

République Démocratique et Populaire d'Algérie

Ministère de L'enseignement Supérieur et de La Recherche Scientifique

UNIVERSITÉ M'HAMED BOUGARA-BOUMERDES



Faculté de Technologie

Département d'Ingénierie des Systèmes Electriques

Mémoire de master

Présenté par :

AYACHE Nermin et LITIM Ikram

Filière: Télécommunications

Spécialité: Réseaux et Télécommunications

DETECTION DE MALADIES DES PLANTES EN UTILISANT

LES RESEAUX DE NEURONES APPROFONDIES

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

MESSAOUDI	Noureddine	Pr	Président
HEDIR	Mahdia	MCB	Examineur
GUERBAI	Yasmine	MCA	Encadrent

Année Universitaire : 2023/2024

REMERCIEMENT

REMERCIEMENT

Tout d'abord, nous souhaitons exprimer notre sincère reconnaissance envers Dieu pour ses bénédictions et sa compatibilité tout au long de cette initiative. C'est grâce à Sa grâce que nous avons réussi cela. Nous sommes reconnaissants de Son soutien inébranlable.

Nous exprimons notre profonde gratitude envers notre chère promotrice Dr. GUERBAI. Sa dévotion remarquable, ses encouragements constants et sa confiance inébranlable en nos compétences ont joué un rôle essentiel dans notre réussite. Nous exprimons notre gratitude sincère pour ses conseils précieux, ses commentaires perspicaces et sa motivation inébranlable qui ont contribué à faire de ce projet ce qu'il est aujourd'hui.

Nous tenons à remercier sincèrement les membres estimés du jury, Dr. HEDIR et Mr. MESSAOUDI, d'avoir accepté d'évaluer notre travail. Leur expertise, leur dévouement et leurs précieux retours affinent notre projet et améliorent sa qualité.

Il est également important d'exprimer notre gratitude envers l'Université de Boumerdes, la Faculté de Technologie et l'équipe de l'Incubateur de Boumerdes. Je suis extrêmement reconnaissant envers Algérie télécom Boumerdes surtout le DRH Mr. MEBARKI, et les encadreurs Mr. HAMMOU et Mme. BENDALI. Notre développement et notre apprentissage ont été favorisés grâce à l'environnement et aux ressources de soutien offerts par notre institution. Nous exprimons notre gratitude pour les possibilités qu'il nous a offertes dans notre domaine.

Je souhaite exprimer ma gratitude spéciale envers Mr. MESSAOUDI, responsable du département, pour sa direction remarquable et ses nombreux efforts pour promouvoir un environnement propice à l'innovation et à l'excellence. Nous avons bénéficié de ses conseils et de son soutien tout au long de notre cursus universitaire.

Les contributions précieuses de nos collègues, ELKOUADI ABD ELOUAHAB et LEMOUCHI ABD ALBASSET, ne peuvent pas être négligées. Leur engagement, leur soutien inébranlable et leur amitié ont apporté une valeur inestimable à notre cheminement. Leur implication et leur soutien ont non seulement contribué à améliorer les résultats de notre projet, mais ont également rendu cette expérience véritablement enrichissante. Nous exprimons notre gratitude sincère pour leur présence précieuse et leur soutien inébranlable tout au long de cette entreprise.

Enfin, nous souhaitons exprimer notre profonde reconnaissance envers tous ceux qui ont fait confiance en nous, nous apprécions tous ceux qui nous ont donné leur main ou leur mot aimable, même les gestes les plus petits, car chaque contribution a joué un rôle important dans notre réussite.

الإهداء

الحمد لله حبا وشكرا و امتنانا على البدء و الختام

{وَأَخِرُ دَعْوَاهُمْ أَنْ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ }

لم تكن الرحلة قصيرة و لا ينبغي لها ان تكون ... لم يكن الحلم قريبا و لا الطريق كان محفوفا بالتسهيلات ... لكنى فعلتها فالحمد لله الذي يسر البدايات و بلغنا النهايات بفضلته و كرمه

إلى من جعل الله الجنة تحت أقدامها .. إلى نور عيني و ضوء دربي و مهجة حياتي .. إلى التي ساندتني و وقفت بجانبي .. إلى التي وهبتني الحياة و الأمل و احتضني قلبها قبل يديها و سهلت لي الشدائد بدعائها

أمي الحبيبة حفظها الله

إلى من كلله الله بالهيبة و الوقار .. و زين إسمي بأجمل الألقاب .. إلى النور الذي أنار دربي و السراج الذي لا ينطفئ نوره بقلبي أبدا .. إلى سندي و حبيبي الغالي

أبي حفظه الله

إلى ضلعي الثابت و أمان أيامي .. إلى من شددت عضدي بهم فكانوا لي ينابيع أرتوي منها .. إلى خيرة أيامي و قرة عيني

إخوتي عبد الجليل و عبد العليم .. أختاي ندى و نورهان

إلى رفقاء الروح الذين شاركوني خطوات هذا الطريق .. إلى من شجعوني على المثابرة و إكمال المسير .. إلى أصدقاء السنين من كانوا عوننا لي و مصدرنا للحب ممتنة لكم جميعا

و أخيرا من قال أنا لها "نالها" و أنا لها و إن أبت رغما عنها أتيت بها .. ما كنت لأفعل لولا توفيق من الله

أهديكم هذا الإنجاز و ثمرة نجاحي الذي لاطالما تمنيته فالحمد لله على التمام

نرمين

إهداء

قال رسول الله صلى الله عليه وسلم: "من صنع إليكم معروفا فكافنوه فإن لم تجدوا ما تكافئون به فادعوا له حتى تروا أنكم قد كافأتموه " رواه أبو داود

لى الله قبل كل شيء الحمد لله لك كما ينبغي لوجهك و عظيم سلطانك

من قال انا لها نالها لم تكن الرحلة قصيرة و لا ينبغي لها ان تكون لم يكن الحلم قريبا و لا الطريق كان محفوفاً بالتسهيلات و لكني فعلتها و نلتها

يا خير عون كان لي عند المحن الى الجدار الذي استند عليه في تعبي و حزني ،الى الكتف الذي أضع عليه اثقالى ،الى عزيزي و حبيبي الذي أحبه بقدر هذا العالم ،الى جنة الدنيا و الآخرة....إي

الى من تمتلك جنة تحت القدم الى ملاي الطاهر و قوتي بعد الله ،داعمي الاولى الابدية ،الى من دعمتني بلا حدود و أعطتني بلا مقابل ، اهديك هذا الانجاز الذي لولا تضحياتك لما كان له وجودأمي

الى من قال فيهم(سنشد عضدك بأخيك)

الى من مُدت يده دون كلل او ملل وقت ضعفي الى من بهم افتخر و عليهم اعتمد اخوتي عبد الرؤوف و عبد الرزاق الى من لم تتوانى في مد يد العون لي تخلت بالاخاء ،الوفاء ،العطاء عاملتني بالحسنى و شدت ازري نحو القمة ،الى توأم روجي اختي سناء

الى سندي و قوتي ،الذي إستمر في تقديم النصائح ،التشجيع و الدعم طوال مسيرتي ،خطيبي ادامك الله سنداً الى صديقة العمر ،الى حبيبة قلبي ، اختي الثانية ،كنتي ضلغي الثابت طوال الفترة ،الى من استند عليها وقت شدتي
اكرام

الى كل من رافقني في رحلتي ، ،كياني ،الى القرييين من القلب ،المساندين في السراء و الضراء ،فرحتي ،عائلتي احبائي ،اقاربي ، وفقكم الله و سدّد خطاكم

الحمد لله في كل بدء و مختتم

إكرام

ملخص

أحد التحديات الرئيسية التي تواجه المهنيين المزارعين هو اكتشاف الأمراض النباتية، وهو جانب حاسم لضمان المحاصيل الصحية والوفيرة وحفظ النباتات. يهدف مشروعنا إلى حل هذه المشكلة باستخدام الذكاء الاصطناعي وتقنيات التعلم العميق لتطوير نظام تحليل أوراق دقيق باستخدام الشبكات العصبية الاصطناعية. تتمتع هذه النماذج بقدرة استثنائية على تحديد الحبوب المريضة، مما يسمح بتدابير وقائية فعالة لمنع فقدان المحاصيل والنباتات. نهدف إلى تزويد المزارعين والفلاحين بكل موثوق به واستباقي لتسهيل اكتشاف الأمراض النباتية. يمثل المشروع تقدمًا كبيرًا في الزراعة، حيث يوفر فرصًا جديدة لتحسين مراقبة الأمراض وعلاجها.

كلمات مفتاحية: الكشف عن أمراض النبات، الذكاء الاصطناعي، التعلم العميق، الشبكة العصبية الترابطية.

Abstract

One of the main challenges facing agricultural professionals is the discovery of plant diseases, a crucial aspect of ensuring healthy and abundant crops and plant conservation. Our project aims to solve this problem using artificial intelligence and deep learning techniques to develop an accurate paper analysis system using artificial neural networks. These models have an exceptional ability to identify satisfactory grains, allowing effective preventive measures to prevent the loss of crops and plants. We aim to provide farmers and peasants with a reliable and proactive solution to facilitate the detection of plant diseases. The project represents significant progress in agriculture, providing new opportunities to improve disease surveillance and treatment.

Keywords: plant disease detection, AI, deep learning, convolutional neural network CNN.

Résumé

L'un des principaux défis auxquels sont confrontés les professionnels agricoles est la découverte des maladies des plantes, un aspect crucial pour assurer des cultures saines et abondantes et la conservation des plantes. Notre projet vise à résoudre ce problème en utilisant l'intelligence artificielle et des techniques d'apprentissage profond pour développer un système d'analyse des feuilles précis en utilisant des réseaux de neurones artificiels. Ces modèles ont une capacité exceptionnelle à identifier des grains satisfaisants, permettant des mesures préventives efficaces pour prévenir la perte de cultures et de plantes. Nous visons à fournir aux agriculteurs et aux paysans une solution fiable et proactive pour faciliter la détection des maladies des plantes. Le projet représente des progrès importants en agriculture, offrant de nouvelles possibilités d'améliorer la surveillance et le traitement des maladies.

Mots-clés : détection des maladies des plantes, IA, apprentissage profond, CNN.

Table de matières

REMERCIEMENT	I
Résumé	Iv
Introduction Générale	1
CHAPITRE.1 Généralité sur la détection des maladies des plantes.....	
1.1 Introduction	4
1.2 Définition des maladies des plantes.....	4
1.3 Types de maladies des plantes.....	4
1.3.1 Maladies fongiques	4
1.3.2 Maladies bactériennes	6
1.3.3 Maladies virales	7
1.3.4 Maladies dues à des nématodes	8
1.3.5 Maladies dues à des carences nutritionnelles	9
1.4 Détection des maladies des plantes	11
1.5 Méthodes de la détection des maladies des plantes	11
1.5.1 Méthodes d'observation visuelle.....	11
1.5.2 Méthodes d'analyse de laboratoire.....	11
1.5.3 Nouvelles technologies	11
1.6 Conclusion.....	12
CHAPITRE.2 Les méthodes utilisées pour la détection des maladies des plantes.....	

2.1 Introduction	14
2.2 L'intelligence Artificiel	14
2.2.1 Définition	14
2.2.2 Types d'intelligence artificielle.....	15
2.3 Machine Learning (ML)	15
2.3.1 Types d'apprentissage automatique machine learning(ML).....	16
2.3.2 Applications de l'apprentissage automatique machine learning (ML).....	17
2.4 Deep Learning (DL)	18
2.4.1 Avantages de l'apprentissage profond.....	18
2.4.2 Applications de l'apprentissage profond	18
2.5 Réseau de neurones Artificielles (Artificiel Neural Network).....	19
2.5.1 Architecture	19
2.5.2 Types de réseaux de neurones	20
2.6 La différence entre réseau de neurones et deep learning	20
2.7 Réseaux de neurones convolutifs (CNN).....	21
2.7.1 L'architecture du CNN	21
2.7.2 Les modèles de CNN	22
2.8 Conclusion	26
CHAPITE.3 Conception et réalisation	
3.1 Introduction	28
3.2 Détection et Classification des maladies des plantes Utilisant VGG-16, MobileNetV1 et LeNet5	28
3.2.1 Définition.....	28

3.2.2 Problèmes et contraintes	28
3.3 Conception de système	29
3.4 Réalisation de système	30
3.4.1 Description et architecture de base de donnée (Dataset).....	30
3.4.2 Prétraitement des ensembles de données	31
3.5 Implémentation et déploiement de modèles d'apprentissage profond	32
3.5.1 VGG16.....	32
3.5.2 MobileNetV1	33
3.5.3 LeNet5	34
3.6 Évaluation, expérimentation et essais	35
3.6.1 Les environnements utilisés et les bibliothèques utilisées.....	35
3.6.2 Les paramètres d'évaluation	37
3.6.3 Courbes d'accuracy	42
3.7 Présentation de site web	44
3.7.1 Interface utilisateur graphique	43
3.7.2 Téléchargement et vérification de la page	44
3.8 Conclusion	47
Conclusion Général	48
BIBLIOGRAPHIE	49

Table des figures

Fig1.1: Maladie du mildiou sur les plantes	5
Fig1.2: Maladie de la rouille sur les plantes	5
Fig1.3: Maladie de la tavelure sur les plantes	5
Fig1.4: Maladie du feu bactérien sur les plantes	6
Fig1.5: Maladie du chancre molle sur les plantes.....	6
Fig1.6: Maladie de la pourriture sur les plantes	7
Fig1.7: Maladie de la mosaïque sur les plantes	7
Fig1.8: Maladie de l'enroulement des feuilles sur les plantes.....	8
Fig1.9: Maladie de la jaunisse sur les plantes	8
Fig1.10: Maladie des galles des racines sur les plantes	9
Fig1.11: Maladie du nématode à kyste sur les plantes	9
Fig1.12: Carence en fer sur les plantes.....	10
Fig1.13: Carence en azote sur les plantes.....	10
Fig1.14: Carence en potassium sur les plantes	10
Fig2.1: Intelligence Artificielle.....	14
Fig2.2: Types d'intelligence artificielle.....	15
Fig2.3: Types d'apprentissage automatique.....	16
Fig2.4: Architecture du CNN.....	21
Fig2.5: AlexNet	22

