



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
Ministère de l'Enseignement Supérieur et de la Recherche  
Scientifique  
Université Mohamed Khider – BISKRA  
Faculté des Sciences Exactes, des Sciences de la Nature et de la Vie  
**Département d'informatique**

N° d'ordre : IA /M2/2020

## Mémoire

Présenté pour obtenir le diplôme de master académique en

# Informatique

Parcours : **Intelligence Artificielle**

---

# Une approche d'apprentissage automatique pour la détection des maladies dans les fermes intelligentes

---

Par :  
**NOUAR RABIE**

Soutenu le /09/2020, devant le jury composé de :

Nom	Grade	Président
MERIZIG Abdelhak	M.C. Classe B	Rapporteur
Nom	Grade	Examineur

Session 2020



## Remerciements

En premier lieu, je remercie le bon Dieu de m'avoir donné la force et la patience nécessaire pour achever ce travail de thèse.

Ce travail n'aurait pas pu aboutir à des résultats sans l'aide et les encouragements de plusieurs personnes que je remercie.

Je tiens à remercier à mon Promoteur **Dr. MERIZIG Abdelhak**, Assistant Professeur à l'université de Biskra, pour ses conseils judicieux, sa grande disponibilité et pour m'avoir suivie et orientée, « **Merci pour la qualité de l'encadrement et votre disponibilité** »

mon directeur de thèse monsieur : .. de m'avoir accueilli au sein de son équipe pour réaliser ma thèse ainsi que pour sa disponibilité et son soutien.

Je remercie également mon chère : **Professeur KAZAR Okba** d'avoir suivre mon travail et aussi pour leurs précieux conseils.

Je tiens aussi à remercier mes chère collègues **Dr. MESBAHI Nadjib** et **Dr. SAOULI Abdelhak** et également toute ma promotion de master .

Enfin je tiens à remercier tous ceux et celles qui m'ont aidé et soutenu de près ou de loin pour l'accomplissement de cette thèse.

NOUAR Rabie

## DEDICACE

- Dedicace à ma mère.
- Dedicace à L'âme de mon père pur Mon Seigneur, ayez pitié de lui.
- Dedicace à mes chers frères et soeurs.
- Dedicace à ma petite famille.
- Dedicace à mes Amies.

## ملخص :

عرف المجال الزراعي في السنوات الاخيرة بتناقص عدد المحاصيل والنباتات في مناطق مختلفة بسبب التوسع العمراني سواء كانت مناطق صناعات أو سكنات; إلا انه بعد التطور التكنولوجي في السنوات القليلة الماضية اصبحت المزارع الذكية هي البديل كتعويض لنقص المحاصيل . كما أن ظهور تقنيات جديدة مثل إنترنت الأشياء (IoT) والبيانات الضخمة سيعطي نتائج جيدة في المستقبل. كما ستولد المستشعرات المثبتة كمية كبيرة من البيانات ، للتعامل مع هذه البيانات في الوقت الفعلي ، يعد في الواقع تحديًا كبيرًا. مشكلة أخرى في هذا المجال ، يمكن أن تؤثر التغييرات في العوامل المناخية سواء من الغلاف الجوي أو التربة على النباتات مع مرور الوقت.في النهاية، يمكن لهذه التغييرات أن تخلق تحديًا كبيرًا لأصحاب المزارع. بالإضافة إلى ذلك ، يمكن أن تظهر واحدة من هته المشاكل على النباتات ، كما ان هته التغييرات تقلل من تطور النباتات أو قد تخلق المرض.لمنع هذا النوع من المشاكل ، سيقترح المرشح في هذا المشروع حلاً يعتمد على طريقة التعلم الآلي للتنبؤ بالمرض ومحاولة منعه.

## الكلمات المفتاحية :

التعلم الآلي، البيانات الضخمة، المزرعة الذكية، إنترنت الأشياء(IoT).

## Abstract

The agricultural domain is known for many years in different culture and region. The number of crops and plants are decreasing over the decades due to the number of buildings either industries or societies. After the technology evolution over these last years, they come up with smart farms. Also, the emergence of new technologies such as the Internet of Things (IoT) and Big Data will give good results in the future. The installed sensors will generate a huge amount of data, to deal with this data in real-time it is actually a big challenge. One more problem in this domain, the changes of climatic factors either from the atmosphere or soil could affect the plants within time. Eventually, these changes could create a big challenge for the farm's owners. Additionally, one of these problems could appear in the plants, ie. Changes that decrease the plants evolving or the one that might create a disease. To prevent such kind of problems, in this project the candidate will propose a solution based on a machine learning method to predict and try to prevent the disease.

