
Figure 39: Comparaison du rappel (Recall) des modèles évalués	55
Figure 40: Comparaison du F1-score des modèles évalués	55

Liste des tableaux

Tableau 1 : L'histoire de l'IA	5
Tableau 2 : Caractéristiques des fonctions d'activations	16
Tableau 3 : Tableaux comparatif des datasets utilisés dans les travaux récents	35
Tableau 4 : Tableaux comparatif des contributions scientifiques	35
Tableau 5 : Tableaux comparatif des limites des travaux existants	36
Tableau 6 : Les informations des classes	53

Introduction générale

L'agriculture représente un secteur fondamental pour l'économie et la sécurité alimentaire mondiale. Elle joue un rôle essentiel dans l'approvisionnement en aliments, le développement économique. Cependant, les cultures agricoles sont constamment exposées à diverses maladies causées par des champignons, des bactéries ou des virus, ce qui entraîne une diminution importante de la qualité et du rendement des productions agricoles. Ces maladies peuvent provoquer des pertes économiques considérables pour les agriculteurs et menacer la disponibilité des ressources alimentaires.

Traditionnellement, la détection des maladies des plantes repose sur l'observation visuelle réalisée par des experts agricoles. Cette approche nécessite une grande expérience et demande souvent un temps important pour identifier correctement les symptômes présents sur les feuilles ou les fruits. De plus, les méthodes traditionnelles peuvent être coûteuses, subjectives et parfois inefficaces lorsqu'il s'agit de détecter des maladies à un stade précoce ou dans des environnements agricoles de grande taille. Les techniques classiques de traitement d'images et de Machine Learning présentent également certaines limites, notamment la nécessité d'extraire manuellement les caractéristiques pertinentes, ce qui réduit leur capacité d'adaptation à des données complexes et variées.

Face à ces limitations, l'intelligence artificielle, et plus particulièrement l'apprentissage profond (Deep Learning), offre aujourd'hui des solutions performantes pour la détection et l'identification des maladies des plantes. Les modèles de Deep Learning, tels que les réseaux de neurones convolutifs (CNN), ResNet50 et EfficientNet, sont capables d'apprendre automatiquement les caractéristiques importantes à partir des images, sans intervention manuelle. Ces approches permettent d'obtenir des résultats précis et rapides, même sur des ensembles de données volumineux et complexes. Grâce aux avancées récentes dans le domaine de la vision par ordinateur, ces modèles sont devenus des outils efficaces pour améliorer la surveillance des cultures et aider les agriculteurs dans la prise de décision.

L'objectif principal de ce projet est de développer une application intelligente capable de détecter et d'identifier automatiquement les maladies des plantes à partir d'images de feuilles en utilisant des techniques d'apprentissage profond.

Ce mémoire est organisé en plusieurs chapitres.

- Le premier chapitre présente les notions fondamentales nécessaires à la compréhension du sujet. Il introduit les concepts de l'intelligence artificielle, du Machine Learning, du Deep Learning, des réseaux de neurones artificiels ainsi que de la vision par ordinateur et du traitement d'images, qui constituent les bases théoriques de ce travail
- Le deuxième chapitre est consacré aux maladies des plantes. Il met en évidence l'importance de la santé des cultures dans le domaine agricole, présente les principales maladies pouvant affecter les plantes ainsi que leurs impacts sur la production agricole.
- Le troisième chapitre expose l'état de l'art relatif à la détection et à l'identification des maladies des plantes. Il présente les travaux de recherche existants, les datasets utilisés, les architectures de Deep Learning les plus courantes, ainsi qu'une analyse comparative des approches proposées dans la littérature.
- Enfin, Le quatrième chapitre décrit la conception, l'implémentation et l'expérimentation de la solution proposée. Il présente les modèles de Deep Learning retenus (CNN, ResNet50 et EfficientNet), les technologies utilisées, les différentes étapes de développement ainsi que l'étude comparative des résultats obtenus.

Chapitre 1 : Intelligence Artificielle

1 Introduction

L'intelligence artificielle (IA) a captivé l'imagination des chercheurs, des ingénieurs et du grand public depuis des décennies. Elle incarne à la fois une quête scientifique et une aspiration technologique, promettant de révolutionner notre façon de vivre, de travailler et d'interagir avec le monde qui nous entoure. À l'ère numérique actuelle, l'IA est devenue un pilier fondamental de nombreux secteurs, allant de la santé à la finance, de la production à l'éducation.

Ce chapitre consacré aux notions fondamentales en intelligence artificielle examine les concepts essentiels tels que l'apprentissage automatique, les réseaux de neurones et l'apprentissage profond. Grâce à ces disciplines, les machines peuvent acquérir des connaissances à partir de données, détecter des motifs et prendre des décisions de manière autonome. Les réseaux de neurones artificiels sont basés sur le fonctionnement du cerveau humain et jouent un rôle essentiel en simulant des processus cognitifs avancés.

2 Intelligence Artificielle

2.1 Définition de l'intelligence artificielle

L'intelligence artificielle, généralement abrégée par le sigle IA, elle a été définie de multiples manières et reste de ce fait un domaine dont il n'est pas facile de circonscrire précisément les contours ; alors l'intelligence artificielle est le terme utilisé pour décrire le développement des systèmes informatiques capables de réaliser des tâches qui nécessitent généralement l'intelligence humaine [1]. Comme était défini par l'un de ses créateurs, Marvin Lee Minsky : *« La construction de programmes informatiques qui effectuent des tâches pour lesquelles, pour l'instant, les êtres humains sont plus compétents, car elles impliquent des processus mentaux de haut niveau. Tels que l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critiquée »* (Minsky, 2004).

Afin d'atteindre une approche maximale du comportement humain, l'intelligence artificielle nécessite une grande quantité de données et une grande capacité de traitement.

2.2 Historique de l'intelligence artificielle

L'histoire de l'intelligence artificielle commence en 1943, lorsque Warren McCulloch et Walter Pitts publient l'article intitulé *« A Logical Calculus of Ideas Immanent in Nervous Activity »*. Ce texte expose le premier modèle mathématique de la construction d'un réseau de neurones par les chercheurs.

En 1950, deux étudiants de Princeton, Marvin Minsky et Dean Edmonds, vont développer *Snarc*, le premier ordinateur à réseau de neurones. La même année, le *Turing Test* est publié par Alan Turing et est toujours utilisé pour évaluer les IA. Les bases de l'intelligence artificielle, de sa vision et de ses objectifs sont basées sur ce test : reproduire ou simuler l'intelligence humaine dans les machines.

Cependant, ce n'est qu'en 1956 que John McCarthy prononcera pour la première fois le mot d'intelligence artificielle lors de la conférence « *Dartmouth Summer Research Project on Artificial Intelligence* ». À cette occasion, les chercheurs exposent les buts et la perspective de l'intelligence artificielle. De nombreuses personnes voient dans cette conférence le véritable début de l'intelligence artificielle telle qu'elle est connue.

De nombreuses années passent et les recherches sur l'intelligence artificielle se poursuivent. Arthur Samuel crée le concept de Machine Learning en 1959, alors qu'il travaillait chez IBM. En 1989, l'ingénieur français Yann Lecun développe le premier réseau de neurones capable de reconnaître des chiffres écrits à la main, ce qui donnera naissance au Deep Learning [2].

Voici le tableau (Tableau 1) récapitulatif de l'histoire de l'intelligence artificielle [2] :

Année	Événement	Description
1943	Article de Warren McCulloch et Walter Pitts	Publication de « A Logical Calculus of Ideas Immanent in Nervous Activity », présentant le premier modèle mathématique de réseau de neurones.
1950	Développement de Snarc	Marvin Minsky et Dean Edmonds développent Snarc, le premier ordinateur à réseau de neurones
1950	Publication du Turing Test	Alan Turing publie le Turing Test pour évaluer l'intelligence des IA, définissant les bases et objectifs de l'intelligence artificielle
1956	Conférence de Dartmouth	John McCarthy utilise pour la première fois le terme "intelligence artificielle", considérée comme le début officiel de l'IA
1959	Concept de Machine Learning	Arthur Samuel, travaillant chez IBM, crée le concept de Machine Learning.
1989	Développement du deep learning	Yann Lecun a mis au point le tout premier réseau de neurones capable de reconnaître des chiffres écrits à la main, donnant naissance au Deep Learning

Tableau 1 : L'histoire de l'IA

3 Machine Learning

3.1 Définition de l'apprentissage automatique

Le ML est un domaine de l'intelligence artificielle qui a été défini en 1959 par son pionnier Arthur Samuel comme « *le domaine d'étude qui permet aux ordinateurs d'acquérir la capacité d'apprendre sans être explicitement programmés à apprendre* » [3], ayant pour but de permettre aux ordinateurs d'acquérir des connaissances. Ce n'est pas un ordinateur intelligent au sens traditionnel, mais il permet aux ordinateurs d'exécuter des tâches en apprenant à partir de données plutôt qu'en suivant des instructions explicites. Contrairement à la programmation traditionnelle, où les règles sont définies manuellement par les programmeurs. Le machine Learning aborde des questions complexes dans lesquelles la programmation traditionnelle présente des limites [4].

Le principe fondamental du machine learning consiste à donner à un ordinateur un ensemble de données d'entraînement (ou *training set*), puis à lui donner la possibilité d'analyser ces données afin de déterminer des modèles et des relations. Après avoir mis en place le modèle, il peut servir à faire des prédictions ou des classifications sur de nouvelles données.

3.2 Les phases de l'apprentissage automatique

De manière générale, les étapes de l'apprentissage automatique, également connues sous le nom de cycle de vie d'un projet d'apprentissage automatique, sont les suivantes [5] :

- a. **Collecte et préparation des données** : consiste à collecter les données requises pour l'entraînement de modèle d'apprentissage automatique et le préparer pour une analyse ultérieure.
- b. **Choix du modèle** : il existe différents modèles d'apprentissage automatique, chacun ayant ses propres avantages et inconvénients en fonction du type de données et de la tâche réalisée.
- c. **Entraînement du modèle** : Le modèle est entraîné sur les données d'apprentissage afin de détecter les raisons et les liens entre les variables pour effectuer une tâche spécifique.
- d. **Évaluation du modèle** : Une fois que le modèle est formé, il est nécessaire d'évaluer sa précision et sa capacité à être généralisé à de nouvelles données en utilisant des données de test qui n'ont pas été utilisées pendant l'entraînement.
- e. **Utilisation du modèle** : Après avoir évalué et validé le modèle, il peut être employé afin de faire des prévisions et des prédictions sur de nouvelles données.

3.3 Les types de l'apprentissage automatique

Le machine Learning peut être catégorisée en plusieurs types principaux en fonction de la manière dont les données sont présentées à l'algorithme et de la façon dont il apprend à partir de ces données. Voici les principaux types de machine Learning (figure 1):




Figure 1 : Les types de machine learning

Apprentissage supervisé

L'apprentissage supervisé se caractérise par l'emploi d'ensembles de données étiquetées (*Labeled data*) afin de créer des algorithmes qui permettent de classer les données ou de prédire avec précision les résultats. Il s'agit de donner une signification aux données dans le cadre d'une question particulière. Le but de ce type d'apprentissage est de trouver la plus proche relation entre les entrées et les sorties observables dans les données [6].