Fig2.6: VGGNet.....	23
Fig2.7: GoogleNet	23
Fig2.8: ResNet	24
Fig2.9: MobileNet.....	24
Fig2.10: EfficientNet	25
Fig2.11: LeNet	25
Fig3.1: Architecture de la détection des maladies des plantes en utilisant CNN.....	29
Fig3.2: Échantillons de l'ensemble de données adopté.....	30
Fig3.3: (a) Accuracy et (b) loss obtenue à l'aide de VGG16 et MobileNetV1	43
Fig3.4: (a) Accuracy et (b) loss obtenue à l'aide de LeNet5	43
Fig3.5: Une fenêtre pour détecter la maladie de votre plante	45
Fig3.6: Une fenêtre pour voir les caractéristiques de certaines plantes.....	45
Fig3.7: Une fenêtre pour nous reconnaître	46
Fig3.8: Une fenêtre d'inscription.....	46
Fig3.9: Logo de notre site web.....	47

Liste des tableaux

Tab3.1: Structure de la matrice de confusion	38
Tab3.2: Résultats des essais sur le groupe de données utilisant VGG16	39
Tab3.3: Résultats des essais sur le groupe de données utilisant MobileNetV1	39
Tab3.4: Résultats des essais sur le groupe de données utilisant LeNet5	40
Tab3.5: Résultats des tests sur les données utilisant VGG16 et MobileNetV1	41
Tab3.6: Résultats de la comparaison CNN	42

Acronymes

ADN	Acide DésoxyriboNucléique.
ANN	Artificial Neural Network.
API	Application Programming Interface.
C	Convolution.
CNN	Convolutional Neural Network.
CPU	Central Processing Unit.
CSS	Cascading Style Sheets.
DL	Deep Learning.
EP	Epoch.
ER	Error Rate.
FN	Faux Négative.
FP	Faux Positif.
GPU	Graphics Processing Unit.
GRU	Gated Recurrent Unit.
HTML	Hypertext Markup Language.
IA	Intelligence Artificielle.
LSTM	Long Short-Term Memory.
ML	Machine Learning.
MP	Max Pooling.
MOBILENET	Mobile Network.
PCR	Polymeras Chain Reaction.
PHP	Personal Home Page.
RAM	Random Access Memory.
RNN	Recurrent Neural Network.
VGG	Visual Geometry Group.

VN Vrai Négatif.

VP Vrai Positif.

Introduction Générale

Depuis des siècles, l'agriculture a joué un rôle crucial dans la subsistance humaine et le développement socio-économique. Cependant, les défis rencontrés par les agriculteurs dans la lutte contre les maladies des plantes persistent, menaçant la sécurité alimentaire mondiale. Les maladies des plantes peuvent entraîner des pertes significatives de récoltes, réduisant ainsi les rendements et affectant la disponibilité des produits alimentaires essentiels.

Dans ce contexte, l'intelligence artificielle (IA) émerge comme un outil révolutionnaire pour la détection précoce et la gestion des maladies des plantes. En exploitant les vastes ensembles de données générées par des capteurs, des drones, des caméras et d'autres technologies de pointe, l'IA offre une opportunité sans précédent d'améliorer la surveillance des cultures, de diagnostiquer les maladies et de mettre en œuvre des stratégies de lutte ciblées.

Ce mémoire explore en profondeur les avancées récentes dans le domaine de la détection des maladies des plantes grâce à l'utilisation de techniques d'intelligence artificielle. En examinant les principes sous-jacents de l'IA, les méthodes de collecte et de prétraitement des données, ainsi que les algorithmes spécifiques utilisés pour la détection des maladies, cette étude vise à fournir une compréhension approfondie des applications potentielles de l'IA dans le domaine de la santé des plantes.

À travers une analyse critique des recherches existantes, des études de cas et des expériences pratiques, ce mémoire évalue l'efficacité, la précision et les limitations des approches actuelles basées sur l'IA pour la détection des maladies des plantes. En outre, il identifie les défis techniques, les lacunes de recherche et les opportunités futures pour le développement de systèmes plus performants et plus adaptés aux besoins des agriculteurs et des professionnels de l'agro-industrie.

En définitive, ce mémoire vise à contribuer à l'avancement des connaissances dans le domaine de la protection des cultures en proposant des recommandations pour l'optimisation et la mise en œuvre efficace de solutions basées sur l'intelligence artificielle dans le contexte de la détection des maladies des plantes.

L'objectif de nos recherches est d'identifier, de détecter les maladies des plantes, attribuer l'engrais approprié pour chaque maladie et pour proposer une approche de modèle d'apprentissage profond. De plus, nous souhaitons aider les agriculteurs, les jardiniers et toute personne intéressée par les plantes à améliorer la détection de ces maladies en utilisant les dernières technologies.

Pour mettre en œuvre ce projet, nous avons structuré cette lettre comme suit :

En premier nous avons défini principalement les maladies des plantes et ses types, la détection des maladies des plantes, les méthodes de détection.

Puis, on a présenté la définition de l'intelligence artificielle, les concepts d'apprentissage automatique et d'apprentissage profond. Ensuite nous avons abordé les CNN (Convolutional Neural Networks) ainsi que les modèles et architectures utilisés dans les CNN.

Finalement, nous avons présenté la solution au problème posé, évalué les résultats des essais effectués en fonction des critères d'évaluation établis.

A la fin de notre étude nous avons pu obtenir des résultats très satisfaisants et trouver des solutions qui peuvent mettre fin à ces maladies.

CHAPITRE.1

Généralité sur la détection des maladies des plantes

CHAPITRE.1 : Généralité sur la détection des maladies des plantes

1.1 Introduction

Les maladies des plantes constituent une menace majeure pour la sécurité alimentaire et l'économie mondiale. Elles affectent une large gamme de cultures, y compris les céréales, les fruits, les légumes et les arbres forestiers. Les pertes de rendement dues aux maladies des plantes peuvent atteindre 40 % ou plus dans certains cas. En plus des pertes de rendement, les maladies des plantes peuvent également entraîner une détérioration de la qualité des produits végétaux, une augmentation des coûts de production et une réduction de la valeur des exportations [1].

Les maladies des plantes ont un impact économique important, car elles réduisent les rendements et la qualité des produits agricoles. Elles peuvent également entraîner des pertes de revenus pour les agriculteurs et les industries agroalimentaires [2].

En outre, les maladies des plantes peuvent avoir un impact négatif sur l'environnement, car elles peuvent conduire à l'utilisation accrue de pesticides et d'autres produits chimiques [3].

1.2 Définition des maladies des plantes

Les maladies des plantes sont des altérations de l'état physiologique normal d'une plante, causées par divers agents pathogènes ou par des facteurs environnementaux défavorables [4]. Ces altérations se manifestent par des symptômes visibles, tels que des taches sur les feuilles, des flétrissements, des déformations, des nécroses, etc., qui affectent la croissance, la reproduction et la productivité de la plante [5].

1.3 Types de maladies des plantes

1.3.1 Maladies fongiques

Ce sont les maladies des plantes les plus répandues. Elles sont causées par des champignons qui peuvent attaquer toutes les parties de la plante, des racines aux feuilles [6].

Exemples

- **Mildiou**: attaque les feuilles et les tiges, provoquant des taches jaunes ou brunes.

CHAPITRE.1 : Généralité sur la détection des maladies des plantes



Figure1.1: Maladie du mildiou sur les plantes

- **Rouille** : provoque des pustules orange ou jaunes sur les feuilles.



Figure1.2: Maladie de la rouille sur les plantes

- **Tavelure** : provoque des taches noires sur les feuilles et les fruits.



Figure1.3: Maladie de la tavelure sur les plantes

CHAPITRE.1 : Généralité sur la détection des maladies des plantes

1.3.2 Maladies bactériennes

Ces maladies sont causées par des bactéries qui peuvent pénétrer dans la plante par des blessures ou des ouvertures naturelles [7].

Exemples

- **Feu bactérien** : provoque le flétrissement et la mort des feuilles.



Figure1.4: Maladie du feu bactérien sur les plantes

- **Chancre** : provoque des lésions sur les tiges et les branches.



Figure1.5: Maladie du chancre sur les plantes

- **Pourriture molle** : provoque la décomposition des tissus végétaux.

CHAPITRE.1 : Généralité sur la détection des maladies des plantes



Figure1.6: Maladie de la pourriture molle sur les plantes

1.3.3 Maladies virales

Ces maladies sont causées par des virus qui peuvent être transmis par des insectes, des graines ou des contacts entre plantes [8].

Exemples

- **Mosaïque** : provoque des taches jaunes ou vertes sur les feuilles.



Figure1.7: Maladie de la mosaïque sur les plantes

- **Enroulement des feuilles** : provoque l'enroulement des feuilles

CHAPITRE.1 : Généralité sur la détection des maladies des plantes



Figure1.8: Maladie de l'enroulement des feuilles sur les plantes

- **Jaunisse** : provoque le jaunissement des feuilles.



Figure1.9: Maladie de la jaunisse sur les plantes

1.3.4 Maladies dues à des nématodes

Ces maladies sont causées par des vers microscopiques qui attaquent les racines des plantes [9].

Exemples

- **Galle des racines** : provoque la formation de galles sur les racines.

CHAPITRE.1 : Généralité sur la détection des maladies des plantes



Figure1.10: Maladie des galles des racines sur les plantes

- **Nématode à kyste** : provoque des lésions sur les racines et réduit la croissance de plante.



Figure1.11: Maladie du nématode à kyste sur les plantes

1.3.5 Maladies dues à des carences nutritionnelles

Ces maladies sont causées par un manque de nutriments essentiels à la croissance des plantes [10].

Exemples

- **Carence en fer** : provoque le jaunissement des feuilles.

CHAPITRE.1 : Généralité sur la détection des maladies des plantes



Figure1.12: Carence en fer sur les plantes

- **Carence en azote** : provoque une croissance réduite et des feuilles pâles.



Figure1.13: Carence en azote sur les plantes

- **Carence en potassium** : provoque des taches brunes sur les feuilles.



Figure1.14: Carence en potassium sur les plantes

CHAPITRE.1 : Généralité sur la détection des maladies des plantes

1.4 Détection des maladies des plantes

La détection des maladies des plantes est un enjeu crucial pour l'agriculture. Un diagnostic précis et précoce est essentiel pour limiter les dégâts, optimiser les traitements et garantir la sécurité alimentaire. Diverses méthodes existent pour détecter les maladies des plantes, chacune avec ses avantages et ses limites.

1.5 Méthodes de la détection des maladies des plantes

1.5.1 Méthodes d'observation visuelle

- **Inspection visuelle:** C'est la méthode la plus simple et la plus directe. Elle consiste à examiner attentivement les plantes pour rechercher des signes de maladie, tels que des taches, des décolorations, des déformations, etc.

- **Clés de diagnostic:** Des outils tels que des guides illustrés ou des applications mobiles peuvent aider à identifier les maladies en fonction des symptômes observés.

1.5.2 Méthodes d'analyse de laboratoire

- **Microscopie:** Permet d'observer les détails fins des tissus végétaux et d'identifier les agents pathogènes (champignons, bactéries, virus) responsables de la maladie.

- **Tests sérologiques:** Utilisent des anticorps pour détecter la présence de pathogènes spécifiques.

- **Techniques moléculaires:** PCR, séquençage d'ADN, etc., permettent d'identifier les pathogènes avec une grande précision.

1.5.3 Nouvelles technologies

- **Imagerie hyper spectrale:** Analyse la lumière réfléchiée par les plantes pour identifier des changements subtils qui peuvent être indicatifs d'une maladie.

CHAPITRE.1 : Généralité sur la détection des maladies des plantes

- **Intelligence artificielle:** L'intelligence artificielle (IA) bouleverse de nombreux secteurs, et l'agriculture n'est pas en reste. Dans le domaine de la santé des plantes, l'IA offre des outils puissants pour la détection précoce et le diagnostic des maladies, permettant ainsi aux agriculteurs de prendre des mesures plus rapides et plus efficaces pour protéger leurs cultures.

1.6 Conclusion

Ce chapitre présente une introduction et une définition sur les maladies des plantes et ses types. Expliquer la détection qui est divisée en trois méthodes utilisant l'observation visuelle, l'analyse de laboratoire et de nouvelles techniques comme l'intelligence artificielle. Par conséquent nous proposons dans le chapitre suivant quelques modèles d'apprentissage profond pour détecter les maladies des plantes.

CHAPITRE.2

Les méthodes utilisées pour la détection des maladies des plantes

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

2.1 Introduction

Dans ce chapitre, nous définirons l'intelligence artificielle et le concept de machine learning, avant de passer au deep learning, avec la présentation des architectures de réseaux neuronaux et des différents modèles utilisés pour détecter les maladies des plantes, tels que AlexNet, MobileNet, VGGNet, ResNet, GoogleNet, LeNet et EfficientNet.

2.2 L'intelligence Artificiel

2.2.1 Définition

L'intelligence artificielle (IA) est la simulation des processus de l'intelligence humaine par des machines capables de raisonner, d'apprendre, de planifier et d'être créatives [11].

Les systèmes d'IA fonctionnent en prenant de grandes quantités de données d'entraînement étiquetées, en analysant les données pour trouver des corrélations et des modèles, et en utilisant ces modèles pour prédire les états futurs.

De cette manière, les chats bots basés sur des exemples textuels peuvent apprendre à générer des interactions réalistes avec les humains.

Les outils de reconnaissance d'images peuvent également apprendre à identifier et décrire des objets dans des images en examinant des millions d'exemples [13].

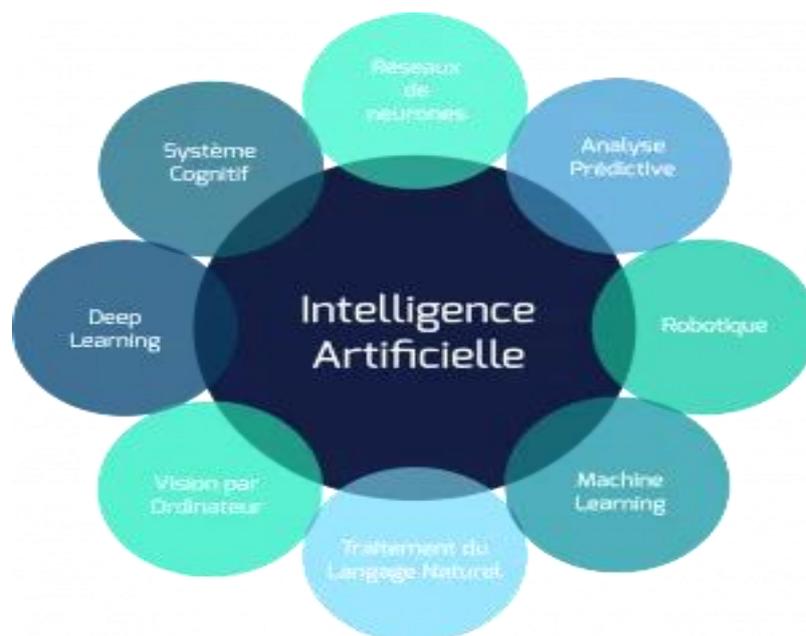


Figure 2.1: Intelligence Artificielle

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

2.2.2 Types d'intelligence artificielle

- **Intelligence Artificielle** : Automatisation de comportements intelligents.
- **Machine Learning** : Programmes informatiques permettant aux machines d'apprendre sans être spécifiquement programmés, afin d'évoluer d'elle-même.
- **Deep Learning** : Apprentissage de modèle de données qui fonctionne comme un réseau de neurones.

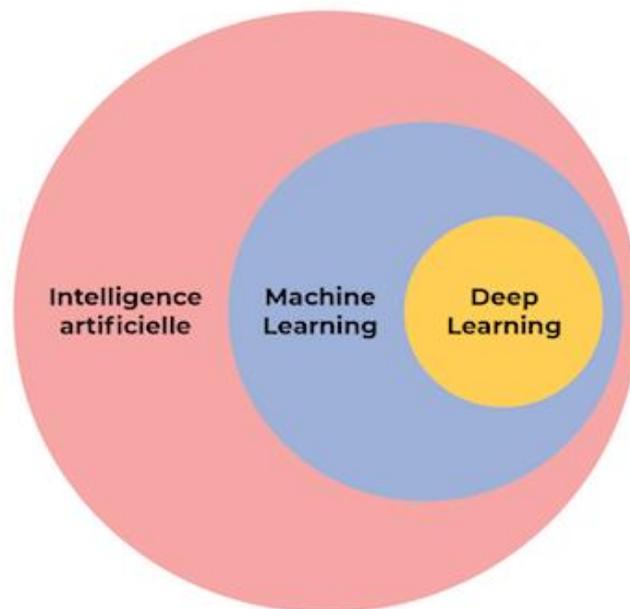


Figure 2.2: Types de l'IA

2.3 Machine Learning (ML)

L'apprentissage automatique, aussi connu sous le nom de "machine learning" en anglais, est un domaine de l'intelligence artificielle (IA) qui permet aux ordinateurs d'apprendre et de s'améliorer automatiquement à partir de données, sans être explicitement programmés.

En d'autres termes, les algorithmes d'apprentissage automatique analysent de grandes quantités de données afin d'identifier des patterns et des relations, puis les utilisent pour effectuer des tâches telles que la classification, la prédiction ou la prise de décision.

Imaginez un algorithme d'apprentissage automatique conçu pour identifier des images de chats. En lui fournissant un ensemble de données d'images contenant des chats et d'autres

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

animaux, l'algorithme apprendra à distinguer les caractéristiques distinctives des chats, comme la forme de leurs oreilles, la texture de leur fourrure et la disposition de leurs yeux.

Par la suite, il pourra utiliser ces connaissances pour identifier des chats dans de nouvelles images qu'il n'a jamais vues auparavant [12].

2.3.1 Types d'apprentissage automatique (ML)

Il existe plusieurs types d'apprentissage automatique, chacun étant adapté à des tâches spécifiques. Voici les trois principaux types:

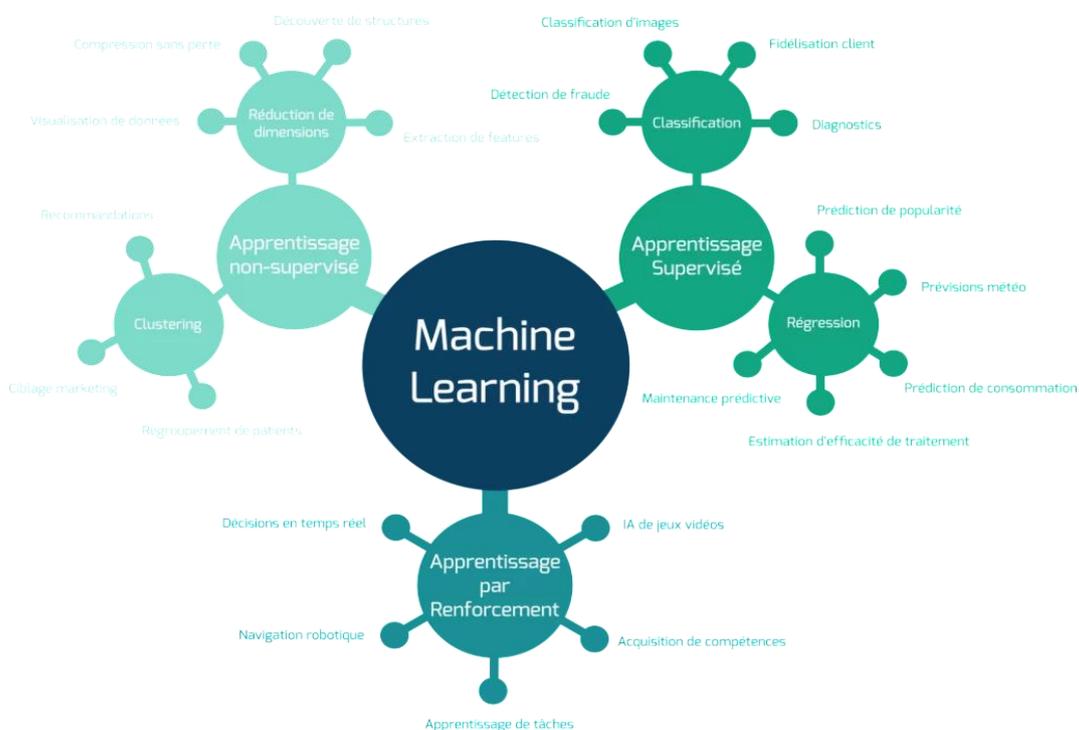


Figure 2.3: Types d'apprentissage automatique

- Apprentissage supervisé

Dans l'apprentissage supervisé, l'algorithme reçoit un ensemble de données d'entraînement où chaque exemple est étiqueté avec la réponse correcte. Par exemple, un ensemble de données d'images de chats et de chiens étiquetés comme "chat" ou "chien". L'algorithme apprend alors à associer les caractéristiques des images aux étiquettes correspondantes.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

- Apprentissage non supervisé

Dans l'apprentissage non supervisé, l'algorithme ne reçoit pas d'étiquettes pour les données d'entraînement. Son objectif est de découvrir des structures et des patterns cachés dans les données. Par exemple, un algorithme d'apprentissage non supervisé pourrait être utilisé pour identifier des groupes de clients ayant des comportements d'achat similaires.

- Apprentissage par renforcement

Dans l'apprentissage par renforcement, l'algorithme apprend par interaction avec son environnement. Il reçoit des récompenses ou des pénalités en fonction de ses actions, et il apprend à choisir les actions qui maximisent sa récompense cumulée. Par exemple, un robot apprenant à marcher peut recevoir une récompense pour chaque pas en avant et une pénalité pour chaque chute.

2.3.2 Applications de l'apprentissage automatique (ML)

L'apprentissage automatique a déjà un impact considérable sur de nombreux domaines de notre vie, notamment :

- **Santé:** diagnostic de maladies, développement de médicaments, analyse d'images médicales, etc.
- **Finance:** détection de fraude, gestion des risques, prédiction du marché boursier, etc.
- **Marketing:** ciblage publicitaire, personnalisation de recommandations, analyse du comportement des clients, etc.
- **Transport:** optimisation du trafic, conduite autonome, systèmes de navigation intelligents, etc.
- **Industrie:** maintenance prédictive, contrôle de la qualité, optimisation des processus de production, etc.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

2.4 Deep Learning (DL)

L'apprentissage profond est un sous-domaine de l'apprentissage automatique (ML) qui se concentre sur des algorithmes inspirés de la structure et du fonctionnement des réseaux neuronaux du cerveau. Il est particulièrement efficace pour des tâches telles que la reconnaissance d'images et de parole, le traitement du langage naturel et d'autres problèmes complexes de reconnaissance de formes.

Les modèles d'apprentissage profond sont composés de plusieurs couches de nœuds interconnectés, appelés neurones ou unités artificielles. Chaque couche traite les informations transmises par la couche précédente, permettant au réseau d'apprendre des fonctionnalités de plus en plus abstraites à mesure qu'il approfondit. Ces réseaux sont généralement formés à l'aide de grandes quantités de données, le modèle ajustant ses paramètres via un processus appelé rétro propagation afin de minimiser la différence entre ses prédictions et les cibles réelles [14].

2.4.1 Avantages de l'apprentissage profond

- **Capacité d'apprentissage automatique des caractéristiques** : L'apprentissage profond ne nécessite pas d'ingénierie manuelle complexe pour extraire des caractéristiques des données. Le réseau apprend automatiquement des représentations pertinentes à partir des données brutes.
- **Gestion efficace de données complexes** : Les architectures profondes permettent de traiter des données de grande taille et de haute dimensionnalité, comme les images, le texte ou les données séquentielles.
- **Amélioration des performances** : L'apprentissage profond a permis d'obtenir des résultats de pointe dans de nombreux domaines, surpassant souvent les approches traditionnelles d'apprentissage automatique.

2.4.2 Applications de l'apprentissage profond

L'apprentissage profond a un large éventail d'applications dans divers domaines, notamment :

- **Vision par ordinateur** : Reconnaissance d'objets, classification d'images, détection d'objets, segmentation d'images, reconnaissance faciale, génération d'images.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

- **Traitement du langage naturel** : Traduction automatique, reconnaissance vocale, analyse de sentiments, chatbots, génération de texte.
- **Robotique** : Contrôle de robots, navigation autonome.
- **Finance** : Prédiction du marché boursier, détection de fraude.
- **Santé** : Diagnostic médical, développement de médicaments, analyse d'images médicales.
- **Média et divertissement** : Recommandation de contenu, filtrage d'images et de vidéos.

2.5 Réseau de neurones Artificielles (Artificiel Neural Network)

Un réseau de neurones, également appelé artificiel neural network (ANN), est un système informatique vaguement inspiré par la structure et la fonction du cerveau humain [15].

2.5.1 Architecture

L'architecture d'un réseau de neurones artificiels définit la manière dont les neurones sont organisés et connectés entre eux. Elle détermine le flux d'informations dans le réseau et influence ses capacités d'apprentissage et de généralisation.

Les éléments clés de cette architecture:

2.5.1.1 Les neurones artificiels: Les unités de base du réseau, qui s'inspirent des neurones biologiques. Ils reçoivent des entrées, les traitent à l'aide d'une fonction d'activation et produisent une sortie.

2.5.1.2 Les couches: Les neurones sont organisés en couches, qui sont interconnectées. On distingue généralement trois types de couches :

- **Couche d'entrée:** Cette couche reçoit les données d'entrée, qui peuvent être des valeurs numériques ou des caractéristiques extraites d'un ensemble de données. Chaque neurone dans cette couche représente une caractéristique d'entrée.
- **Couches cachées:** Ces couches intermédiaires sont responsables de l'extraction des caractéristiques et de la représentation des modèles dans les données d'entrée. Chaque couche cachée est composée de plusieurs neurones, et chaque neurone est connecté à chaque neurone

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

de la couche précédente et de la couche suivante. Les réseaux de neurones profonds ont généralement plusieurs couches cachées.

- **Couche de sortie:** Cette couche produit les résultats finaux du réseau de neurones. La configuration de cette couche dépend de la nature de la tâche à accomplir. Par exemple, pour une tâche de classification binaire, une seule sortie peut être utilisée avec une fonction d'activation comme la sigmoïde. Pour une classification multiclasse, plusieurs sorties avec une fonction d'activation comme la softmax peuvent être utilisées. Pour la régression, une seule sortie peut être utilisée sans fonction d'activation spécifique

2.5.1.3 Les connexions : Les neurones sont reliés entre eux par des synapses, représentées par des poids. Ces poids déterminent la force de la connexion entre deux neurones et sont ajustés lors de l'apprentissage du réseau.

2.5.2 Types de réseaux de neurones

Il existe de nombreux types de réseaux de neurones, chacun avec sa propre architecture et ses propres applications. Parmi les types de réseaux de neurones les plus courants, on trouve:

- **Réseaux de neurones multicouches perceptrons (MLP):** Ce sont les réseaux de neurones les plus simples. Ils sont composés de couches entièrement connectées de neurones artificiels.