En général, l'apprentissage supervisé est classé en deux grandes catégories : **la classification** et **la régression**.

a. Classification

La classification en apprentissage automatique est une approche d'analyse de données qui vise à déterminer à quelle catégorie ou classe, à partir d'un ensemble d'exemples (dont les catégories sont connues), appartient une nouvelle observation (Murphy, 2012) [7]. L'objectif de ce processus est de créer un modèle à partir de données d'entraînement, où chaque observation est décrite par un vecteur de caractéristiques et est liée à une classe. Ensuite, on peut utiliser le modèle ainsi acquis pour prédire la classe des nouvelles observations. La classification est essentielle dans divers domaines, comme la reconnaissance d'images, le diagnostic médical, la détection de spam, et bien d'autres encore.

b. Régression

La régression est une méthode de modélisation prédictive qui vise à établir une corrélation significative entre une variable dépendante et une ou plusieurs variables indépendantes, également connues sous le nom de variables cibles. Son objectif est de déterminer comment la variable dépendante change lorsque les variables indépendantes varient. Différentes méthodes de régression existent : linéaire, logistique, polynomiale, Ridge, Lasso et bien d'autres encore [8]. Par exemple : la prédiction du prix des maisons en fonction de caractéristiques telles que la superficie, le nombre de chambres, l'emplacement, etc.

Apprentissage non supervisé

Dans ce contexte, l'apprentissage consiste à identifier les groupes homogènes d'exemples présents dans les données. L'objectif est d'associer les données les plus similaires au sein d'un même groupe, tout en séparant celles jugées différentes dans des groupes distincts. En résumé, il s'agit de rechercher la distribution sous-jacente des exemples dans leur espace de description [9].

L'apprentissage non supervisé repose principalement sur les méthodes de regroupement (clustering).

Clustering

L'extraction de données et l'apprentissage automatique non supervisé utilisent l'analyse de cluster pour organiser des éléments similaires en sous-ensembles appelés "clusters" ou "groupes". Le clustering k-means est une méthode courante pour l'analyse de clusters qui vise à diviser un ensemble d'objets en clusters K de manière à réduire au minimum les distances carrées entre les objets et leur moyenne de cluster attribuée.

Deux méthodes fréquemment utilisées dans le domaine de l'apprentissage non supervisé sont le cluster hiérarchique et le cluster k-means, qui permettent de regrouper les points de données en différentes catégories. Tandis que le clustering k-means sépare les données en un nombre précis de clusters, le clustering hiérarchique crée une structure hiérarchisée similaire à un arbre pour décrire les liens entre les groupes [10].

Apprentissage par renforcement

La notion d'apprentissage par renforcement désigne une catégorie de problèmes d'apprentissage automatique qui vise à enseigner, à partir d'expériences successives, ce qu'il

faut faire pour trouver la solution optimale. Le système d'apprentissage peut interagir avec son environnement et réaliser des actions dans le cadre de l'apprentissage par renforcement.

Il reçoit en échange de ces actions une récompense, qui peut être positive si l'action était une bonne décision, ou négative si l'action était une mauvaise décision. Parfois, la récompense survient après une série d'actions prolongées [11]. L'apprentissage par renforcement trouve ses principales applications dans les jeux (échecs, go, etc.) et la robotique.

3.4 Avantages et inconvénients de l'apprentissage automatique

La figure ci-dessous (figure 2) met en évidence les avantages et les inconvénients de machine Learning :




Figure 2 : Avantages et inconvénients de machine Learning

4 Deep Learning

4.1 Qu'est-ce que l'apprentissage profond ?

Le Deep Learning est une discipline de l'intelligence artificielle qui est un sous ensemble de machine Learning (figure 3). Qui utilise des réseaux de neurones artificiels à plusieurs couches (d'où le terme "profond") afin de représenter des structures de données complexes. Ces réseaux de neurones profonds ont la capacité de tirer automatiquement des caractéristiques pertinentes des données brutes, ce qui permet de résoudre des problèmes complexes tels que la

reconnaissance d'images, le traitement du langage naturel et de nombreuses autres applications [12].

Ce terme fait référence à toutes les méthodes d'apprentissage automatique, c'est-à-dire une forme d'apprentissage basée sur des méthodes mathématiques, qui sont utilisées pour modéliser et représenter des données.




Figure 3 : La relation entre l'intelligence artificiel et machine learning et deep learning

4.2 Les applications de l'apprentissage profond

Le Deep Learning est largement utilisé dans de multiples domaines [13], incluant la reconnaissance d'images, la traduction automatique, les véhicules autonomes, le diagnostic médical avancé, les recommandations personnalisées, la modération automatique des réseaux sociaux, ainsi que la prédiction financière et le trading automatisé. Il est également appliqué dans l'identification de défauts sur des pièces, la détection de malwares et de fraudes, la création de chatbots pour des interactions conversationnelles, l'exploration spatiale, ainsi que dans le développement de robots intelligents. Ces applications témoignent de la capacité du Deep Learning à transformer divers secteurs grâce à ses capacités d'analyse et de prise de décision basées sur les données.

5 Les réseaux de neurones artificiels

5.1 Introduction sur les réseaux de neurones

Même si de nombreux algorithmes du machine Learning sont disponibles pour résoudre les problèmes de données, les ANN (*Artificial Neural Network*) sont de plus en plus appréciées

dans le domaine du Deep Learning en raison de leur aptitude à trouver des modèles dans des ensembles de données volumineuses et complexes qui ne peuvent pas être interprétés par des êtres humains habituels. La partie neuronale du nom désigne la similitude de l'architecture du modèle avec l'anatomie du cerveau humain. Cette section vise à reproduire la capacité d'un individu à utiliser des données historiques pour apprendre en transférant des bits de données d'un neurone à l'autre jusqu'à ce qu'un résultat soit obtenu [14]. Dans ANN, les dendrites des réseaux neuronaux biologiques correspondent aux entrées, les noyaux cellulaires aux nœuds, les synapses aux poids et les axons représentent les sorties (figure 4).




Figure 4 : neurone biologique et neurone artificiel

5.2 Fonctionnement des réseaux de neurones

Les réseaux neuronaux artificiels sont des modèles inspirés du cerveau humain composés de plusieurs couches interconnectées (figure 5), chacune recevant et interprétant les informations provenant de la couche précédente.

Selon Kohonen [15], les réseaux de neurones artificiels sont définis comme des réseaux connectés à grande échelle en parallèle avec des éléments simples (souvent adaptatifs) et leur structure hiérarchique. Il est prévu qu'ils interagissent avec les objets du monde réel de la même façon que les systèmes nerveux cellulaires.

Au sein d'un réseau neuronal, l'information se propage de l'entrée (*Input layer*) vers la sortie (*Output layer*), en passant par différentes couches intermédiaires appelées couches cachées (*Hidden layers*).




Figure 5 : Un réseau de neurones artificiel

5.3 Réseaux de neurones convolutionnels CNN

Les réseaux de neurones convolutifs sont une catégorie distincte de réseaux neuronaux. Cependant, les CNN sont spécialement conçues pour traiter les images en provenance. Et ont été largement utilisés dans une variété d'applications, allant de la classification d'images à la détection d'objets et la segmentation sémantique [16].

La dénomination « Réseau de neurones à convolution » signifie que le réseau utilise une opération mathématique connue sous le nom de convolution plutôt que la multiplication matricielle générale dans au moins une de leurs couches.

5.4 L'architecture des réseaux de neurones convolutionnels

La topologie de CNN est structurée en plusieurs étapes d'apprentissage, qui incluent une combinaison de trois types de couches spécifiques la couche de **convolution**, la couche de **pooling** et la couche de **fully connected** (figure 6).




Figure 6 : L'architecture d'un réseau de neurones convolutif (CNN)

➤ La couche de convolution :

La convolution est la première couche à extraire des entités d'une image d'entrée, C'est la partie du CNN qui effectue les calculs pour obtenir des informations utiles à partir des données de l'image. Chaque couche convolutive est composée de filtres qui peuvent être appris par le réseau au cours de l'entraînement, appelés noyaux. Tandis qu'une image colorée peut être perçue comme une matrice de pixels tridimensionnelle, un filtre est un tableau de poids bidimensionnel qui est glissé à travers les champs réceptifs de l'image afin de déterminer si une caractéristique est présente ou non.

En général, le filtre, qui est généralement une matrice de dimensions 3x3 (mais la taille peut varier), est appliqué à une image. Par la suite, le filtre est décalé d'un nombre n de pixels, également connu sous le nom de *stride* (pas). La valeur du pas peut être n'importe quel nombre entier, et un pas plus grand diminue la matrice de sortie, et Le rembourrage (*padding*) est souvent utilisé pour préserver la taille spatiale de l'entrée et éviter la réduction excessive de la taille de la sortie. Le produit des points est calculé en fonction des pixels d'entrée et les poids du filtre (figure 7). Ce processus se poursuit jusqu'à la fin de la matrice d'entrée. Chaque sortie de points génère une matrice connue sous le nom de carte d'activation ou carte de caractéristiques (*features map*). La carte des caractéristiques renferme les données extraites de l'image en utilisant le filtre approprié [17].




Figure 7 : Représentation sur la couche convolutive

- **La couche de pooling :**

La couche de pooling est souvent placée entre deux couches de convolution. Mise en place d'une opération de pooling qui est un processus de discrétisation à base d'échantillon. C'est la diminution de la taille des images tout en maintenant leurs caractéristiques essentielles. Afin d'accomplir cela, l'image est divisée en cellules régulières de 2×2 pixels qui ne se chevauchent pas, ou en cellules de 3×3 pixels séparées par un pas de 2 pixels. Par la suite, nous mettons en œuvre la méthode de pooling (figure 8). Les résultats obtenus sont identiques à ceux des entrées, mais de taille inférieure. La mise en place de la couche de pooling diminue le nombre de paramètres et de calculs dans le réseau. Cela permet d'améliorer ces performances et d'éviter le sur-apprentissage [18].

Il existe deux types de pooling :

- **Pooling maximal :** qui prend le pixel qui a la valeur maximale entre tous les pixels de la sélection.
- **Pooling moyen :** qui prend la moyenne de tous les pixels de la sélection.




Figure 8 : Les types de pooling

- **La couche de fully connected :**

La couche entièrement connectée, est une composante clé des réseaux de neurones, y compris des réseaux de neurones convolutionnels (CNN). Contrairement aux couches de convolution et de pooling, où les connexions entre les neurones sont locales et partagées, chaque neurone dans une couche entièrement connectée est connecté à tous les neurones de la couche précédente.

Ce type de couche reçoit un vecteur en entrée et génère un nouveau vecteur en sortie supplémentaire afin de classifier l'image en entrée du réseau. En retournant un vecteur de dimension N, où N représente le nombre total de classes dans notre problème de classification d'images. Chaque composant du vecteur représente la probabilité que l'image en entrée d'appartenir à une classe [19].