- **Réseaux de neurones convolutifs (CNN):** Ils sont utilisés pour le traitement d'images et de vidéos. Ils sont composés de couches de neurones convolutifs qui extraient des caractéristiques locales des données d'entrée.

- **Réseaux de neurones récurrents (RNN):** Ils sont utilisés pour traiter des données séquentielles, telles que le texte ou la parole. Ils sont capables de capturer des dépendances temporelles dans les données.

2.6 La différence entre réseau de neurones et deep learning

L'apprentissage profond et les réseaux de neurones ont tendance à être utilisés de manière interchangeable, le « profond » dans l'apprentissage profond se réfère à la profondeur des couches dans un réseau de neurones. Un réseau de neurones composé de plus de trois couches, qui inclurait les entrées et les sorties, peut être considéré comme un algorithme

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

d'apprentissage profond. Un réseau de neurones qui n'a que deux ou trois couches est juste un réseau de neurones de base.

2.7 Réseaux de neurones convolutifs (CNN)

Un réseau neuronal convolutif (CNN) est un type spécial de réseau neuronal d'apprentissage profond caractérisé par le traitement de données disposées dans une structure en forme de grille, telle qu'une image.

Contrairement aux réseaux de neurones traditionnels, les CNN profitent des caractéristiques uniques de ces données pour apprendre automatiquement des fonctionnalités pendant le processus de formation.

Cela le rend particulièrement puissant pour des tâches telles que la reconnaissance d'images, la classification d'images et l'analyse vidéo [16].

2.7.1 L'architecture du CNN

Les architectures de réseaux neuronaux convolutifs (CNN) sont conçues pour la reconnaissance de formes et l'analyse de données basées sur une grille telles que des images.

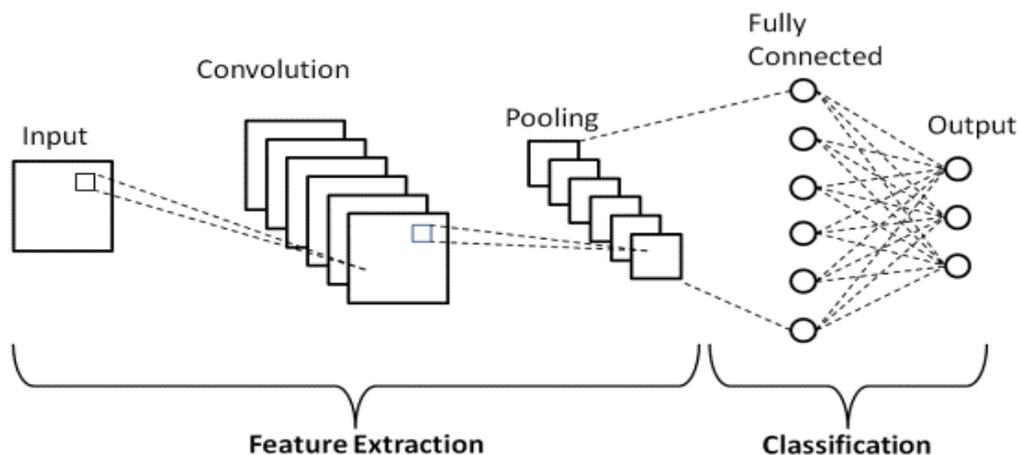


Figure 2.4: Architecture du CNN

Les principaux éléments de son architecture sont :

- **Couches convolutives** : Ces couches appliquent des filtres convolutifs aux données d'entrée.

Un filtre est une petite matrice de nombres qui se déplace sur l'image et calcule une somme pondérée de pixels à chaque emplacement.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

Cela vous permet d'extraire des fonctionnalités locales à partir d'images.

- **Couches pooling (sous-échantillonnage)** : Ces couches réduisent la dimensionnalité des données en regroupant les pixels adjacents. Cela réduit le nombre de paramètres dans le modèle et le rend moins sensible au bruit.

- **Couches entièrement connectées** : Ces couches connectent chaque neurone de la couche précédente à chaque neurone de la couche suivante. Ceux-ci sont utilisés pour classer les données d'entrée.

2.7.2 Les modèles de CNN

De nombreux modèles CNN populaires ont été développés au fil des ans, chacun avec ses propres forces et faiblesses [17].

Voici quelques-uns des modèles les plus populaires :

- **AlexNet** : AlexNet a été l'un des premiers modèles CNN à connaître un grand succès dans le domaine de la reconnaissance d'images. Il a remporté le concours ImageNet 2012 avec une large marge sur les autres modèles. AlexNet est un modèle relativement profond avec 5 couches convolutives et 3 couches entièrement connectées.

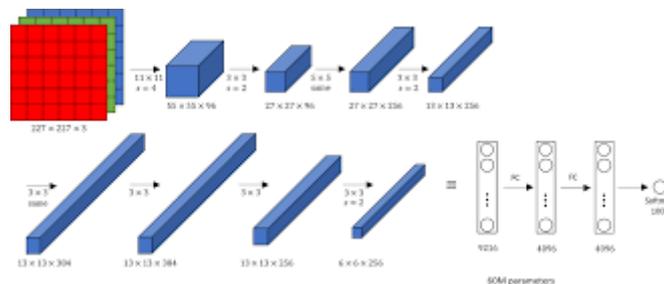


Figure 2.5: AlexNet

- **VGGNet** : VGGNet est une famille de modèles CNN basés sur l'architecture AlexNet.

Le modèle VGGNet comporte un grand nombre de couches convolutives et peut extraire des caractéristiques plus complexes à partir d'images. VGG16 et VGG19 sont deux des modèles VGGNet les plus populaires.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

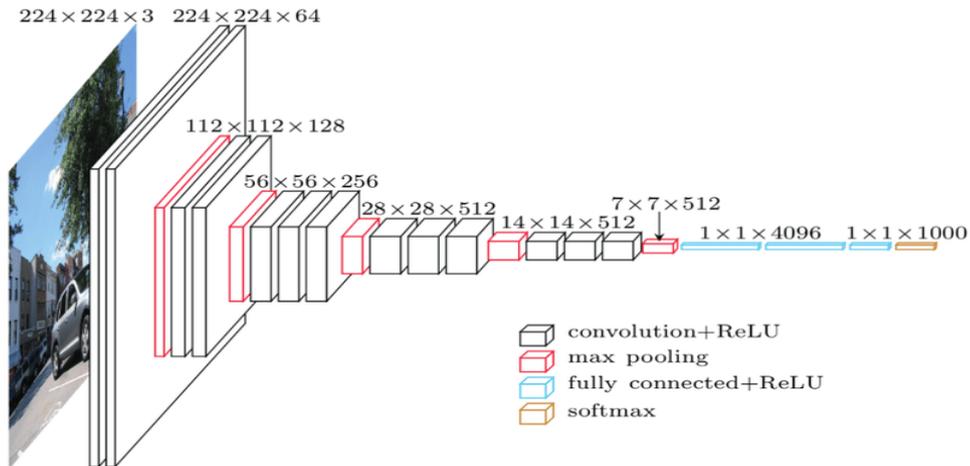


Figure 2.6: VGGNet

- **GoogLeNet** : GoogLeNet est un modèle CNN qui utilise l'architecture Inception pour réduire le nombre de paramètres et améliorer les performances. L'architecture Inception utilise plusieurs petits filtres convolutifs en parallèle pour extraire des fonctionnalités à différentes échelles.

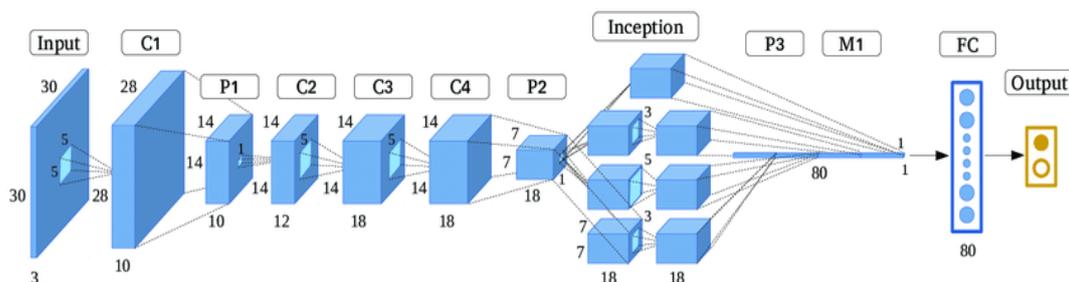


Figure 2.7: GoogleNet

- **ResNet** : ResNet est une famille de modèles CNN qui exploite les connexions résiduelles pour améliorer la profondeur du réseau sans augmenter la difficulté de formation. La connectivité résiduelle permet aux informations de se propager plus facilement sur le réseau, permettant ainsi d'entraîner des modèles plus profonds avec de meilleures performances.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

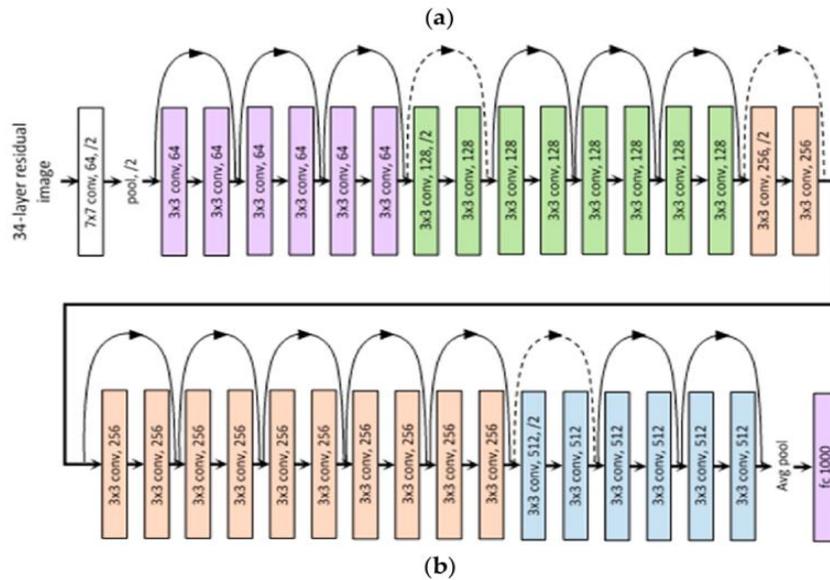


Figure 2.8: ResNet

- **MobileNet** : MobileNet est une famille de modèles CNN optimisés pour les appareils mobiles. Le modèle MobileNet utilise des couches convolutionnelles profondes et des couches de pooling dilatées pour réduire le nombre de paramètres et le coût de calcul.

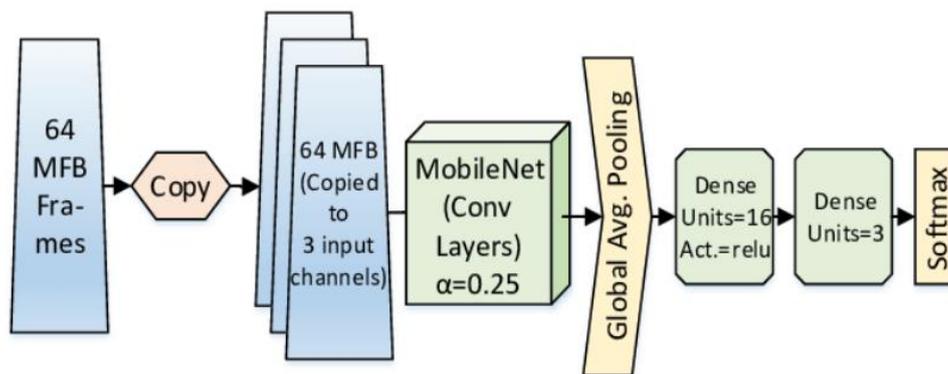


Figure 2.9: MobileNet

- **EfficientNet** : EfficientNet est une famille de modèles CNN qui utilise une approche de recherche automatisée pour trouver des architectures optimales pour différents niveaux de précision et de complexité. Les modèles EfficientNet offrent un bon compromis entre précision et efficacité, ce qui en fait un choix populaire pour les applications mobiles et embarquées.

CHAPITRE.2 : Les méthodes utilisées pour la détection des maladies des plantes

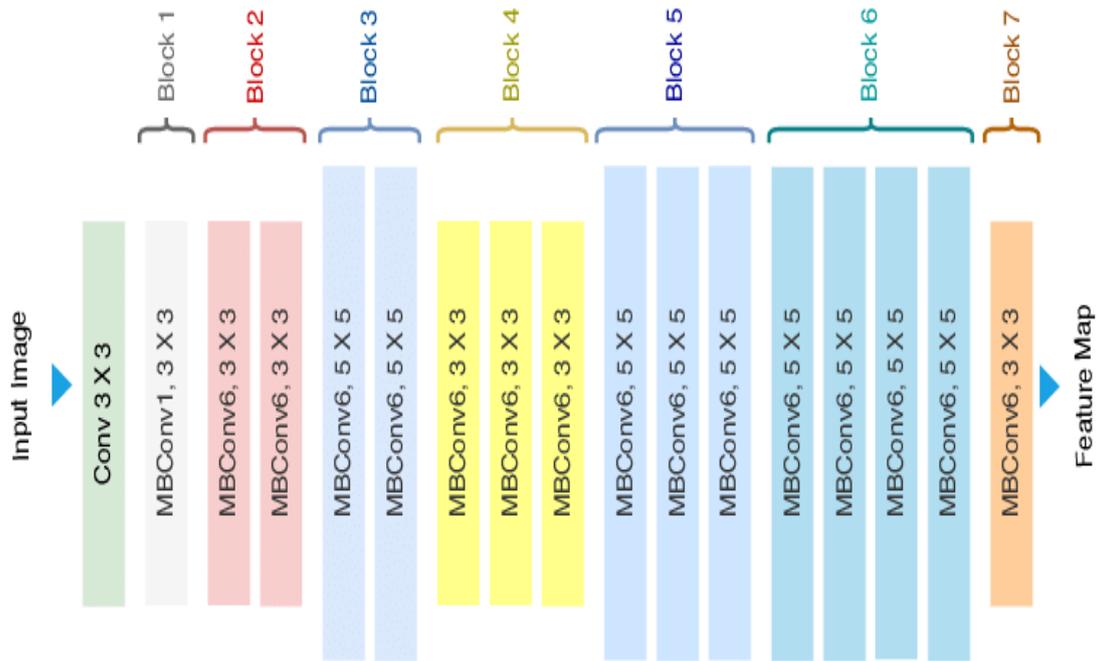


Figure 2.10: EfficientNet

- **LeNet:** LeNet, et plus précisément LeNet-5, est un réseau neuronal convolutif (CNN) simple mais révolutionnaire, développé par Yann LeCun et ses collaborateurs en 1998. Il s'agit de l'un des premiers CNN à avoir été mis au point et il a joué un rôle crucial dans l'essor de l'apprentissage profond.