Figure 9 : La couche fully connected

Les fonctions d'activation

La fonction d'activation dans un réseau de neurones est utilisée pour introduire de la non-linéarité dans les sorties des neurones, ce qui permet au réseau de modéliser des relations complexes et non linéaires entre les entrées et les sorties. Elle détermine essentiellement si un neurone est "activé" ou "désactivé" en fonction de sa sortie [20] :

Le tableau suivant liste les fonctions d'activation couramment utilisées dans les réseaux de neurones :

Fonction	Formule	Caractéristiques
ReLU	$f(x) = \max(0, x)$	- apporte une solution à la disparition du gradient. -résoudre le problème de la saturation des neurones

LeakyReLU	$f(x) = \max(0.1x, x)$	- Réduit le problème des neurones morts
Sigmoïde	$f(x) = \frac{1}{1 + e^{-x}}$	-utilise pour la classification binaire
Tanh	$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	-centrer les valeurs autour de 0
Softmax	$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$	-Utilisé pour la classification multi-classes

Tableau 2 : Caractéristiques des fonctions d'activations

6 La Vision par ordinateur

6.1 Évolution et objectifs de la vision par ordinateur

La vision par ordinateur est une combinaison de méthodes développées pour l'analyse automatique d'images. Au début de 1964, les spécialistes de l'IA se sont intéressés à la possibilité de reproduire les capacités sensorielles des êtres humains. Puisque la vision constitue le sens humain le plus essentiel, il est logique que de nombreux travaux aient été réalisés dans cette direction. Le point commun de ces créations est de chercher à donner une signification aux images, ou bien extraire la sémantique à partir des informations enregistrées sur une base de données [21]. La vision par ordinateur imite la capacité du cerveau humain à comprendre une scène en mouvement à partir des signaux visuels, notamment pour repérer rapidement des objets et anticiper leurs déplacements.

6.2 Fonctionnement des systèmes de vision par ordinateur

La vision par ordinateur fait référence à l'aspect de l'intelligence et la perception artificielle lié au canal visuel. Un système de vision par ordinateur a pour mission de fournir des informations au système sur le monde qui l'entoure, en utilisant des capteurs tels que des caméras vidéo. Chaque image est représentée par une matrice de pixels à deux dimensions. Un système de vision par ordinateur analyse les données de niveau d'abstraction bas du flux vidéo afin d'en extraire des données de niveau d'abstraction plus élevé [22].

La figure suivante illustre divers domaines d'application de la vision par ordinateur, tels que la reconnaissance faciale, la conduite autonome, la surveillance de sécurité et l'analyse médicale.



Figure 10: Les domaines d'application de vision par ordinateur

6.3 Le traitement d'image

Le traitement d'images est un aspect essentiel de la vision par ordinateur, englobe l'intersection de l'informatique et des mathématiques appliquées. Son objectif est de manipuler des images à travers diverses techniques, aboutissant à une nouvelle image, une version modifiée ou même simplement un paramètre associé à l'image originale. Ces résultats peuvent ensuite être utilisés pour une analyse supplémentaire ou pour éclairer les processus décisionnels.

Il revêt une importance immense dans diverses applications pratiques telles que la robotique, les véhicules autonomes et la reconnaissance d'objets. En permettant la transformation et la manipulation simultanée de nombreuses images, le traitement d'images facilite l'extraction d'informations précieuses à partir de ces ensembles de données visuelles [23].

6.4 Étapes fondamentales du traitement d'image

Les étapes fondamentales du traitement d'image impliquent plusieurs processus qui transforment une image brute en une version utile pour une analyse ou une application spécifique. Voici les principales étapes [24] :

- a. **Acquisition** : La première étape du processus de traitement d'images est toujours l'acquisition d'images, car sans elles, aucun traitement n'est réalisable. On peut définir l'acquisition d'images de manière générale comme l'opération de récupération d'une image provenant d'une source, généralement matérielle, pour la transmettre à tous les processus qui doivent suivre.
- b. **Prétraitement** : Le prétraitement est une étape cruciale dans le traitement d'images, car il prépare l'image brute pour les étapes ultérieures d'analyse et d'interprétation. L'objectif est de nettoyer et d'améliorer l'image de manière à faciliter la segmentation, l'extraction de caractéristiques et la reconnaissance. Il peut s'agir de la correction d'illumination, le redimensionnement et la réduction de bruit.
- c. **Segmentation** : La segmentation d'images est une étape essentielle dans le domaine du traitement d'images et de la vision par ordinateur, qui implique de séparer une image en ensemble différent des régions ou segments qui sont homogènes en fonction de certains critères de similarité. La segmentation vise principalement à rendre la représentation d'une image plus claire et plus accessible à l'analyse en simplifiant ou en modifiant sa représentation.
- d. **Analyse et interprétation** : Une fois que la segmentation d'une image a été réalisée, chaque région est représentée et décrite de manière appropriée pour un traitement informatique ultérieur. L'objectif de l'interprétation et l'analyse d'image est de repérer et d'évaluer diverses cibles présentes dans une image afin de récolter des informations pertinentes. On définit une cible comme étant toute structure ou objet visible dans une image.

6.5 Applications du traitement d'images

Le traitement d'images est une technologie devenue un instrument puissant pour améliorer la qualité visuelle et extraire des données importantes ou des informations significatives et automatiser des processus complexes dans divers domaines, Voici quelques-uns des principaux avantages du traitement d'images, quel que soit le domaine d'activité [25] :

- Il permet la disposition de l'image numérique dans le format désirée (image améliorée, radiographie, négative photo, IRM, etc.). Cela favorise l'amélioration des images afin de faciliter leur interprétation humaine.
- Le traitement et l'extrait des images peuvent permettre à la machine d'interpréter les informations.
- Il permet la possibilité de manipuler les pixels de l'image afin d'obtenir la densité et le contraste désirés.
- Les images peuvent être facilement stockées et récupérées.
- Il facilite la diffusion électronique des images vers des fournisseurs externes.

Permettre de détecter et de suivre en temps réel les objets d'intérêt d'une façon automatique.

7 Conclusion

En conclusion, ce chapitre nous a introduits aux bases essentielles de l'intelligence artificielle, en soulignant le potentiel révolutionnaire de machine Learning, de Deep Learning et des réseaux de neurones.

Le chapitre suivant présentera l'importance de l'agriculture, les principales maladies des plantes ainsi que leurs impacts sur la santé des cultures et la production agricole.

Chapitre 2 :

Maladies des plantes

1 Introduction

Il est incontestable que la production agricole joue un rôle crucial dans le développement économique. Cependant, les cultures peuvent être exposées à des agents pathogènes pendant leur phase de croissance, ce qui risque de diminuer la productivité ou d'entraîner la mort des plantes. Pour réduire les pertes économiques, un diagnostic exact des maladies des plantes est essentiel et l'intelligence artificielle est souvent employée pour cela. Des actions de gestion et de contrôle des maladies, incluant une surveillance constante des cultures et un diagnostic précis, sont indispensables pour atténuer les effets néfastes des maladies végétales sur la production alimentaire et l'efficacité économique. Ce chapitre se concentrera sur le secteur de l'agronomie, en particulier sur les plantes et les différentes affections qui peuvent leur nuire ainsi que les techniques et méthodes utilisées pour l'identification et la détection des maladies des plantes.

2 L'agriculture et l'importance de la santé des plantes

L'émergence de maladies dans les plantes affecte défavorablement la production agricole. Si les problèmes phytosanitaires ne sont pas détectés à temps, l'insécurité alimentaire risque de s'accroître [26]. L'identification précoce constitue le fondement d'une prévention et d'un contrôle performant des maladies végétales, et occupe une place cruciale dans la gestion et la prise de décisions relatives à la production agricole. L'identification des maladies végétales a été une problématique essentielle ces dernières années.

Les végétaux atteints d'une maladie montrent souvent des signes ou des dégâts manifestes sur les feuilles, les tiges, les fleurs ou les fruits. Typiquement, chaque maladie ou parasite exhibe un schéma distinct qui peut être exploité pour identifier spécifiquement les irrégularités. En général, l'identification des maladies des plantes s'effectue principalement par l'observation des feuilles, et la majorité des symptômes de ces maladies tendent à se manifester sur les feuilles [27]. Effectivement, la condition d'une plante se reflète dans la couleur, la texture, les contours et la dimension de ses feuilles. Comme le démontre la figure 13, toute modification de ces paramètres indique une dégradation de la santé de la plante. Dans la majorité des situations, on fait appel à des spécialistes en agriculture et sylviculture pour détecter les maladies et nuisibles affectant les arbres fruitiers, s'appuyant sur leur expertise. Non seulement cette approche est subjective, elle est également longue, laborieuse et peu efficace.

Durant la phase d'identification, les agriculteurs moins chevronnés courent le risque de mal évaluer et de recourir à des médicaments de manière aveugle. L'impact sur la qualité et

l'efficacité conduira aussi à une contamination environnementale, entraînant des dommages économiques superflus. Face à ces enjeux, l'étude de l'emploi des méthodes de traitement d'images et d'intelligence artificielle pour la détection anticipée des pathologies végétales est devenue un domaine de recherche en pleine expansion grâce aux avancées technologiques des instruments d'acquisition et de traitement [28].



Figure 11: Exemples de feuilles représentant des plantes malades - PlantVillage ensemble de données [29]

3 Les maladies des plantes

Les maladies phytopathologiques constituent l'une des principales raisons de la réduction des récoltes à l'échelle internationale. D'après les études, les seules infections fongiques peuvent causer la destruction d'un tiers de la production alimentaire annuelle.

Les maladies des plantes peuvent être soit attribuées à un agent biotique, c'est-à-dire vivant, soit être dues à des facteurs environnementaux abiotiques comme la grêle, les gelées printanières, les conditions climatiques, les dommages causés par des produits chimiques, etc. Ces dernières présentent un risque moindre et peuvent être évitées, car elles ne sont ni infectieuses, ni transmissibles [30]. En revanche, les maladies biotiques représentent le plus grand danger et occasionnent les dommages les plus importants aux cultures.

Un principe essentiel en phytopathologie est le Triangle des Maladies, qui déclare qu'une maladie ne peut se produire que si trois éléments cruciaux sont réunis :

- 1- **Un hôte sensible** : Une plante vulnérable à l'infection.
- 2- **Un agent pathogène** : L'agent causal de la maladie.
- 3- **Un environnement favorable** : Des conditions environnementales qui favorisent le développement de la maladie.

L'infection débute lorsque l'agent pathogène réussit à infiltrer la plante et à atteindre certains tissus propices à l'infection. Lorsque les conditions environnementales sont propices, le microbe commence à proliférer et à se diffuser, provoquant des manifestations claires de la maladie.

Les plantes réagissent aux maladies de trois manières principales :

- 1- **Surdéveloppement des tissus** : Formation de galles, gonflements ou enrroulements des feuilles.
- 2- **Sous-développement des tissus** : Nanisme, chlorose (manque de chlorophylle) ou développement incomplet des organes.
- 3- **Mort des tissus** : Brûlure, taches foliaires, flétrissement et chancres [31].