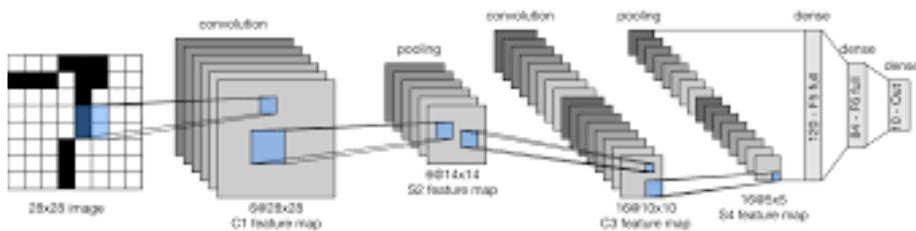


Fig2.11: LeNet.

2.8 Conclusion

Dans ce chapitre, nous avons initié notre étude en introduisant le concept d'intelligence artificielle, l'apprentissage automatique, ses types et applications.

Puis, dans la deuxième partie, nous avons présenté le deep learning, ses avantages, applications et ses modèles de réseaux neuronaux avec leurs architectures et modèles. Dans le chapitre suivant, nous présenterons notre étude sur la détection des maladies des plantes à l'aide de différents modèles d'apprentissage profond, ainsi qu'une comparaison des résultats obtenus à partir de différentes architectures pour chaque modèle. Enfin, nous allons faire une explication légère de notre plate-forme.

CHAPITE.3

Conception et Réalisation

3.1 Introduction

Ce chapitre présente la solution que nous proposons pour résoudre le problème de la détection précoce des maladies des plantes. Commençons par la partie théorique puis passons à la partie pratique. Nous y décrivons le modèle CNN utilisé, la conception du système, l'environnement, les bibliothèques, les expériences et l'évaluation des résultats. Enfin, j'aimerais conclure par une introduction au site Web du système de reconnaissance.

3.2 Détection et Classification des maladies des plantes Utilisant VGG-16, MobileNetV1 et LeNet5

3.2.1 Définition

Nous avons mené une étude de recherche en utilisant des modèles de réseaux neuronaux convolutifs (CNN) pré-entraînés, à savoir VGG16 , MobileNetV1 et LeNet5 , pour analyser un ensemble de données d'images de plantes accessibles au public sur Kaggle.

Notre processus comprenait l'application des deux techniques de prétraitement pour améliorer les fonctionnalités de précision de la reconnaissance. Pour l'expérience, nous avons collecté un échantillon de 16 012 images de plantes avec 10 étiquettes de classe [32].

3.2.2 Problèmes et contraintes

En combinant la puissance de l'apprentissage profond avec une approche conviviale, notre étude porte sur le système d'aide aux agriculteurs, aux jardiniers et à tous ceux qui souhaitent protéger la santé de leurs végétaux [21]. Chacune de ces étapes correspond à des classes uniques au sein de la pathologie agriculture [22].

-Fiabilité : Le système doit être fiable et fournir constamment des résultats précis.

-Haute performance rentable : Il devrait atteindre une exécution efficace et rapide tout en maintenant les coûts bas.

-Capacité d'apprentissage tout au long de la vie : permettre au système d'acquérir continuellement de nouvelles connaissances et améliorer au fil du temps.

L'objectif ici est d'avoir un système qui réalise les meilleurs taux de performance selon les contraintes spécifiées (capacité de calcul et de stockage limités).

3.3 Conception de système

Notre système de détection des maladies des plantes s'appuie sur un modèle d'apprentissage profond puissant pour identifier et classifier avec précision les maladies affectant les cultures. Ce modèle, entraîné sur un ensemble de données complet d'images de plantes saines et malades, est capable de reconnaître les motifs visuels subtils et les structures caractéristiques des différentes pathologies.

Lorsqu'un utilisateur soumet une image d'une plante malade, notre système entre en action. L'image est d'abord prétraitée et transformée en un format adapté à l'analyse par le réseau neuronal. Le modèle compare ensuite l'image aux données d'apprentissage, recherchant les correspondances les plus proches. En se basant sur les caractéristiques apprises, le système émet une prédiction quant à la maladie qui affecte la plante.

La comparaison de l'image avec l'ensemble de données joue un rôle crucial dans le processus de diagnostic. En effet, elle permet d'identifier les images les plus similaires à celle de l'utilisateur, augmentant ainsi la fiabilité et la précision du résultat. La figure ci-dessous donne un aperçu de cette architecture.

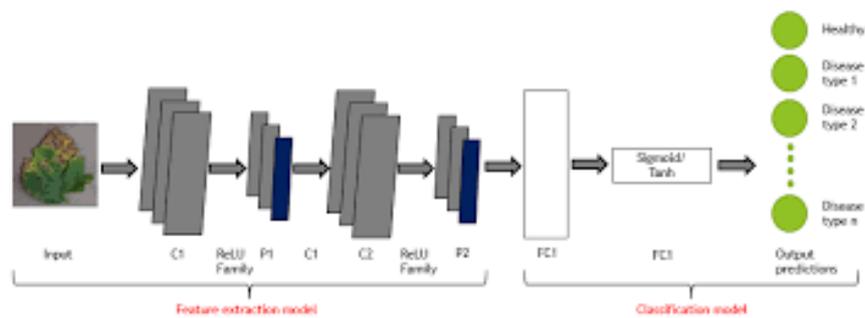


Fig3.1: Architecture de la détection des maladies des plantes en utilisant CNN.

Notre système offre plusieurs avantages :

-Précision accrue: Grâce à l'apprentissage profond, le système est capable de détecter les maladies des plantes avec un haut niveau de précision, même dans des cas complexes ou présentant des symptômes peu évidents.

-Rapidité: Le processus d'analyse est rapide et efficace, permettant aux utilisateurs d'obtenir un diagnostic rapide et de prendre des mesures en temps opportun pour sauver leurs cultures.

-Facilité d'utilisation: L'interface utilisateur est intuitive et simple d'utilisation, ne nécessitant aucune connaissance technique particulière pour son utilisation.

-Polyvalence: Le système peut être utilisé pour identifier un large éventail de maladies affectant différentes cultures.

3.4 Réalisation de système

En passant de la conception du système à sa phase de mise en œuvre, nous commençons par prétraitement des ensembles de données suivi de l'exécution de plusieurs modèles d'apprentissage profond. Enfin, nous présentons notre application développée, ainsi que citer tous les outils pertinents utilisés dans ce projet.

3.4.1 Description et architecture de Dataset

L'ensemble de données (dataset) utilisé pour ce projet a été fourni par Kaggle appelé Plant Village. L'ensemble de données se compose de 20,639 images de plantes de haute qualité (gauche et droite), ces images sont redimensionnées à 256 x 256 pixels, ce qui les rend faciles à utiliser avec de nombreux modèles d'apprentissage profond pré-entraînés.

Toutes les images sont enregistrées dans des dossiers respectifs en fonction de leur état de santé (healthy, bacterial-spot, latehealthy, etc...). Les images de feuilles de plantes dans l'ensemble de données sont classées en 15 catégories (classes), comme le montre la figure 3.2 ci-dessus.

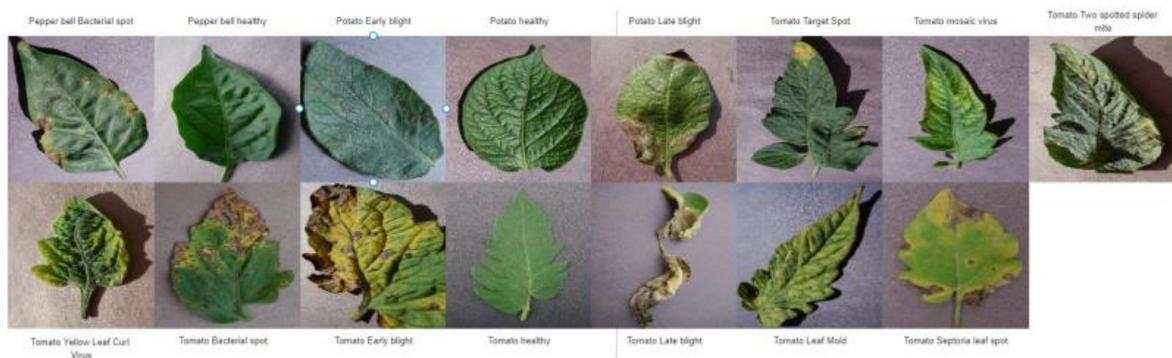


Fig3.2: Échantillons de l'ensemble de données adopté.

3.4.2 Prétraitement des ensembles de données

Pour notre première expérience, nous avons essayé de promouvoir la détection des maladies des plantes, et avons suivi un plan précis. Nous avons nourri une variété de données avec des explications précises représentant différents stades de la maladie. Ensuite, nous avons normalisé les valeurs de pixels pour assurer la cohérence et diviser l'ensemble de données en kits de train, validation et test. En normalisant les caractéristiques et les modèles pré-entraînés, nous avons extrait des caractéristiques pertinentes pour une détection et une classification précises des maladies affectant les plantes.

- Acquisition de données

Après une acquisition réussie, nous avons obtenu un jeu de données qui répond à nos exigences. Comprend une variété d'images de plantes avec des explications précises de la morbidité virale et ce dernier a assuré que notre processus de sélection rigoureux comprenait différentes étapes de la maladie. Cela permet à nos modèles d'apprendre et d'identifier efficacement les tendances et les indicateurs de morbidité des plantes, améliorant ainsi la détection et la compréhension de la maladie.

- Train, Test, Validation

Diviser l'ensemble de données prétraité en ensembles de train, de validation et de test. Train comprenant 60% de l'ensemble de données, qui est utilisé pour former les modèles VGG16 et MobileNetV1. Alors que les ensembles de validation et de test représentent 20% des données, utilisés pour évaluer la performance des modèles sur des données invisibles et ont la capacité de faire des prédictions.

-L'optimisation de hyperparamètres

L'optimisation des hyperparamètres est le processus de recherche du meilleur ensemble de valeurs d'hyperparamètres pour notre modèle. Où les hyperparamètres sont les paramètres de configuration qui influencent le processus de training, tels que le taux d'apprentissage, la taille du lot, le nombre de couches cachées. L'objectif de l'optimisation des hyperparamètres est de trouver la combinaison optimale de ces paramètres qui donne les meilleures performances sur notre jeu de données. Ce processus contribue généralement à ce que le

modèle puisse atteindre une précision, une vitesse de convergence et une capacité de généralisation améliorées.

3.5 Implémentation et déploiement de modèles d'apprentissage profond

Dans cette section, nous présenterons les outils et technologies utilisés pour développer notre système.

3.5.1 VGG16:

Dans le contexte de la détection des maladies des plantes, VGG16 peut être utilisé comme un outil puissant pour classer les images de plantes en fonction de la présence ou de l'absence de maladies [18]. Voici comment cela pourrait fonctionner :

-Collecte des données: Vous auriez besoin d'un grand ensemble d'images de plantes, certaines présentant des maladies et d'autres non. Ces images doivent être étiquetées de manière appropriée.

-Prétraitement des données: Les images doivent être redimensionnées à la taille d'entrée attendue par VGG16, généralement 224x224 pixels. De plus, il est courant de normaliser les valeurs de pixel pour les mettre à l'échelle entre 0 et 1.

-Entraînement du modèle: Vous pouvez utiliser la partie convolutionnelle pré-entraînée de VGG16 comme extracteur de caractéristiques. Cela signifie que vous conserverez les poids de toutes les couches de convolution de VGG16 et ajouterez vos propres couches entièrement connectées à la fin pour la classification des maladies. Vous entraînerez ensuite ce modèle sur vos données d'entraînement.

-Évaluation du modèle: Une fois le modèle entraîné, vous pouvez l'évaluer sur un ensemble de données de validation pour voir à quel point il est performant dans la détection des maladies des plantes. Vous pouvez utiliser des métriques telles que la précision, le rappel et la F-mesure pour évaluer ses performances.

-Optimisation du modèle: En fonction des performances de votre modèle, vous pouvez ajuster différents paramètres tels que le taux d'apprentissage, la taille du lot et le nombre de couches ajoutées pour améliorer ses performances.

-Déploiement du modèle: Une fois que vous êtes satisfait des performances de votre modèle, vous pouvez le déployer dans des applications réelles pour la détection automatique des maladies des plantes.