Figure 12: Le triangle des maladies des plantes

On les classe les maladies des plantes généralement en trois catégories principales, à savoir:

3.1 Maladies fongiques

Les maladies provoquées par des champignons microscopiques constituent la classe la plus commune de pathologies végétales. Elles sont dues à des champignons ou des êtres similaires, et représentent approximativement 85% des affections phytopathologiques. Les spores de champignons, étant très petites et légères, ont la capacité de se propager dans l'air et d'infecter d'autres plantes ou arbres [32].

Elles ont tendance à se développer dans des conditions d'humidité élevée et de température propice. Les signes les plus fréquemment observés incluent la formation de taches sombres ou noires sur les feuilles, l'exsudation d'humidité, l'apparition de moisissures, ainsi que la décomposition des fruits ou des racines. L'oïdium, le mildiou et la rouille sont quelques-unes des maladies les plus célèbres. Si elles ne sont pas identifiées à temps, ces maladies peuvent se répandre vite et causer des pertes significatives dans le domaine agricole.



Figure 13: Feuille de tomate atteinte d'une maladie bactérienne (tache bactérienne).

3.2 Maladies bactériennes

Des bactéries pathogènes qui s'introduisent dans les tissus végétaux via des lésions ou des orifices naturels sont à l'origine des maladies bactériennes. On les identifie généralement par des taches d'humidité, des lésions nécrotiques, la présence de chancres ou un flétrissement des végétaux. Ces pathologies peuvent se diffuser via l'eau, le vent, les insectes ou encore les instruments agricoles infectés. Parmi les exemples habituels, on compte le feu bactérien et la tache bactérienne des feuilles [33].

3.3 Maladies virales

Ces maladies sont dues à des virus et sont classées comme le type le plus rare parmi les pathologies végétales. Toutefois, une fois qu'elles sont contaminées, aucun remède chimique ne permet d'éradiquer un virus et il est nécessaire d'éliminer toutes les plantes suspectes pour stopper la propagation de l'infection. On observe fréquemment des décolorations, des motifs en mosaïque, des altérations des feuilles, un ralentissement de croissance et une diminution de la productivité. L'infection se propage principalement par le biais d'insectes vecteurs comme les pucerons ou les aleurodes. Le virus de la mosaïque est l'une des maladies virales les plus reconnues [34].



Figure 14: Exemple de maladie virale (virus de la mosaïque).

La figure 15 présente les trois catégories de maladies introduites ainsi que les symptômes associés à chacune d'elles :




Figure 15: Différents types de maladies des plantes [35]

4 Les approches et les techniques pour la détection des maladies des plantes

4.1 Méthodes traditionnelles

Il existe plusieurs méthodes de classification des maladies végétales basées sur différents critères. Toutefois, une classification habituelle se fonde sur l'agent infectieux à l'origine de la maladie.

On fait généralement la distinction entre diverses sortes de maladies des plantes, notamment les maladies abiotiques, aussi connues sous le nom de maladies non infectieuses, et les maladies biotiques, qui sont infectieuses.

Les conditions environnementales défavorables comme les températures extrêmes ou l'excès/déficit d'humidité sont souvent à l'origine des maladies non transmissibles. Par ailleurs, elles peuvent être dues à la présence d'impuretés nuisibles dans l'atmosphère, notamment celles provenant d'activités industrielles telles que les usines chimiques ou métallurgiques situées à proximité. Ces maladies sont généralement causées par la composition physico-chimique défavorable du sol, souvent associée à une utilisation inappropriée des herbicides sur les champs. Ces illustrations mettent en évidence la nécessité de l'agriculture durable, non seulement pour la sauvegarde de l'environnement, mais également pour la viabilité économique des fermes agricoles.

Même une illumination insuffisante peut entraîner des effets défavorables, surtout pour les végétaux cultivés sous serre. Par ailleurs, les toxines dégagées dans le sol par certaines embryophytes (plantes supérieures) et champignons peuvent aussi être à l'origine de maladies affectant les cultures.

4.2 Méthodes basées sur l'intelligence artificielle

L'intelligence artificielle révolutionne de plus en plus le domaine de l'agriculture et se positionne comme un outil crucial pour unir efficacité économique et soutenabilité environnementale.

En utilisant des solutions qui unissent l'agriculture et l'apprentissage automatique, elle est en mesure d'améliorer la prévision des rendements tout en réduisant les coûts pour les exploitants.

Confrontée à des enjeux liés aux ressources naturelles, l'IA promeut une agriculture précise et procure au secteur agricole une prise de décision informée.

5 Conclusion

Dans ce chapitre, nous avons mis en lumière l'importance de la santé des végétaux en agriculture, ainsi que les maladies majeures susceptibles d'impacter les récoltes. Nous avons aussi détaillé les différentes sortes d'affections phytopathologiques, y compris les maladies dues à des champignons, des bactéries et des virus.

Comprendre ces affections est crucial afin de mettre en place des solutions efficaces pour leur détection et leur diagnostic. Le chapitre suivant approfondira cette thématique en mettant en lumière l'analyse des techniques et des méthodes employées pour la détection et l'identification des maladies végétales.

Chapitre 3 :

Etat de L'art

1 Introduction

Les affections des végétaux constituent une menace majeure pour la production agricole et la sûreté alimentaire. Pour identifier ces pathologies de façon précoce et efficace, diverses méthodes basées sur l'intelligence artificielle et le Deep Learning ont été suggérées par des chercheurs. Ce chapitre met en avant les travaux les plus notables effectués dans ce secteur, suivi d'une étude comparative des différentes propositions faites, ainsi que de leurs principales contraintes.

2 Travaux connexes

2.1 Mohanty et al. (2016)

Mohanty et al. (2016) ont présenté l'une des premières études les plus marquantes en détection des maladies des plantes à l'aide de l'apprentissage profond. Les auteurs ont étudié l'utilisation des Réseaux Neuronaux Convolutionnels (CNN) pour la classification à grande échelle des maladies des plantes.[36]

Leur méthode a consisté à former des architectures de CNN profondes, telles qu'AlexNet et GoogleNet, sur le jeu de données PlantVillage, qui comprend plus de 50 000 images de feuilles de plantes saines et malades provenant de plusieurs espèces de cultures.[36]

Les résultats de l'expérience ont montré que les modèles d'apprentissage profond surpassent nettement les méthodes traditionnelles d'apprentissage automatique. Les auteurs ont mentionné des précisions de classification dépassant 99% dans des conditions de laboratoire contrôlées, soulignant la capacité des CNN à apprendre automatiquement des caractéristiques visuelles distinctives à partir d'images brutes.[36]

Néanmoins, l'étude présente des limites notables, notamment en ce qui concerne la nature du jeu de données, qui comprend principalement des images prises dans des conditions contrôlées et avec des arrière-plans uniformes. Cela restreint la capacité de généralisation du modèle dans des environnements agricoles concrets, où les images sont fréquemment influencées par des éclairages changeants, du bruit et des arrière-plans complexes.[37]

Malgré ces contraintes, cette étude est perçue comme une référence majeure dans ce domaine, ayant eu une grande influence sur les recherches ultérieures concernant la détection des maladies des plantes basée sur l'apprentissage profond.

2.2 Sladojevic et al. (2016)

Sladojevic et al. (2016) ont proposé un système basé sur le CNN pour la reconnaissance automatique des maladies des plantes, en utilisant des images de feuilles recueillies sur de nombreuses sources en ligne. [38]

La recherche a adopté une stratégie d'apprentissage de bout en bout, permettant au modèle d'apprendre automatiquement des représentations de caractéristiques sans avoir besoin de l'extraction manuelle des caractéristiques. Le système a été élaboré pour identifier diverses pathologies des plantes à partir des symptômes visuels présents sur les images de feuilles.

Les résultats ont confirmé que les modèles basés sur CNN obtiennent de bonnes performances de classification, démontrant ainsi l'efficacité de l'apprentissage profond pour le diagnostic agricole en fonction des images.

Toutefois, l'étude est contrainte par la taille limitée et le faible niveau de diversité du jeu de données, qui pourrait affecter la robustesse du modèle dans des conditions réelles. De plus, le processus de formation a nécessité des ressources informatiques considérables. [38]

Dans l'ensemble, ce travail a confirmé le potentiel des CNN comme une solution efficace pour la détection automatisée des maladies des plantes.

2.3 Ferentinos (2018)

Ferentinos (2018) a conçu un cadre basé sur l'apprentissage profond pour la détection des maladies des plantes, utilisant plusieurs architectures CNN, y compris AlexNet, VGGNet et GoogleNe [37].

Cette étude a évalué ces modèles sur un grand ensemble de données d'images de feuilles de plantes recueillies sous des conditions à la fois contrôlées et partiellement réelles, offrant une diversité accrue par rapport aux travaux précédents.

Les résultats expérimentaux ont indiqué que les modèles basés sur le CNN ont atteint des performances de classification très élevées, certaines architectures atteignant des précisions supérieures à 99%. [37]

Les réseaux plus profonds tendent généralement à donner de meilleurs résultats grâce à leur capacité à apprendre des représentations de caractéristiques plus complexes.

Cependant, l'étude a mis en évidence des limites telles que le coût computationnel élevé. De plus, même avec une diversité accrue des ensembles de données, la variabilité totale du monde réel n'était toujours pas entièrement représentée.

Cette étude a démontré la grande capacité des architectures CNN à généraliser à travers différentes espèces de plantes et catégories de maladies.

2.4 Too et al. (2019)

Too et al. (2019) ont examiné l'efficacité de différentes architectures d'apprentissage profond pour la classification des maladies des plantes en utilisant l'apprentissage par transfert. [39] La recherche a mis en comparaison des modèles tels que VGG16, ResNet50, InceptionV3 et DenseNet.

La méthode se basait sur l'ajustement de réseaux pré-entraînés sur des ensembles de données à grande échelle tels que l'ImageNet, ce qui permettait une réutilisation efficace des caractéristiques pour les tâches de classification des maladies des plantes.

Les résultats ont montré que l'apprentissage par transfert améliore considérablement les performances, en particulier lorsque les données d'entraînement sont insuffisantes. [39] Parmi les modèles examinés, DenseNet a obtenu la meilleure précision, tandis que les architectures ResNet et Inception ont suivi de près.

Néanmoins, malgré leur performance impressionnante, ces modèles sont régulièrement gourmands en ressources informatiques et peuvent ne pas être adaptés à une mise en œuvre sur des systèmes limités en ressources ou en temps réel.

Cette recherche souligne l'apprentissage par transfert comme une stratégie particulièrement efficace pour améliorer la performance de détection des maladies des plantes.

2.5 Zhang et al. (2018)

Zhang et ses collaborateurs (2018) ont suggéré une méthode hybride associant la segmentation d'image et la classification basée sur CNN pour la détection des maladies des plantes [40].

La méthode commence par l'application de techniques de traitement d'image pour délimiter les zones affectées de la feuille, minimisant ainsi les interférences de fond. Les images segmentées sont ensuite transférées à un CNN pour la classification.