3.5.2 MobileNetV1:

MobileNetV1 est une autre architecture de réseau de neurones convolutifs qui a été conçue pour être légère en termes de calculs et de paramètres, ce qui la rend particulièrement adaptée aux appareils mobiles et aux applications embarquées [19].Voici comment vous pourriez utiliser MobileNetV1 dans la détection des maladies des plantes :

-Collecte des données: Tout d'abord, vous devez collecter un ensemble de données d'images de plantes, certaines avec des maladies et d'autres sans. Ces images doivent être étiquetées correctement.

-Prétraitement des données: Comme pour tout autre modèle de détection d'images, vous devez redimensionner et normaliser vos images pour les préparer à être utilisées comme entrée pour le modèle MobileNetV1.

-Entraînement du modèle: Vous pouvez utiliser MobileNetV1 comme un extracteur de caractéristiques pré-entraîné ou bien entraîner le modèle à partir de zéro en l'initialisant avec des poids aléatoires. La première option est généralement préférée, car MobileNetV1 a été pré-entraîné sur de grandes bases de données d'images, ce qui lui permet de capturer des caractéristiques générales des images. Vous ajouterez ensuite vos propres couches entièrement connectées pour la classification des maladies et entraînerez le modèle sur vos données d'entraînement.

-Évaluation du modèle: Une fois que le modèle est entraîné, vous devez l'évaluer sur un ensemble de données de validation pour évaluer ses performances. Vous pouvez utiliser des métriques telles que la précision, le rappel et la F-mesure pour évaluer la capacité du modèle à détecter les maladies des plantes.

-Optimisation du modèle: Vous pouvez ajuster différents paramètres du modèle, tels que le taux d'apprentissage, la taille du lot et la complexité du modèle, pour améliorer ses performances.

-Déploiement du modèle: Une fois que vous êtes satisfait des performances du modèle, vous pouvez le déployer dans des applications réelles pour la détection automatique des maladies des plantes.

3.5.3 LeNet5:

LeNet5 peut toujours être efficace dans certains contextes, en particulier lorsque les ressources computationnelles sont limitées [20].Voici comment vous pourriez utiliser LeNet5 dans la détection des maladies des plantes :

-Collecte des données: Tout d'abord, vous devez collecter un ensemble de données d'images de plantes, étiquetées avec des informations sur les maladies présentes ou non.

-Prétraitement des données: Comme pour tout modèle de détection d'images, vous devez prétraiter vos données en les redimensionnant à une taille appropriée et en normalisant les valeurs de pixel.

-Entraînement du modèle: Vous pouvez utiliser l'architecture LeNet5 comme modèle de base. LeNet5 est composé de deux couches de convolution suivies de couches de sous-échantillonnage (pooling), puis de trois couches entièrement connectées. Vous ajusterez la sortie de la dernière couche entièrement connectée pour correspondre au nombre de classes de maladies que vous essayez de détecter. Ensuite, vous entraînerez le modèle sur vos données d'entraînement.

-Évaluation du modèle: Une fois que le modèle est entraîné, vous devez l'évaluer sur un ensemble de données de validation pour évaluer ses performances. Vous pouvez utiliser des métriques telles que la précision, le rappel et la F-mesure pour évaluer la capacité du modèle à détecter les maladies des plantes.

-Optimisation du modèle: Comme avec tout modèle d'apprentissage automatique, vous pouvez ajuster différents hyperparamètres, tels que le taux d'apprentissage ou le nombre de filtres dans les couches de convolution, pour améliorer les performances du modèle.

-Déploiement du modèle: Une fois que vous êtes satisfait des performances du modèle, vous pouvez le déployer dans des applications réelles pour la détection automatique des maladies des plantes.

3.6 Évaluation, expérimentation et essais

L'évaluation, l'expérimentation et les essais sont essentiels pour tester et valider de nouvelles technologies, notamment dans la détection des maladies des plantes. Ces étapes permettent de mesurer l'efficacité, d'identifier les points forts et les limites des méthodes, et d'ajuster les approches pour assurer qu'elles répondent aux besoins des agriculteurs de manière pratique et fiable.

3.6.1 Les environnements utilisés et les bibliothèques utilisées

Les environnements de développement et les bibliothèques utilisés jouent un rôle crucial dans la mise en œuvre des technologies avancées. Par exemple, les environnements de programmation comme Python, associés à des bibliothèques telles que TensorFlow, Keras ..., permettent de développer et de tester des algorithmes d'intelligence artificielle pour la détection des maladies des plantes. Ces outils fournissent les fonctionnalités nécessaires pour traiter de grandes quantités de données, entraîner des modèles d'apprentissage automatique et analyser les résultats de manière efficace et précise.

3.6.1.1 Environnements virtuels et environnements matériels

Les environnements virtuels et matériels sont essentiels pour le développement et le déploiement de technologies avancées. Les environnements virtuels, comme les machines virtuelles et les conteneurs, permettent de simuler divers scénarios et de tester les applications de manière flexible et isolée. Les environnements matériels, comprenant des dispositifs physiques comme les capteurs, drones et caméras, sont utilisés pour recueillir des données réelles et exécuter les solutions développées en conditions pratiques. Ensemble, ils garantissent que les technologies sont robustes et efficaces dans des situations réelles.

Environnement virtuel, nous avons utilisé :

- **Python**

Nous avons choisi Python (v3.11) car c'est un langage de programmation open source préféré par les professionnels de l'informatique. L'attrait de Python réside dans ses nombreuses fonctionnalités qui permettent aux développeurs de se concentrer sur l'art plutôt que sur la mécanique. Python s'est fait un nom dans la gestion d'infrastructures, l'analyse de données et le développement de logiciels. Cela a amélioré le processus et libéré les

développeurs des langages obsolètes et souvent lents. Par conséquent, l'écriture et le développement en Python sont connus pour leur vitesse d'exécution rapide par rapport à ses concurrents [30].

- **Visual Studio Code**

Visual Studio Code (VS Code) est un éditeur de code source multiplateforme gratuit, léger et développé par Microsoft. Cela permet et permet la création de pages Web HTML et CSS.

- **Google Colab**

Google Colab (également connu sous le nom de Google Colaboratory) est un environnement interactif de développement et de partage d'ordinateurs portables basé sur le cloud qui permet aux utilisateurs d'écrire, d'exécuter et de collaborer sur du code Python sans installer de logiciel supplémentaire. Utiliser plusieurs bibliothèques [31]

- **Kaggle**

Kaggle Notebook est un environnement informatique en ligne pour la science des données et l'apprentissage automatique ou profond qui vous permet de créer, partager et collaborer sur du code Python, des bibliothèques populaires et des ensembles de données [32].

Les environnements matériels que nous avons utilisés pour exécuter le code Python sur Google Colab et Kaggle Notebook /

- **RAM** 2.7 /12.7 GB.
- **GPU** 0.6/15.0 GB.
- **Disque** 27.2 /78.2 GB.
- **CPU** Intel(R) Core (TM) i5-7300Q CPU @2.50GHz.

3.6.1.2 Les bibliothèques employées

- **TensorFlow**

Tensorflow est une bibliothèque développée par Google spécialisée dans la formation et le développement de modèles de deep learning. Tensorflow propose une API qui permet l'implémentation d'architectures profondes très complexes de manière simple et rapide. Nous

utilisons Tensorflow pour implémenter et tester différentes configurations du modèle de deep learning [29].

- **Keras**

Keras est le cadre le plus largement utilisé. Il s'agit d'une bibliothèque open-source basée sur Python qui permet de construire facilement et rapidement des réseaux de neurones et des modèles d'apprentissage automatique, en tirant parti des principaux frameworks tels que Tensorflow et Pytorch. Keras était nécessaire pour la mise en œuvre des modèles de prédiction LSTM et GRU, ainsi que pour le prétraitement des données [26].

- **Numpy**

NumPy est une bibliothèque Python open source utilisée pour l'informatique numérique. Il fournit un objet de tableau multidimensionnel puissant et un large éventail de fonctions pour manipuler des tableaux et effectuer des opérations mathématiques. NumPy est couramment utilisé dans les applications scientifiques et d'analyse de données en raison de son efficacité dans la gestion de grandes bases de données. Il offre des opérations numériques optimisées, des capacités de diffusion et une intégration avec d'autres bibliothèques. NumPy était nécessaire dans le prétraitement pour l'extraction de fonctionnalités et l'analyse des données [27].

3.6.2 Les paramètres d'évaluation

Il y a plusieurs paramètres d'évaluation établis dans la littérature qui sont basés sur la matrice de confusion pour chaque classe, offrant quatre éléments d'information importants en termes de rappel et précision :

- **Table de confusion**

Le tableau de confusion est un tableau utilisé pour évaluer le rendement d'un modèle de classification. Il s'agit d'une matrice avec des lignes et des colonnes représentant les catégories réelles et prévues. Chaque cellule dans la matrice représente le nombre d'événements où les classes réelles et prévues sont les mêmes. Il montre le nombre de « Vrai

positif (TP), « Faux positif (FP) », « Vrai Négatif (TN) et « Faux négatif (FN) » comme indiqué ci-dessous:

		Effective	
		Vrais	Faux
La prévision	Vrai	Vrai positif (VP)	Faux positif (FP)
	Faux	Faux négatif (FN)	Vrai négatif (VN)

Tab3.1: Structure de la matrice de confusion .

- **Précision**

Proportion d'observations correctement prédites et classées par rapport au total

$$Accuracy = \frac{TP+TN}{TP+TN+FN+F} \quad (3.1)$$

- **Taux d'erreur (ER)**

Le taux d'erreur est la fraction de cas mal catégorisés dans un modèle de classification qui représente l'erreur globale de la classification.

$$ER = 1-Accuracy \quad (3.2)$$

- **Rappel (sensibilité)**

Sensibilité ou taux de vrais positifs, c'est la proportion de véritables prédictions positives par rapport au total positif cas dans l'ensemble de données.

$$Rappel = \frac{TP}{FP+TN} \quad (3.3)$$

- **Précision**

Il calcule la proportion d'événements positifs anticipés avec précision parmi tous les événements prédits. événements positifs.

$$Précision = \frac{tp}{tp+fp} \quad (3.4)$$

- **Test et interprétations**

Dans notre méthode, nous répartissons le premier dataset en 70% pour la phase de formation, 20% pour la validation et 20% pour la phase de test. En outre, en utilisant VGG16 et MobileNetV1.

Modèle	VGG16		
	Train	Val	Test
C=1*1 MP={1*1 , 2*2}	100%	100%	100%
C=2*2 MP={1*1 , 2*2}	100%	100%	100%
C=3*3 MP={1*1 , 2*2}	100%	100%	100%
C=5*5 MP={1*1 , 2*2}	100%	100%	100%

Tab3.2: Résultats des essais sur le groupe de données utilisant VGG16.

Modèle	MobileNetV1		
	Train	val	Test
C=1*1 MP={1*1 , 2*2}	100%	100%	100%
C=2*2 MP={1*1 , 2*2}	100%	100%	100%
C=3*3 MP={1*1 , 2*2}	100%	100%	100%
C=5*5 MP={1*1 , 2*2}	100%	100%	100%

Tab3.3: Résultats des essais sur le groupe de données utilisant MobileNetV1.

Modèle	LeNet5		
	Train	val	Test
C=1*1 MP={1*1 , 2*2}	100%	100%	100%
C=2*2 MP={1*1 , 2*2}	100%	100%	100%
C=3*3 MP={1*1 , 2*2}	100%	100%	100%
C=5*5 MP={1*1 , 2*2}	100%	100%	100%

Tab3.4: Résultats des essais sur le groupe de données utilisant LeNet5.

Données : C:Convolution,

MP: Max Pooling,

EP: Epochs

Dans notre expérience, afin de réduire le bruit, j'ai cherché à examiner comment les valeurs maximales diffèrent (1*1 et 2*2). Explorer la relation entre max pooling et convolution est l'objectif principal.

Les résultats de nos recherches ont montré que les valeurs de max pooling et convolution ont été très satisfaisantes dans les trois modèles CNN : VGG16, MobileNetV1, LeNet5.

Peu importe à quel point nous modifions les valeurs de convolution et du max pooling, les résultats restent constants à leurs apogée, et nous interprétons cela comme signifiant que le modèle utilisé est excellent.

CHAPITRE.3 Conception et réalisation

En se fondant sur nos observations et notre analyse du tableau 3.4, nous concluons que le VGG16 donne à MobileNetV1 une bonne précision et ajoute également des chiffres de superposition de CNN, et modifie le taux d'apprentissage dans le tableau ci-dessous :

modele	VGG16			MobileNet V1		
	Train	Val	Test	Train	Val	Test
Ep=1	100%	100%	100%	100%	100%	100%
Ep=5	100%	100%	100%	100%	100%	100%
Ep=10	100%	100%	100%	100%	100%	100%
Ep=20	100%	100%	100%	100%	100%	100%

Tab3.5: Résultats des tests sur les données utilisant VGG16 et MobileNetV1.

D'après l'étude en cours, l'utilisation de couches supplémentaires de réseau neuronal synthétique (CNN) permet de traiter les images de manière plus précise que l'utilisation d'images filtrées avec un filtre gaussien.

Cela met en évidence l'efficacité de la structure de CNN dans l'apprentissage instantané de modèles complexes. Les performances de MobileNet , VGG16 et de LeNet5 ont été évaluées après 20 entraînements, et les résultats ont démontré des taux de 100%. Ce résultat met en évidence une corrélation positive entre le nombre d'engagements et les performances des modèles, car plus d'engagements ont entraîné une augmentation des itérations de formation et une amélioration de leur précision dans la traitement des images.

L'utilisation de MobileNetV1 VGG16 a démontré que plusieurs fois a eu un effet bénéfique sur la précision, ce qui permet aux modèles de poursuivre leur apprentissage et d'améliorer leur capacité de classification.