Les résultats ont démontré que la segmentation perfectionne la précision de la classification en concentrant le modèle sur des caractéristiques visuelles pertinentes et minimisant le bruit [40].

Toutefois, la mise en place d'une étape de segmentation supplémentaire accroît la complexité computationnelle, et les performances de la segmentation peuvent se détériorer en conditions d'éclairage changeantes ou face à des fonds complexes.

Cette recherche met l'accent sur la nécessité de combiner les techniques de prétraitement d'image avec les modèles d'apprentissage profond pour optimiser la performance de classification.

2.6 Brahimi et al. (2017)

Brahimi et al. (2017) ont conçu un système de classification basé sur CNN, ciblant les maladies des feuilles de tomate, à l'aide d'un jeu de données multi-classes.[41]

Pour améliorer la généralisation et minimiser le surapprentissage, le modèle a intégré des techniques d'augmentation de données telles que la rotation et le retournement.

Des résultats expérimentaux ont démontré que l'approche suggérée surpassait les méthodes traditionnelles d'apprentissage machine en termes de précision de classification.[41]

Toutefois, le modèle nécessitait un temps de formation considérable et des ressources informatiques importantes. De plus, son évaluation a été limitée à certains types de cultures, ce qui pourrait en restreindre l'applicabilité générale.

Cette étude a souligné l'importance de l'augmentation de données pour améliorer la performance des apprentissages profonds dans les tâches de classification des maladies des plantes.

2.7 Howard et al. (2017) – MobileNet

MobileNet, une architecture CNN légère conçue pour les applications de vision mobile et embarquée, a été présentée par Howard et al. (2017). [48] Bien qu'il n'ait pas été initialement conçu pour la détection des maladies végétales, il a été largement adopté dans les systèmes d'intelligence artificielle agricoles.

MobileNet repose sur des convolutions séparables en profondeur, permettant une réduction importante du nombre de paramètres et du coût computationnel. [42] Par rapport aux réseaux convolutionnels standards.

Cette architecture offre un compromis solide entre précision et efficacité, ce qui la rend appropriée pour les applications en temps réel et pour sa mise en œuvre sur des appareils mobiles.

Néanmoins, les modèles légers ont généralement une précision légèrement inférieure par rapport aux architectures plus profondes.

MobileNet est particulièrement adapté aux applications agricoles pratiques où les ressources informatiques sont limitées.

2.8 Tan and Le (2019) – EfficientNet

L'architecture CNN avant-gardiste EfficientNet a été conçue par Tan et Le (2019), qui présente une méthode de mise à l'échelle composée permettant de modifier uniformément la profondeur, la largeur et la résolution du réseau.[43]

EfficientNet parvient à obtenir une grande précision tout en préservant l'efficacité computationnelle, ce qui le rend tout à fait adapté à une vaste gamme de tâches de classification d'images, y compris la détection de maladies des plantes.

Le modèle a fait preuve d'une performance supérieure par rapport aux architectures traditionnelles comme ResNet et VGGNet, en particulier en matière de rapport précision-efficacité de calcul.[43]

Toutefois, EfficientNet nécessite un réglage précis et peut s'avérer relativement complexe à mettre en œuvre pour les débutants.

Ce travail constitue une avancée marquante dans la conception d'architectures d'apprentissage profond efficaces et évolutives pour des applications dans le monde réel.

3 Analyse comparative

La littérature examinée souligne des progrès significatifs dans la détection des maladies des plantes, notamment par l'intégration de techniques d'apprentissage profond. Néanmoins, chaque méthode possède des points forts et des contraintes spécifiques, qui sont influencés par des facteurs tels que l'architecture du modèle, la qualité du jeu de données et le contexte d'application.

Les méthodes traditionnelles d'apprentissage automatique, comme les Machines à vecteurs de support (MVS) et les k-voisins les plus proches (k-NN), reposent grandement sur l'extraction de caractéristiques conçue manuellement [50]. Bien que ces techniques soient assez simples et efficaces sur le plan computationnel, elles présentent une robustesse limitée et une généralisation insatisfaisante lorsqu'elles sont mises en œuvre dans des conditions agricoles réelles.

En revanche, les méthodes d'apprentissage profond, en particulier les réseaux de neurones convolutionnels (CNN), ont montré une performance supérieure en apprenant de manière autonome les représentations d'attributs directement à partir des données d'images brutes [36]. Des études telles que celle de Mohanty et al. (2016) et de Ferentinos (2018) affirment des taux d'exactitude extrêmement élevés, souvent supérieurs à 99% dans des conditions expérimentales maîtrisées [42][44]. Toutefois, ces résultats sont souvent atteints en utilisant des ensembles de données soigneusement élaborés, ce qui restreint leur efficacité dans les situations du monde réel.

Les techniques d'apprentissage par transfert, basées sur des architectures comme VGG16, ResNet ou Inception, offrent une solution pragmatique en exploitant des modèles pré-entraînés [39]. Ces méthodes renforcent la précision et diminuent le temps de formation, notamment dans les situations où les données étiquetées sont limitées. Cependant, ils demeurent souvent gourmands en calculs et nécessitent des ressources matérielles importantes.

Des architectures légères telles que MobileNet répondent aux contraintes de calcul en diminuant la complexité du modèle et en permettant son déploiement sur des systèmes mobiles et embarqués [42]. Bien que ces modèles offrent une inférence plus rapide et une consommation de ressources réduite, il se peut qu'ils connaissent une légère baisse de précision dans la classification par rapport aux réseaux plus profonds.

Des architectures plus récentes, à l'instar d'EfficientNet, visent à atteindre un équilibre idéal entre précision et efficacité en adoptant des stratégies de scaling composé [43]. Ces modèles ont montré des performances de pointe tout en conservant un coût de calcul relativement faible, ce qui les rend adaptés à des applications concrètes.

En somme, la comparaison met en évidence un compromis essentiel entre la précision, la complexité de calcul et la possibilité de mise en œuvre dans le monde réel. Ainsi, le choix d'un modèle adapté repose sur les besoins spécifiques de l'application, notamment les attentes de performance, les contraintes matérielles et les conditions de déploiement.

3.1. Comparaison des datasets utilisés

Référence	Dataset utilisé	Type de données	Conditions d'acquisition	Observation
Mohanty et al. (2016)	PlantVillage	Images de feuilles saines et malades	Conditions contrôlées, fond uniforme	Dataset large mais peu représentatif du terrain réel

Sladojevic et al. (2016)	Images collectées depuis Internet	Images de feuilles malades	Conditions variables	Plus proche de la réalité, mais diversité limitée
Ferentinos (2018)	Dataset de feuilles de plantes	Images de plusieurs espèces végétales	Conditions contrôlées et partiellement réelles	Dataset plus diversifié que les premiers travaux
Too et al. (2019)	PlantVillage	Images de feuilles	Conditions contrôlées	Utilisé pour comparer plusieurs modèles pré-entraînés
Zhang et al. (2018)	Images de feuilles malades	Images segmentées	Conditions variables	Utilisation de la segmentation pour réduire le bruit
Brahimi et al. (2017)	Dataset de feuilles de tomate	Images de maladies de tomate	Conditions contrôlées	Limité à une seule culture
Howard et al. (2017)	ImageNet	Images générales	Dataset généraliste	Architecture utilisée ensuite dans plusieurs applications agricoles
Tan and Le (2019)	ImageNet	Images générales	Dataset généraliste	Architecture efficace utilisée pour plusieurs tâches de classification

Tableau 3 : Tableaux comparatif des datasets utilisés dans les travaux récents

3.2. Comparaison des contributions scientifiques

Référence	Contribution principale
Mohanty et al. (2016)	Démonstration de l'efficacité du Deep Learning pour la détection des maladies des plantes à partir d'images de feuilles
Sladojevic et al. (2016)	Proposition d'un système CNN end-to-end pour reconnaître automatiquement les maladies des plantes
Ferentinos (2018)	Évaluation de plusieurs architectures CNN sur un grand dataset de maladies de plantes
Too et al. (2019)	Comparaison de plusieurs modèles pré-entraînés avec transfert learning
Zhang et al. (2018)	Combinaison de la segmentation d'image avec la classification par CNN
Brahimi et al. (2017)	Application des CNN à la détection des maladies de la tomate avec augmentation des données
Howard et al. (2017)	Introduction d'une architecture légère adaptée aux systèmes mobiles et embarqués
Tan and Le (2019)	Proposition d'EfficientNet, une architecture efficace basée sur le compound scaling

Tableau 4 : Tableaux comparatif des contributions scientifiques

4 Limites des travaux existants

Malgré des avancées importantes dans la détection des maladies des plantes grâce à l'apprentissage profond, plusieurs problèmes restent encore non résolus.

En premier lieu, de nombreuses études actuelles s'appuient sur des ensembles de données rassemblés dans des conditions de laboratoire maîtrisées, à l'instar du dataset PlantVillage [37]. Ces ensembles de données possèdent généralement des fonds uniformes et une lumière parfaite, ce qui ne dépeint pas fidèlement les environnements agricoles réels. Par conséquent, les modèles formés sur ces données pourraient avoir une performance insatisfaisante lorsqu'ils sont utilisés dans des conditions de terrain.

De deux, les architectures de deep learning à haute performance comme VGGNet, ResNet, et Inception demandent des ressources computationnelles importantes tant pour l'entraînement que pour l'inférence [43]. la limite leur utilisation dans des environnements ayant des capacités matérielles limitées, comme les zones rurales ou les milieux à faibles ressources.

En troisième lieu, même si les modèles légers comme MobileNet permettent de diminuer le coût computationnel, ils présentent souvent un compromis au niveau de la précision [44]. Il reste crucial de trouver l'équilibre optimal entre l'efficacité et la performance dans ce domaine.

De plus, de nombreuses études antérieures se sont essentiellement concentrées sur la précision de la classification, en négligeant d'autres éléments cruciaux tels que l'interprétabilité du modèle, sa capacité à résister au bruit et sa performance en temps réel.

Référence	Limites principales
Mohanty et al. (2016)	Utilisation d'images prises dans des conditions contrôlées, limitant la généralisation au terrain réel
Sladojevic et al. (2016)	Dataset relativement limité et besoin de ressources de calcul importantes
Ferentinos (2018)	Coût de calcul élevé et temps d'entraînement important
Too et al. (2019)	Modèles performants mais souvent lourds pour un déploiement en temps réel
Zhang et al. (2018)	Étape de segmentation supplémentaire qui augmente la complexité du système
Brahimi et al. (2017)	Étude limitée aux maladies de la tomate
Howard et al. (2017)	Légère baisse de précision par rapport aux modèles profonds plus complexes
Tan and Le (2019)	Modèle plus complexe à configurer et nécessitant un réglage précis des paramètres

Tableau 5 : Tableaux comparatif des limites des travaux existants

5 Conclusion

En résumé, ce chapitre a offert une revue exhaustive des recherches existantes sur la détection des maladies des plantes en utilisant à la fois des approches traditionnelles d'apprentissage automatique et d'apprentissage profond. L'étude a mis en évidence les atouts et les contraintes des différentes techniques, y compris les modèles basés sur les réseaux de neurones convolutionnels, les stratégies d'apprentissage par transfert, et les architectures peu gourmandes en ressources.

L'étude comparative a démontré que ces méthodes ont considérablement surpassé les méthodes traditionnelles en termes de précision et de capacité de représentation des caractéristiques. Néanmoins, des problèmes liés au coût computationnel, aux limites des ensembles de données et à l'applicabilité dans le monde réel demeurent des préoccupations majeures. Le chapitre suivant se concentrera sur la conception et l'implémentation pratique d'un système de détection et d'identification des maladies des plantes basé sur CNN, EfficientNet et ResNet50.

Chapitre 4 : Conception Et Implémentation

1 Introduction

Dans ce chapitre, nous présentons l'implémentation du système de détection et d'identification des maladies des plantes basé sur l'apprentissage profond. Nous détaillons les technologies utilisées, les modèles implémentés, ainsi que les différentes expérimentations réalisées afin d'évaluer les performances du système proposé. Une étude comparative entre plusieurs architectures de Deep Learning est également effectuée pour identifier le modèle le plus performant.

2 Conception

Pour répondre à cette problématique, une approche basée sur l'apprentissage profond (Deep Learning) a été adoptée en utilisant plusieurs modèles de classification d'images, notamment CNN, ResNet50 et EfficientNet. Les modèles ont été entraînés sur un dataset de feuilles de plantes malades afin d'apprendre automatiquement les caractéristiques visuelles associées aux différentes maladies. Une étude comparative a ensuite été effectuée à l'aide de plusieurs métriques d'évaluation telles que l'Accuracy, le Recall, la Précision et le F1-Score afin d'identifier le modèle le plus performant dans chaque scénario. Enfin, les modèles retenus ont été intégrés dans une application web interactive développée avec Streamlit permettant de charger une image, afficher les prédictions, visualiser les meilleures probabilités de classification et consulter les résultats de manière claire, moderne et intuitive.




Figure 16: Organigramme général du modèle de détection et d'identification des maladies des plantes

Dans ce qui suit, nous allons détailler l'ensemble d'étapes du processus de traitement :

2.1 CNN Baseline

2.1.1 Définition

Le modèle CNN Baseline est un réseau de neurones convolutif simple utilisé comme modèle de référence. Il permet d'extraire automatiquement les caractéristiques visuelles importantes des images, telles que les formes, les taches, les couleurs et les textures présentes sur les feuilles.

2.1.2 Étapes du modèle CNN Baseline

Entrée de l'image : L'image de la feuille est chargée puis redimensionnée.

Prétraitement : Les pixels de l'image sont normalisés afin d'avoir des valeurs comprises entre 0 et 1.

Extraction des caractéristiques : Des couches convolutionnelles détectent les éléments visuels importants comme les contours, les taches et les motifs de maladie.

Réduction de dimension : Les couches de pooling réduisent la taille des cartes de caractéristiques tout en conservant les informations importantes.

Classification Les caractéristiques extraites sont envoyées vers des couches entièrement connectées.

Prédiction finale : La couche Softmax fournit la probabilité de chaque classe, puis le système choisit la classe ayant la probabilité la plus élevée.




Figure 17: Architecture de CNN BASELINE pour la détection des maladies des plantes

2.2 ResNet50

2.2.1 Définition

ResNet50 est un modèle profond composé de 50 couches. Il est basé sur le principe des connexions résiduelles, qui permettent au réseau d'apprendre plus efficacement même lorsqu'il devient très profond. L'avantage principal de ResNet50 est sa capacité à éviter le problème de la dégradation des performances dans les réseaux profonds. Grâce aux connexions résiduelles, le modèle peut transmettre directement certaines informations d'une couche à une autre.

2.2.2 Étapes du modèle ResNet50

Entrée de l'image : L'image est redimensionnée selon la taille attendue par le modèle.

Prétraitement spécifique : Les valeurs des pixels sont préparées selon les exigences de ResNet50.

Extraction profonde des caractéristiques : Le modèle analyse progressivement l'image à travers plusieurs blocs convolutionnels.

Connexions résiduelles : Certaines informations sont directement transférées entre les couches afin de faciliter l'apprentissage.

Global Average Pooling : Les caractéristiques extraites sont résumées en un vecteur compact.

Couche de classification : Une couche dense est ajoutée pour adapter le modèle au nombre de classes de notre dataset.

Sortie Softmax : Le modèle génère les probabilités associées aux différentes maladies.




Figure 18: Architecture de RESNET50 pour la détection des maladies des plantes

2.3 EfficientNet

2.3.1 Définition

EfficientNet est une architecture moderne conçue pour obtenir de bonnes performances tout en réduisant le coût de calcul. Elle repose sur une stratégie appelée compound scaling, qui équilibre la profondeur, la largeur et la résolution du réseau. Ce modèle est particulièrement intéressant car il offre souvent une très bonne précision avec moins de paramètres que d'autres architectures plus lourdes.

2.3.2 Étapes du modèle EfficientNet

Entrée de l'image : L'image est redimensionnée selon la taille utilisée par EfficientNet.

Prétraitement : L'image est normalisée afin d'être compatible avec le modèle.

Extraction optimisée des caractéristiques : EfficientNet utilise des blocs convolutionnels efficaces pour apprendre les détails visuels des feuilles.

Apprentissage hiérarchique : Les premières couches détectent des caractéristiques simples, tandis que les couches profondes détectent des motifs plus complexes liés aux maladies.

Global Average Pooling : Les cartes de caractéristiques sont transformées en un vecteur représentatif.

Classification finale : Une couche dense suivie d'une fonction Softmax permet de prédire la maladie.




Figure 19: Architecture de EFFICIENTNET pour la détection des maladies des plantes.

3 Implémentation

3.1 Mise en place et la configuration de l'environnement

Au sein de notre projet, nous avons opté pour l'utilisation du Python comme langage de programmation en raison de ses caractéristiques avancées en Deep Learning, de sa souplesse, de sa compatibilité avec une large gamme de plateformes, de sa communauté étendue de développeurs, et de ses outils avancés de visualisation de données.

Langage python :

Le langage de programmation Python est largement employé dans le domaine de la programmation générale. Fondé par Guidovan Rossum et publié en 1991, il adopte une approche de conception axée sur la lisibilité du code, en mettant l'accent sur l'utilisation d'espaces importants. Python fournit des structures qui facilitent une programmation très claire à l'échelle petite et grande [45]. Python est équipé d'un système dynamique et d'une gestion automatique de mémoire. Il supporte différentes approches de programmation, telles que l'orienté objet, les impératifs, les fonctions et les procédures, et possède une bibliothèque standard étendue et exhaustive. On peut trouver des interpréteurs de Python pour différents systèmes d'exploitation.



Figure 20: Logo Python

Python est largement employé pour l'implémentation des CNN, puisqu'il propose de nombreuses bibliothèques et des modules spécialisés dans du deep learning, comme TensorFlow, PyTorch, Keras, et bien d'autres encore. Il est aisé de concevoir des modèles de CNN performants et personnalisables qu'il s'agisse d'utiliser des réseaux pré-entraînés ou en développant ses propres architectures grâce à ces outils.

Visual Studio Code (VS Code) :

Visual Studio Code (VS Code) est un éditeur de code source gratuit et open source développé par Microsoft. Il permet de développer des applications dans différents langages de programmation tels que Python, Java, C++, JavaScript et bien d'autres. Grâce à son interface légère, ses nombreuses extensions et ses outils intégrés de débogage et de gestion de projet, VS Code est devenu l'un des environnements de développement les plus utilisés par les développeurs [46]. Dans le cadre de ce projet, VS Code a été utilisé pour l'écriture, la modification et l'organisation



Figure 21: logo VS Code.

du code source de l'application ainsi que pour l'entraînement et l'évaluation des modèles de Deep Learning.

3.2 Les bibliothèques utilisées

Dans cette application, nous avons employé diverses bibliothèques Python afin de détecter et identifier les maladies des plantes. Parmi les bibliothèques utilisées dans le programme, voici une brève description :

TensorFlow :

TensorFlow est une bibliothèque open source de machine learning qui permet de concevoir et de mettre en place des applications de machine et deep learning [47]. TensorFlow propose une plateforme complète pour l'apprentissage automatique, comprenant des outils pour préparer des données, concevoir plusieurs types de modèles, les mettre en place et les maintenir. Des modèles pré-programmés ou personnalisables sont également disponibles dans TensorFlow, de plus un ensemble des bibliothèques et des extensions spécialisées qui permettent d'ajouter de nouvelles fonctionnalités à TensorFlow.



Figure 22: logo TensorFlow

Keras :

Keras est une librairie de pointe spécialisée dans l'apprentissage profond [48], offrant la possibilité de concevoir et d'entraîner facilement et intuitivement des modèles de réseaux de neurones. Sa base repose sur TensorFlow. Elle présente de nombreux bénéfices par rapport aux autres bibliothèques de deep learning. On peut concevoir des couches, et des mesures ainsi que des fonctions de perte sur mesure. Elle peut servir à résoudre divers problèmes en Deep Learning, comme la classification des images, et la création de texte, le traitement du langage naturel, etc. Keras offre une documentation complète et grand nombre de tutoriels afin de l'utiliser de manière efficace.



Figure 23: Logo Keras

NumPy :

NumPy est un module Python qui offre la possibilité de gérer les tableaux. Il est équipé d'outils permettant de manipuler un objet tableau multidimensionnel performant. Il s'agit du module Python essentiel pour les calculs scientifiques [49].

Scikit-learn :

est une bibliothèque Python dédiée à l'apprentissage automatique. Elle fournit des outils performants pour la classification, la régression, le clustering, le prétraitement des données ainsi que l'évaluation des modèles [50]. Dans ce projet, elle a été utilisée pour le calcul des métriques de performance et l'analyse des résultats des modèles entraînés.



Figure 24: Logo de la bibliothèque Scikit-learn

Matplotlib :

Est une bibliothèque Python dédiée à la visualisation de données. Elle permet de créer différents types de graphiques tels que les courbes, les histogrammes, les diagrammes en barres et les matrices de confusion. Dans ce projet, elle a été utilisée pour visualiser les performances des modèles, notamment les courbes d'Accuracy et de Loss ainsi que les résultats expérimentaux [51].



Figure 25: Logo de la bibliothèque Matplotlib

Pandas

Est une bibliothèque Python spécialisée dans la manipulation et l'analyse de données. Elle fournit des structures de données performantes, telles que les DataFrames, permettant de charger, organiser, nettoyer et analyser efficacement de grands volumes de données. Dans ce projet, Pandas a été utilisée pour le traitement des données et l'analyse des résultats expérimentaux [52].



Figure 26: Logo de la bibliothèque Pandas

Pillow

Est une bibliothèque Python dédiée au traitement et à la manipulation d'images. Elle permet d'effectuer diverses opérations telles que le chargement, le redimensionnement, la conversion de formats et l'amélioration des images [53]. Dans ce projet, elle a été utilisée pour le prétraitement des images avant leur utilisation par les modèles de Deep Learning.