- **Etude comparative**

CHAPITRE.3 Conception et réalisation

Tâche de détection (Tomato)	Références M. Chibani	Résultats CNN	Nos Références	Résultats CNN De nos études
-Target spot -Mosaic virus -Yellow leaf curl Virus -Bacterial spot -Early blight -Late blight -Leaf mold -Petoria leaf spot -Two spotted spider mite	(2023 Ieeexplore .ieee.org)	96.36% La somme des taches	/	100% Pour tous les taches

Tab3.6: Résultats de la comparaison CNN.

Nos résultats ont été comparés à ceux de monsieur Chibani et nous avons constaté que :

Ce tableau montre la comparaison des performances de divers modèles CNN pour détecter les maladies des tomates. Selon les résultats, le modèle CNN des auteurs semble efficace pour détecter diverses maladies, avec des précisions similaires ou supérieures à celles des modèles de référence. En se basant sur les données disponibles, nos résultats semblent être supérieurs à ceux de Mr.Chibani (2023) pour détecter les tâches aux tomates. Mais il convient de souligner que les résultats de détection des tâches peuvent différer selon différents éléments, tels que la qualité des images, la taille du jeu de données et la complexité des tâches. Des évaluations plus poussées.

3.6.3 Courbes d'accuracy

Les courbes de accuracy pour la loss (a) et les courbes de accuracy pour les époques (b) sont présentées ci-dessous pour trois modèles : VGG16, MobileNetV1, LeNet5.

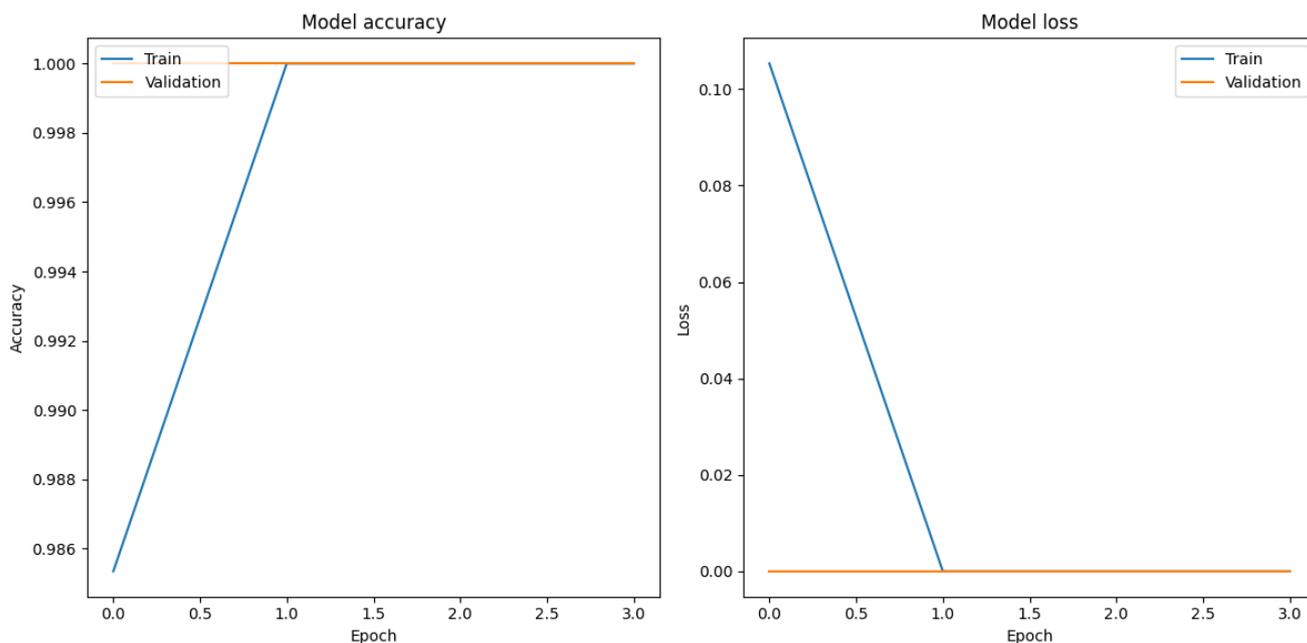


Fig3.3: (a) accuracy et (b) loss obtenue à l'aide de VGG16 et MobileNetV1.

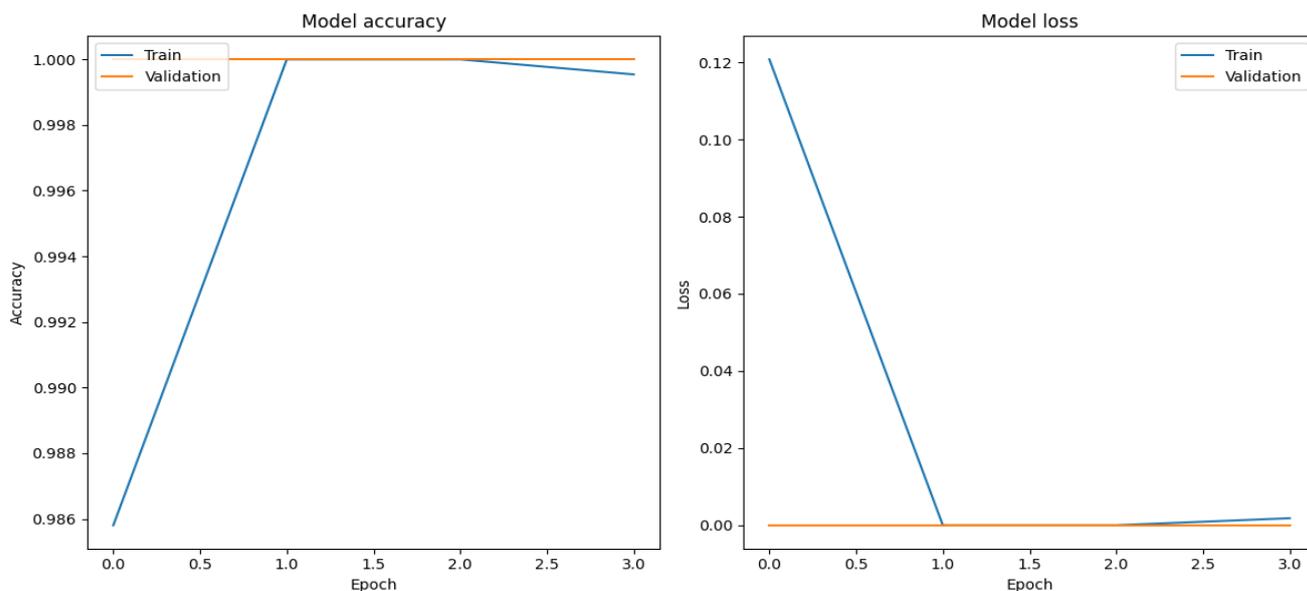


Fig3.4: (a) accuracy et (b) loss obtenue à l'aide de LeNet5.

Accuracy de VGG16 MobileNetV1 atteint 100% après 20 fois, avec 0 loss et en revanche, LeNet5 atteint 100% d'accuracy pour les images grises après 20 fois, avec 0.09 perte. Modèles VGG16 MobileNetV1 LeNet5 détecte et classe les images avec succès. Les faibles valeurs de perte montrent leur capacité à réduire les erreurs et à faire des prédictions précises, ce qui en fait des outils précieux pour détecter les maladies des plantes.

3.7 Présentation de site web

Une fois que nos modèles de deep learning ont été développés et rendus opérationnels pour les utilisateurs, nous avons élaboré une interface conviviale. Il offre la possibilité de traiter les images des plants présentés par les utilisateurs et offre une analyse. La demande est principalement composée de :

3.7.1 Interface utilisateur graphique

- L'interface de téléchargement d'images fundus : l'utilisateur peut télécharger une image via cette interface.
- Interface des résultats : Cette interface affiche les résultats de la prédiction effectuée sur les images soumises, fournissant des informations de diagnostic pertinentes.

Pour mieux comprendre la fonctionnalité de notre site web, nous présenterons quelques captures d'écran illustrant son interface et son principe de fonctionnement.

3.7.2 Téléchargement et vérification de la page

Notre page d'accueil est équipée d'un bouton pour détecter les maladies des plantes, d'une fenêtre montrant les caractéristiques de certaines plantes, d'un bouton pour nous reconnaître directement et enfin d'une fenêtre permettant d'entrer vos informations personnelles. Les figures ci-dessous illustre ce que nous avons dit.

CHAPITRE.3 Conception et réalisation

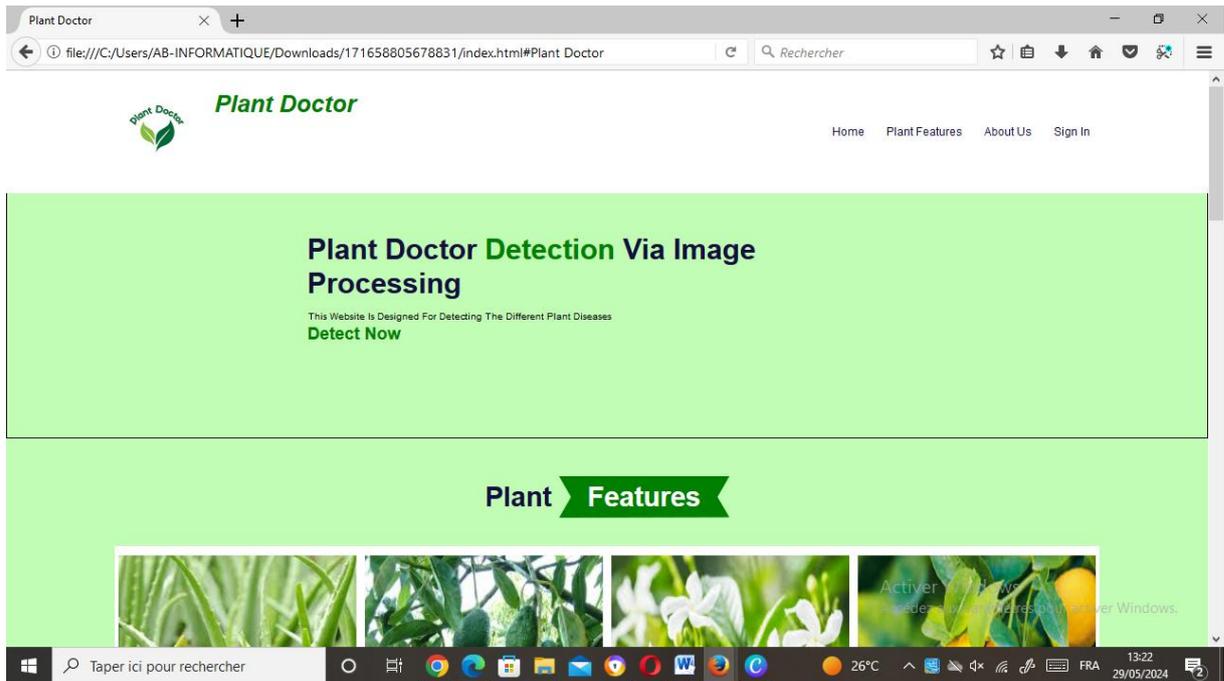


Fig3.5: Une fenêtre pour détecter la maladie de votre plante.

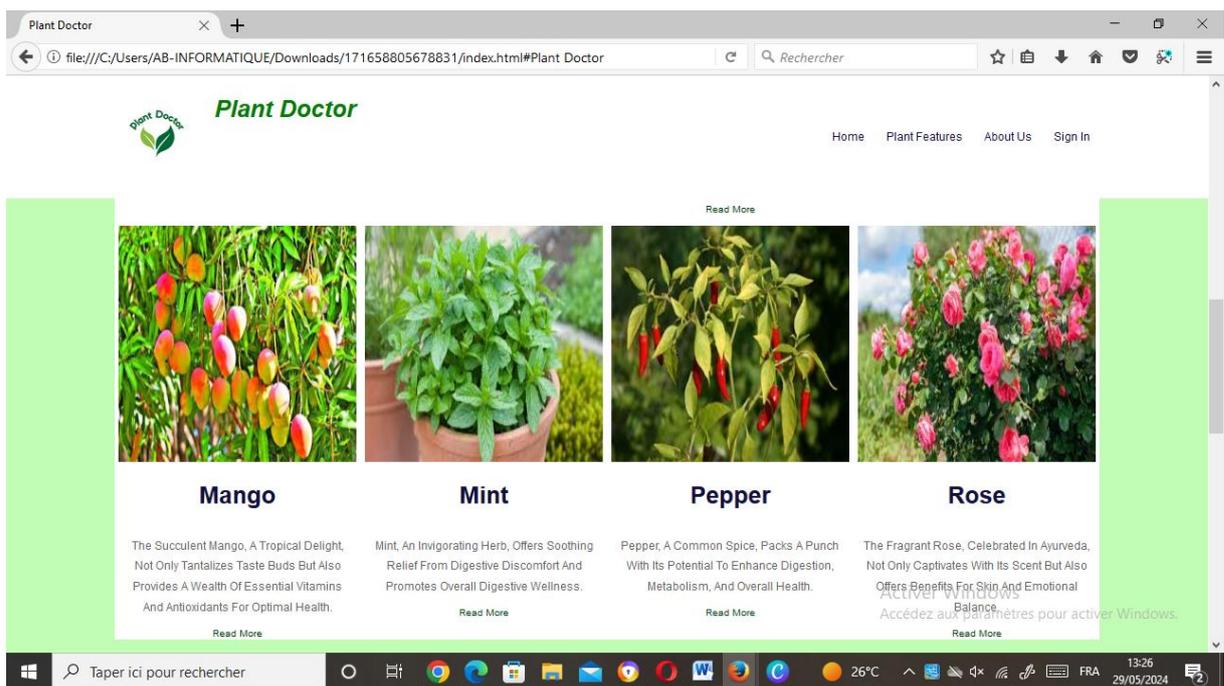


Fig3.6: Une fenêtre pour voir les caractéristiques de certaines plantes.