Figure 27: Logo de la bibliothèque Pillow.

Streamlit

Est un framework open source développée en Python permettant de créer rapidement des applications web interactives dédiées à la science des données, au Machine Learning et à l'intelligence artificielle [54]. Il offre une interface simple pour intégrer des modèles d'apprentissage automatique, visualiser les résultats et interagir avec les utilisateurs. Dans ce projet, Streamlit a été utilisé pour développer l'interface web permettant le chargement des images, l'affichage des prédictions et la visualisation des performances des modèles.



Figure 28: Logo du framework Streamlit

OpenCV (Open Source Computer Vision Library)

Est une bibliothèque open source spécialisée dans la vision par ordinateur et le traitement d'images. Elle fournit un ensemble d'outils permettant l'acquisition, le prétraitement, l'analyse et la manipulation des images et des vidéos. Dans ce projet, OpenCV a été utilisée pour certaines opérations de traitement d'images, notamment le chargement, la conversion et le prétraitement des images avant leur utilisation par les modèles de Deep Learning [55].



Figure 29: Logo de la bibliothèque OpenCV

Altair

Est une bibliothèque Python dédiée à la visualisation de données interactives. Basée sur la grammaire de visualisation Vega-Lite, elle permet de créer facilement des graphiques clairs, dynamiques et personnalisables. Dans ce projet, Altair a été utilisée pour représenter visuellement les résultats des



Figure 30: Logo de la bibliothèque Altair.

prédictions et les niveaux de confiance associés aux différentes classes détectées [56].

3.3 Dataset utilisé

PlantVillage Dataset

Le dataset **PlantVillage** est la base de données utilisée pour entraîner et tester les modèles de Deep Learning. Il contient des milliers d'images de feuilles de plantes saines et malades appartenant à plusieurs catégories agricoles. Ce dataset est largement utilisé dans les projets de détection des maladies des plantes grâce à sa qualité et à sa diversité. Les images sont utilisées pour apprendre aux modèles à reconnaître automatiquement différentes maladies végétales. L'ensemble de données PlantVillage comprend 54 303 images de feuilles saines et malsaines divisées en 38 catégories par espèce et maladie. Afin d'assurer un apprentissage efficace et une évaluation fiable du modèle, les données ont été réparties en trois sous-ensembles selon la méthode de division (split) 80/10/10. Ainsi, 80 % des images ont été utilisées pour l'entraînement (Train), 10 % pour la validation (Validation) et 10 % pour le test (Test).




Figure 31: Exemple d'image du dataset PlantVillage — Maladie des feuilles de tomate (Tomato Leaf Disease)

4 Le choix des modèles

Dans ce projet, plusieurs modèles de Deep Learning ont été sélectionnés afin de comparer leurs performances dans la détection et l'identification des maladies des plantes. Le choix de ces modèles repose sur leur efficacité dans les tâches de classification d'images, leur précision ainsi que leur capacité de généralisation.

L'objectif principal est d'évaluer les performances de chaque architecture à travers différentes métriques telles que l'Accuracy, la précision, Le recall et F1 Score.

Le modèle **CNN Baseline** est utilisé comme point de départ afin d'obtenir une référence simple pour les comparaisons. Ensuite, **ResNet50** est choisi grâce à sa grande capacité d'apprentissage et sa robustesse dans les tâches de classification d'images complexes. Enfin, **EfficientNet** est intégré pour bénéficier d'une architecture moderne offrant un excellent compromis entre précision et performance computationnelle.

Cette approche comparative permet de déterminer le modèle le plus adapté à la détection des maladies des plantes dans des conditions réelles.

4.1 Etude comparative

La figure ci-dessous présente un exemple de prédiction réalisée par le système proposé. Après le téléchargement de l'image d'une feuille de tomate infectée, le modèle de Deep Learning a détecté avec succès la maladie du mildiou (*Tomato Late Blight*) avec un taux de confiance élevé. Cette étape constitue la phase initiale avant l'évaluation et la comparaison des performances des différents modèles utilisés.




Figure 32: Exemple de détection de la maladie du mildiou sur une feuille de tomate par le modèle de Deep Learning

4.1.1 Courbes d'entraînement (Accuracy / Loss)

CNN Baseline

La figure ci-dessous illustre la progression des courbes d'Accuracy et de Loss de modèle CNN Baseline durant la phase de formation. Les performances s'améliorent graduellement avec l'accroissement du nombre d'époques, comme le suggère l'augmentation de la précision et la réduction de la perte lors de l'entraînement. Les résultats démontrent que le modèle réussit à acquérir avec succès les traits visuels liés aux diverses maladies des plantes.




Figure 33: Évolution des performances d'entraînement et de validation de modèle CNN Baseline.

EfficientNet

Les graphes dans la figure suivante indiquent qu'EfficientNet parvient à un niveau de performance significatif rapidement dès les premières époques de formation. La précision de validation reste très similaire à celle de l'entraînement durant l'ensemble du processus d'apprentissage, tandis que les valeurs de perte demeurent basses et continuent leur tendance à la baisse graduelle. Cette stabilité reflète une aptitude à généraliser efficacement du modèle en plus d'une convergence performante. Ces constatations corroborent l'aptitude d'EfficientNet à saisir les attributs distinctifs de diverses pathologies tout en préservant une haute performance sur les données de validation.




Figure 34: Évolution des performances d'entraînement et de validation de modèle EfficientNet

ResNet50

Les courbes obtenues dans la figure qui suit montrent que l'architecture ResNet50 atteint rapidement des performances élevées grâce à l'utilisation du transfert d'apprentissage. Les résultats restent globalement stables tout au long de l'entraînement, avec une précision de validation qui se maintient à un niveau élevé. L'analyse des courbes met également en évidence la capacité du modèle à extraire efficacement les caractéristiques discriminantes des feuilles malades. Ces observations confirment la pertinence de ResNet50 pour les tâches de détection et d'identification des maladies des plantes.




Figure 35 : Évolution des performances d'entraînement et de validation de modèle ResNet50

4.1.2 Analyse des résultats

Analyse des résultats

Les résultats de l'évaluation des méthodes utilisées sont exposés et comparés. Les modèles ont été évalués en utilisant différentes mesures, telles que l'accuracy, precision, le rappel et le score F1.

L'exactitude (Accuracy)

Elle mesure la proportion de bonnes prédictions sur l'ensemble des prédictions.

$$\text{Accuracy: } (\text{Tous corrects} / \text{Tous}) = \frac{\text{Vrai positif} + \text{vrai négatif}}{\text{Vrai positif} + \text{vrai négatif} + \text{Faux Positif} + \text{Faux Négatif}}$$

La précision (Precision)

Elle mesure la proportion de vrais positifs parmi tous les éléments prédits comme positifs.

$$\text{Precision :} (\text{Vrais positifs} / \text{positifs prévus}) = \frac{\text{Vrai positif}}{\text{Vrai positif} + \text{Faux positif}}$$

Le rappel (Recall)

Le rappel correspond à la proportion de vrais positifs parmi tous les éléments réellement positifs.

$$\text{Recall:} (\text{Vrais positifs} / \text{tous les positifs réels}) = \frac{\text{Vrai positif}}{\text{Vrai positif} + \text{faux négatif}}$$

Le F1-score

Le F1-score est la moyenne harmonique entre la précision et le rappel. Il est particulièrement utile lorsque le jeu de données est déséquilibré.

$$\text{Score F1: score F1} = (2 * \text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

Où :

- Vrai positif (TP) : résultat pour lequel le modèle prédit correctement qu'une image ou une feuille de plante est atteinte par une maladie donnée.
 - Vrai négatif (TN) : Résultat pour lequel le modèle prédit correctement qu'une image ou une feuille de plante n'est pas atteinte par la maladie considérée (plante saine ou appartenant à une autre classe).
 - Un faux positif (FP) résultat pour lequel le modèle prédit à tort qu'une image ou une feuille de plante est atteinte par une maladie alors qu'elle ne l'est pas.
 - Un faux négatif (FN) résultat pour lequel le modèle prédit à tort qu'une image ou une feuille de plante n'est pas atteinte par la maladie alors qu'elle est réellement malade.
- [57]

Ces informations sont présentées dans une matrice de confusion.

		<i>Classe prédite</i>	
		<i>Classe0</i>	<i>Classe1</i>
Classe réelle	<i>Classe0</i>	<i>VN</i>	FN
	<i>Classe1</i>	FP	VP

Tableau 6 : Les informations des classes



Figure 36: Comparaison des métriques de performance des modèles CNN Baseline, ResNet50 et EfficientNet.

La figure 36 présente les résultats finaux obtenus par les trois modèles évalués sur un ensemble de 30 images de test. Les résultats montrent que les modèles ResNet50 et EfficientNet ont correctement classifié l'ensemble des images testées, atteignant ainsi une accuracy, une précision et un rappel de 100 %, sans aucune erreur de prédiction. Ces performances témoignent de leur grande capacité à extraire les caractéristiques discriminantes des maladies des plantes et à fournir des prédictions fiables.

En revanche, le modèle CNN Baseline a correctement classifié 25 images sur 30, avec 5 erreurs de prédiction, ce qui correspond à une accuracy de 83,33 %, une précision de 88,61 % et un rappel de 83,33 %. Bien que ses résultats restent satisfaisants, ils demeurent inférieurs à ceux des modèles plus avancés. Cette comparaison met en évidence l'efficacité des architectures profondes telles que ResNet50 et EfficientNet pour les tâches de classification des maladies des plantes à partir d'images.



Figure 37: Comparaison de l'accuracy des modèles évalués




Figure 38: Comparaison de la précision des modèles évalués




Figure 39: Comparaison du rappel (Recall) des modèles évalués

Graphique comparatif - F1-score (%)




Figure 40: Comparaison du F1-score des modèles évalués

5 Conclusion

Dans ce chapitre, nous avons présenté l'implémentation et l'expérimentation de notre système de détection et d'identification des maladies des plantes basé sur l'apprentissage profond. Plusieurs modèles de Deep Learning, notamment CNN, ResNet50 et EfficientNet, ont été entraînés et évalués à l'aide de différentes métriques de performance telles que l'Accuracy, la Précision, le Recall et le F1-score. Une étude comparative a également été réalisée sur différents types d'images.

Les résultats obtenus ont montré que les modèles basés sur des architectures avancées, offrent de meilleures performances et une meilleure capacité de généralisation sur les données réelles.

Enfin, l'intégration des modèles dans une application web interactive développée avec Streamlit a permis de proposer une solution moderne, intuitive et facilement exploitable pour la prédiction des maladies des plantes à partir d'images.

Conclusion générale et perspectives

Au terme de ce travail, nous avons étudié l'utilisation de l'intelligence artificielle et plus particulièrement de l'apprentissage profond pour la détection et l'identification des maladies des plantes. Ce projet a permis de mettre en évidence l'importance des techniques de Deep Learning dans le domaine agricole, notamment pour automatiser l'analyse des feuilles infectées et améliorer la rapidité ainsi que la précision du diagnostic. Plusieurs modèles ont été étudiés et comparés, tels que CNN, ResNet50 et EfficientNet, afin d'évaluer leurs performances à travers différents indicateurs comme l'Accuracy, la Précision, le Recall et F1 Score. Une application web interactive basée sur Streamlit a également été développée pour faciliter l'utilisation des modèles et permettre des tests sur des images réelles.

Malgré les résultats encourageants obtenus, certaines limites restent présentes. Les performances des modèles dépendent fortement de la qualité et de la diversité du dataset utilisé lors de l'entraînement. Certaines maladies présentant des symptômes similaires peuvent encore provoquer des erreurs de classification. De plus, les conditions réelles telles que les variations d'éclairage, les arrière-plans complexes ou la qualité des images peuvent influencer la précision des prédictions. Enfin, les modèles de Deep Learning nécessitent des ressources matérielles importantes ainsi qu'un temps d'entraînement relativement élevé.

Comme perspectives futures, plusieurs améliorations peuvent être envisagées afin d'optimiser davantage ce système. Il serait possible d'utiliser des datasets plus variés et plus volumineux afin d'augmenter la capacité de généralisation des modèles. L'intégration de techniques avancées d'augmentation de données et d'optimisation pourrait également améliorer les performances de classification. De plus, le développement d'une application mobile ou d'un système embarqué permettrait une utilisation directe sur le terrain par les agriculteurs. Enfin, l'intégration de nouvelles fonctionnalités, telles que des recommandations de traitement adaptées aux maladies détectées ou l'analyse en temps réel via caméra, constituerait une évolution importante pour rendre ce système encore plus intelligent et utile dans des applications agricoles réelles.

Bibliographie

- [1] Briganti, G. (2023). Intelligence artificielle : une introduction pour les cliniciens. *Revue des Maladies Respiratoires*, 40(4), 308-313.
- [2] Robert, J. (2024, Mar 8). Intelligence Artificielle : Définition, histoire, enjeux. Formation Data Science. Disponible : <https://datascientest.com/intelligence-artificielle-definition> .
- [3] Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229.
- [4] Benzaki, Y. (2016, novembre 22). Introduction au Machine learning : Définitions et Concepts. Disponible : <https://mrmint.fr/introduction-machine-learning>
- [5] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning* (2nd ed.). Springer.
- [6] Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- [7] Murphy, K. P. (2022). *Probabilistic machine learning: an introduction*. MIT press.
- [8] Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (Vol. 326). John Wiley & Sons.
- [9] Candillier, L. (2006). *Contextualisation, visualisation et évaluation en apprentissage non supervisé* (Doctoral dissertation, Université Charles de Gaulle-Lille III).
- [10] Sharma Pulkit. (2019). The most comprehensive guide k-means clustering. Analytics Vidhya.
- [11] Azencott, C. A. (2022). *Introduction au Machine Learning-2e éd.* Dunod.
- [12] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- [13] Définition | Deep Learning - Apprentissage profond. (2024). Disponible : www.futura-sciences.com

Bibliographie

- [14] Belabdeli, F. Z. (2023). *Evaluation des maladies cardiaques à l'aide de techniques de Machine Learning et Deep Learning* (Master's thesis, Université Paul Verlaine).
- [15] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
- [16] Mohammadi, M., Al-Fuqaha, A., Sorour, S., & Guizani, M. (2018). Deep learning for IoT big data and streaming analytics: A survey. *IEEE Communications Surveys & Tutorials*, 20(4), 2923-2960.
- [17] Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects.
- [18] Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y. (2017). Learning pooling for convolutional neural network. *Neurocomputing*, 224, 96-104.
- [19] Liu, K., Kang, G., Zhang, N., & Hou, B. (2018). Breast cancer classification based on fully-connected layer first convolutional neural networks.
- [20] Marimuthu, P. (2022). *How Activation Functions Work in Deep Learning*.
- [21] Audebert, N. (2018). *Classification de données massives de télédétection* (Doctoral dissertation, Université Bretagne Sud).
- [22] Bérard, F. (1999). *Vision par ordinateur pour l'interaction homme-machine fortement couplée* (Doctoral dissertation, Université Joseph-Fourier-Grenoble I).
- [23] Robert, J. (2023). Image Processing : principes fondamentaux et usages pratiques. Disponible : <https://datascientest.com/image-processing-tout-savoir>
- [24] Belsare, A. D., & Mushrif, M. M. (2012). Histopathological image analysis using image processing techniques: An overview. *Signal & Image Processing*, 3(4), 23.
- [25] ain, A. K. (1989). Fundamentals of digital image processing. *Prentice-Hall*.
- [26] CHENG, Xi; ZHANG, Youhua; CHEN, Yiqiong; WU, Yunzhi; YUE, Yi. Pest identification via deep residual learning in complex background. *Computers and Electronics in Agriculture*. 2017, t. 141, p. 351-356.

Bibliographie

- [27] EBRAHIMI, MA; KHOSHTAGHAZA, Mohammad-Hadi; MINAEI, Saeid; JAMSHIDI, Bahareh. Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*. 2017, t. 137, p. 52-58.
- [28] LI, Lili ; ZHANG, Shujuan ; WANG, Bin. Plant disease detection and classification by deep learning—a review. *IEEE Access*. 2021, t. 9, p. 56683-56698.
- [29] Hughes, D. P., & Salathé, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint arXiv:1511.08060*.
- [30] SANKARAN, Sindhuja; MISHRA, Ashish; EHSANI, Reza; DAVIS, Cristina. A review of advanced techniques for detecting plant diseases. *Computers and electronics in agriculture*. 2010, t. 72, no 1, p. 1-13.
- [31] University of Kentucky. (n.d.). Plant Diseases: Identification and Management. Retrieved from <https://www.uky.edu/Ag/Entomology/PSEP/pdfs/11pests1disease.pdf>
- [32] Encyclopaedia Britannica. (2024). *Plant disease*. Encyclopaedia Britannica.
- [33] Food and Agriculture Organization. (2023). *Plant health and disease management*. FAO.
- [34] American Phytopathological Society. (2022). *Plant virus diseases*. APS.
- [35] RATHOD, Arti N; TANAWAL, Bhavesh; SHAH, Vatsal. Image processing techniques for detection of leaf disease. *International Journal of Advanced Research in Computer Science and Software Engineering*. 2013, t. 3, no 11.
- [36] J. G. A. Mohanty, D. P. Hughes, and M. Salathé, “Using Deep Learning for Image-Based Plant Disease Detection,” *Frontiers in Plant Science*, vol. 7, 2016.
- [37] K. P. Ferentinos, “Deep Learning Models for Plant Disease Detection and Diagnosis,” *Computers and Electronics in Agriculture*, 2018.
- [38] A. Sladojevic et al., “Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification,” *Computational Intelligence and Neuroscience*, 2016.
- [39] J. Too et al., “A comparative study of fine-tuning deep learning models for plant disease identification,” *Computers and Electronics in Agriculture*, 2019.

Bibliographie

- [40] Y. LeCun, Y. Bengio, and G. Hinton, “Deep Learning,” *Nature*, 2015.
- [41] Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: Classification and symptoms visualization. *Applied Artificial Intelligence*.
- [42] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [43] A. Krizhevsky et al., “ImageNet Classification with Deep Convolutional Neural Networks,” *NeurIPS*, 2012
- [44] Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- [45] Python.org. <https://www.python.org/>
- [46] Microsoft. (2025). *Visual Studio Code*. <https://code.visualstudio.com/>
- [47] *TensorFlow*. (n.d.).TensorFlow.<https://www.tensorflow.org/?hl=fr>
- [48] Team, K. (n.d.). *Keras: Deep Learning for humans*. <https://keras.io/>
- [49] Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). *Array programming with NumPy*. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- [50] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). *Scikit-learn: Machine Learning in Python*. *Journal of Machine Learning Research*, 12, 2825–2830.
- [51] Hunter, J. D. (2007). *Matplotlib: A 2D graphics environment*. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- [52] McKinney, W. (2010). *Data structures for statistical computing in Python*. In S. van der Walt & J. Millman (Eds.), *Proceedings of the 9th Python in Science Conference (SciPy 2010)* (pp. 56–61).
- [53] Pillow Contributors. (2026). *Pillow (PIL Fork) Documentation*
- [54] Streamlit Inc. (2026). *Streamlit documentation*. <https://docs.streamlit.io/>
- [55] Bradski, G. (2000). *The OpenCV Library*. *Dr. Dobb’s Journal of Software Tools*.

Bibliographie

- [56] Altair Developers. (2026). *Altair: Declarative statistical visualization library for Python*. <https://altair-viz.github.io/>
- [57] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer

ملخص

يتمحور هذا المشروع حول اكتشاف وتشخيص أمراض النباتات باستعمال تقنيات التعلم العميق. يهدف المشروع إلى تطوير نظام ذكي قادر على تحليل صور أوراق النباتات والتعرف تلقائيًا على الأمراض بدقة عالية. تم دراسة ومقارنة عدة نماذج من التعلم العميق مثل CNN و ResNet50 و EfficientNet باستخدام مجموعة من مؤشرات الأداء. كما تم تطوير تطبيق ويب تفاعلي باستعمال Streamlit يسمح للمستخدمين باختبار النماذج بسهولة على صور حقيقية. أظهرت النتائج فعالية تقنيات التعلم العميق في المجال الزراعي وقدرتها على تحسين مراقبة المحاصيل وتشخيص الأمراض النباتية.

كلمات مفتاحية: الذكاء الاصطناعي، التعلم العميق، اكتشاف أمراض النباتات، الرؤية الحاسوبية.

Abstract

This project focuses on the detection and identification of plant diseases using deep learning techniques. The main objective is to develop an intelligent system capable of analyzing leaf images and automatically identifying diseases with high accuracy. Several Deep Learning models, including CNN, ResNet50, and EfficientNet, were studied and compared using different performance metrics. An interactive web application based on Streamlit was also developed to allow users to test the models on real images easily. The obtained results demonstrate the effectiveness of Deep Learning approaches in agriculture and their potential to improve crop monitoring and disease diagnosis.

Key words: Artificial intelligence, Deep learning, Plant disease detection, Computer vision.

Résumé

Ce projet porte sur la détection et l'identification des maladies des plantes à l'aide des techniques d'apprentissage profond. L'objectif principal est de développer un système intelligent capable d'analyser les images des feuilles afin d'identifier automatiquement les maladies avec une grande précision. Plusieurs modèles de Deep Learning, notamment CNN, ResNet50 et EfficientNet, ont été étudiés et comparés à travers différentes métriques de performance. Une application web interactive basée sur Streamlit a également été développée pour permettre aux utilisateurs de tester facilement les modèles sur des images réelles. Les résultats obtenus montrent l'efficacité des approches de Deep Learning dans le domaine agricole et leur potentiel pour améliorer la surveillance des cultures.

Mots clés : Intelligence artificielle, Apprentissage profond, Détection des maladies des plantes, Vision par ordinateur.