CHAPITRE.3 Conception et réalisation

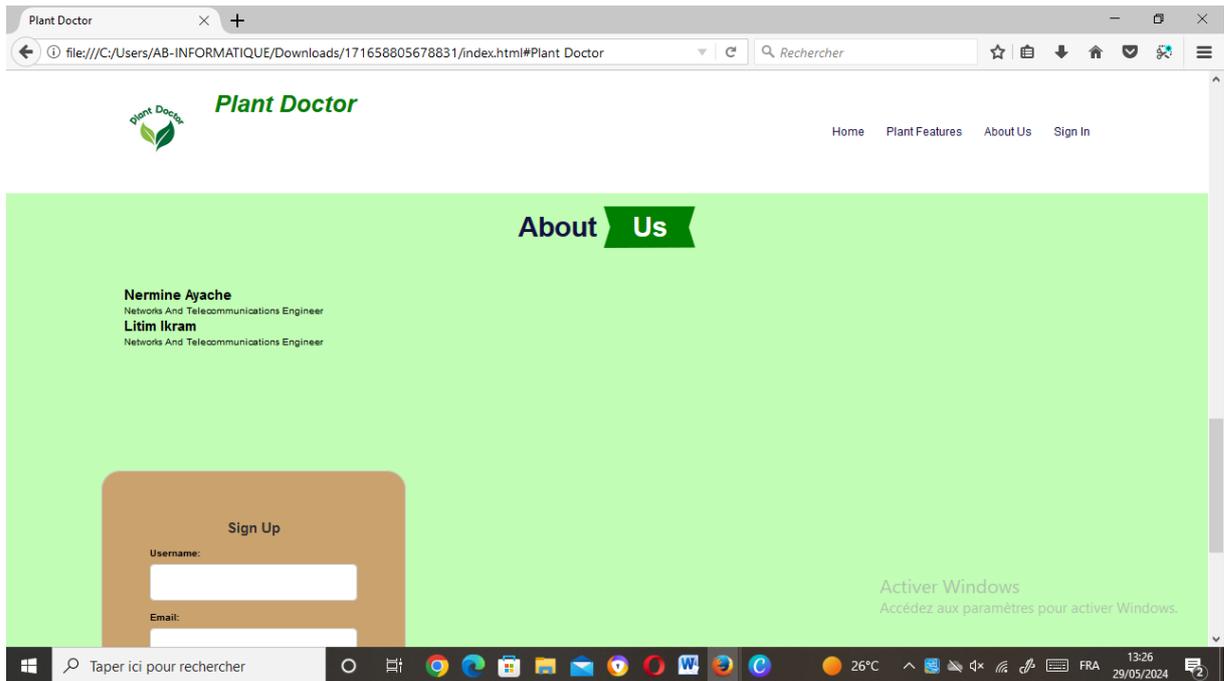


Fig3.7: Une fenêtre pour nous reconnaître.

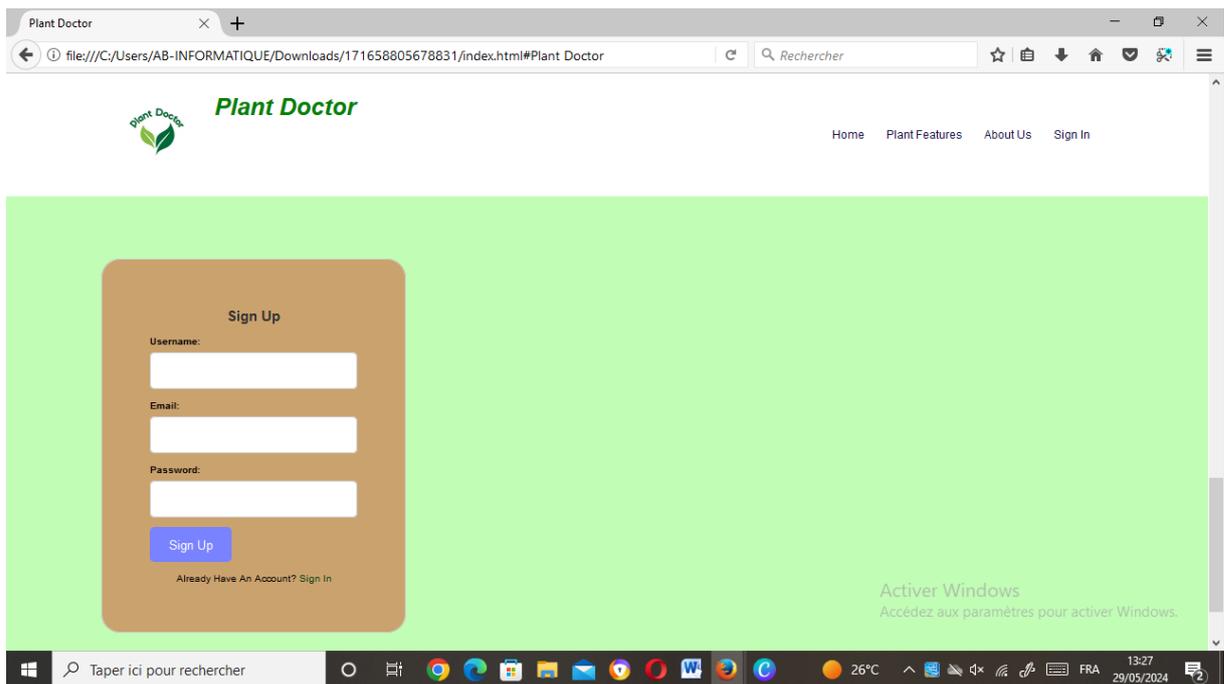


Fig3.8: Une fenêtre d'inscription.

- Logo de site web

Le logo "Plant Doctor" est un logo efficace qui communique clairement le message de notre projet. Il est simple, élégant.



Fig3.9: Logo de notre site web.

- Après avoir effectué diverses études sur la manière de fonctionner une application d'intelligence artificielle qui détecte les maladies des plantes, nous avons remarqué qu'il devrait être associé à un site Web. Cela nous a conduit à partir de la base, qui est ce site qui ne contient que la page d'accueil, et à développer ce site pour créer une application qui détecte les maladies des plantes à très bientôt.

3.8 Conclusion

Dans ce dernier chapitre, nous nous sommes concentrés sur les différents outils et technologies utilisés pour développer notre système de détection de la maladie des plantes, ainsi que sur l'architecture des trois modèles d'apprentissage profond que nous avons construits. Ces modèles sont constitués de VGG16 et MobileNetV1 et LeNet5. Nous avons mené de nombreuses expériences.

Les travaux de recherche ont porté sur les configurations de ces architectures. Parallèlement à ces tests, nous avons fourni nos observations et nos interprétations pour comparer les performances de précision des architectures dans la phase de test finale. Enfin, nous avons présenté notre site web, mettant en évidence les bibliothèques utilisées dans le processus.

Conclusion Générale

Grâce à l'avancement de ce projet, nous avons pu mettre en pratique nos connaissances et acquérir une expérience précieuse. En raison des progrès constants de la technologie, la fréquence des maladies des plantes a augmenté, ce qui pose des difficultés pour les détecter. Nous avons travaillé sur cette question tout au long de notre projet, ce qui a conduit à la création de notre site Web.

Selon nos résultats, les trois structures MobileNetV1, VGG16 et LeNet5 présentent des résultats similaires, démontrant une précision VGG16 accrue. Cette initiative nous a permis d'explorer les multiples structures employées dans le traitement de la CNN, nous fournissant ainsi des informations sur les dernières tendances et techniques dans ce domaine.

Les améliorations futures sont possibles sur le site web, qui peut être amélioré avec des fonctionnalités plus avancées. En utilisant un ensemble de données plus vaste et en mettant en place des algorithmes plus avancés, on peut obtenir de meilleurs résultats. De plus, le site web peut être étendu pour détecter et diagnostiquer d'autres affections des plantes. Une tendance à venir pourrait consister à améliorer le projet en ajustant et en améliorant l'algorithme employé.

BIBLIOGRAFIE

1. A. Mezenner, H. Nemmour, Y. Chibani, A. Hafiane, "Local Directional Patterns for Plant Leaf Disease Detection," in *IEEE*, 24 avril 2023.
2. Plantes et agents pathogènes, une liaison raffinée et dangereuse : l'exemple des champignons
The exquisite refinement of plant-microorganism interactions : the case of fungal pathogens, october 2001, page 899-903.
3. R. N. Strange et P. R. Scott, "Plant disease: a threat to global food security," *Annual Review of Phytopathology*, vol. 43, no. 1, pp. 83-116, 2005.
4. G. Shrestha, D. Deepsikha, M. Das, N. Dey, "Plant Disease Detection Using CNN," in *2020 IEEE Applied Signal Processing Conference (ASPCON)*.
5. S. Santhana Hari, M. Sivakumar, P. Renuga, S. Karthikeyan, S. Suriya, "Detection of Plant Disease by Leaf Image Using Convolutional Neural Network," in *2019 International Conference on Vision Towards Emerging Trends in Communication and Networking (ViTECoN)*.
6. "Bulletin de Santé du Végétal Jardins, Espaces Végétalisés et Infrastructures –Région Grand Est BSV n°2 du 7 juin 2023."
7. La Clinique Des Plante, [En ligne]. Disponible: <https://www.cliniquedesplantes.fr/fiches/la-bacteriose-du-noyer>. (Accès: 20 Février 2024)
8. Jardiner Malin, [En ligne]. Disponible: <https://www.jardiner-malin.fr/fiche/produit-naturel-conseils-contre-insectes-parasites-ravageurs.html>. (Accès: 20 Février 2024)
9. M. Sardogan, A. Tuncer, Y. Ozen, "Plant leaf disease detection and classification based on CNN with LVQ algorithm," in *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, pp. 382-385.
10. "USDA National Agricultural Library - Plant Health." [En ligne]. Disponible: <https://www.europarl.europa.eu/news/en/headlines/society/20200827STO85804/what-is-artificial-intelligence-and-how-is-it-used>. (Accès: 21 février 2024)

BIBLIOGRAPHIE

11. S. Russell et P. Norvig, "Artificial Intelligence: A Modern Approach," [En ligne]. Disponible: https://people.engr.tamu.edu/guni/csce421/files/AI_Russell_Norvig.pdf. (Accès: 24 février 2024)
12. "Types of Machine Learning," [En ligne]. Disponible: <https://www.coursera.org/articles/types-of-machine-learning>. (18 Mars 2024)
13. "What is Artificial Intelligence? Everything You Need to Know," [En ligne]. Disponible: <https://blog.logiklabs.io/what-is-artificial-intelligence-everything-you-need-to-know/>. (18 Mars 2024)
14. A. Crochet-Damais, "Deep learning: définition et principes de l'apprentissage profond," [En ligne]. Disponible: <https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501333-deep-learning-definition-et-principes-de-l-apprentissage-profond/>. (20 Mars 2024)
15. "Réseau Neurones Artificiels - Définition," [En ligne]. Disponible: <https://www.lebigdata.fr/reseau-neurones-artificiels-definition>. (10 Avril 2024)
16. "Comment marche le CNN?," [En ligne]. Disponible: <https://blent.ai/blog/a/cnn-comment-ca-marche>. (13 Avril 2024)
17. "VGG16 – Convolutional Network for Classification and Detection," [En ligne]. Disponible: <https://neurohive.io/en/popular-networks/vgg16/>. (29 Avril 2024)
18. "VGGNet-16 Architecture: A Complete Guide," [En ligne]. Disponible: <https://www.kaggle.com>. (29 Avril 2024)
19. K. Bapat, "Introduction to MobileNet v1 using Depth Wise Separable Convolution – Krutika Bapat – Engineering at IIIT-Naya Raipur | 2016-2020," [En ligne]. Disponible: <https://krutikabapat.medium.com/introduction-to-mobilenet-v1-using-depth-wise-separable>. (1 Mai 2024)
20. Y. LeCun, L. Bottou, Y. Bengio, et P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.

BIBLIOGRAFIE

21. A. Krizhevsky, I. Sutskever, et G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097-1105.
22. K. Simonyan et A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
23. C. Szegedy et al., "Going deeper with convolutions," *arXiv preprint arXiv:1409.4842*, 2014.
24. K. He et al., "Deep residual learning for image recognition," *arXiv preprint arXiv:1512.0385*, 2015.
25. M. Tan et Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proceedings of the 36th International Conference on Machine Learning*, Long Beach, CA, USA, 2019.
26. "Keras, MobileNet. Documentation,". Disponible: <https://keras.io/api/applications/mobilenet>. (5 Mai 2024)
27. "NumPy: A fundamental package for scientific computing with Python," [En ligne]. Disponible: <https://numpy.org/>. (5 Mai 2024)
28. "OpenCV: Open-Source Computer Vision Library," [En ligne]. Disponible: <https://opencv.org/>. (5 Mai 2024)
29. "TensorFlow," [En ligne]. Disponible: <https://www.tensorflow.org/>. (5 Mai 2024)
30. "Python Documentation," [En ligne].
Disponible: <https://www.python.org/doc/essays/blurb/>. (5 Mai 2024)
31. "What is Google Colab? - Education Ecosystem Blog," [En ligne]. Disponible: <https://educationecosystem.com/blog/what-is-google-colab/>. (5 Mai 2024)
32. "Kaggle Getting Started Guide," [En ligne]. Disponible: <https://www.kaggle.com/getting-started/13245>. (5 Mai 2024)
33. "NumPy Introduction - W3Schools," [En ligne]. (5 Mai 2024)

BIBLIOGRAFIE

Disponibile:https://www.w3schools.com/python/numpy/numpy_intro.asp#:~:text=NumPy%20stands%20for%20Numerical%20Python.