**Keywords :** *Machine Learning, Big Data, Smart farm, Internet of Things (IoT).*

## Résumé

Après l'évolution technologique de ces dernières années, ils proposent des fermes intelligentes. De plus, l'émergence de nouvelles technologies telles que l'Internet des objets (IoT) et le Big Data donneront de bons résultats à l'avenir. Les capteurs installés généreront une énorme quantité de données, le traitement de ces données en temps réel est en fait un gros défi. Un autre problème dans ce domaine est que les changements des facteurs climatiques dans l'atmosphère ou le sol pourraient affecter les plantes au fil du temps. En fin de compte, ces changements pourraient créer un grand défi pour les propriétaires de la ferme. De plus, un de ces problèmes pourrait apparaître chez les plantes, c'est-à-dire des Changements qui diminuent l'évolution des plantes ou qui pourraient créer une maladie.

**Mots clés :** *Apprentissage automatique , Big Data, Fermes Intelligentes , Internet des objets(IoT).*



# Table des figures

2.1	Un Ferme traditionnel . . . . .	6
2.2	Exemple d'une serre traditionnel . . . . .	7
2.3	Architectures de Smart farm [31] . . . . .	10
2.4	Exemple d'une Serrer intelligente . . . . .	11
2.5	Domains d'application d'IoT à l'agriculture . . . . .	14
2.6	Architecture général d'un RCSF en agriculture [22] . . . . .	15
3.1	Type des maladies Agricole [27]. . . . .	22
3.2	Le triangle des maladies des plantes[50]. . . . .	23
3.3	Les méthodes de détection des maladies des plantes[22] . . . . .	24
3.4	Liens entre l'IA et l'apprentissage [32][24]. . . . .	26
4.1	Architecture générale de système. . . . .	33
4.2	Échantillons de la base des images [PlantVillage – Dataset] . . . . .	34
4.3	Représentation de la phase d'apprentissage . . . . .	34
4.4	Processus de détection des maladies . . . . .	37
4.5	Résultat de Méthode HSV . . . . .	39
4.6	Schéma générale d'un classification CNN [52] . . . . .	40
4.7	-Le Modèle Proposé N° 01 . . . . .	42
4.8	les couches du Modèle N° 01 . . . . .	44
4.9	Le Modèle Proposé N° 02 . . . . .	45
4.10	les couches du Modèle N° 02 . . . . .	46
4.11	Le Modèle Proposé N° 03 . . . . .	47

4.12 les couches du Modèle N° 03 . . . . .	48
5.1 La fenêtre principale de système. . . . .	53
5.2 La fenêtre Mode apprentissage. . . . .	54
5.3 La fenêtre Mode prédiction. . . . .	55
5.4 Compilation de Modèle N°01 . . . . .	56
5.5 Compilation de Modèle N°01 . . . . .	57
5.6 Compilation de Modèle N°02 avec (batch size=32) . . . . .	58
5.7 Compilation de Modèle N°02 avec (batch size=32) . . . . .	59
5.8 Compilation de Modèle N°02 avec (batch size=24) . . . . .	60
5.9 Compilation de Modèle N°02 avec (batch size=24) . . . . .	61
5.10 Compilation de Modèle N°03 . . . . .	62
5.11 Compilation de Modèle N°03 . . . . .	63
5.12 Exemple d'un rapporte de prédiction. . . . .	64
5.13 Exemples des images de teste classifier. . . . .	65

# Liste des tableaux

2.1	Comparaison entre l'agriculture traditionnelle et intelligente[15][16]. . . . .	18
3.1	Comparaison entre l'apprentissage supervisé et non-supervisé [36][41]. . . . .	27
3.2	Tableau comparative des techniques de classification [37] . . . . .	28
3.3	Tableau connexes . . . . .	29
3.4	Tableau Synthèse des Travaux connexes . . . . .	30
4.1	Description de la Base de données d'apprentissage . . . . .	36
4.2	les couches du Modèle N°01 . . . . .	43
4.3	les couches du Modèle N° 02 . . . . .	45
4.4	les couches du Modèle N° 03 . . . . .	47
5.1	Caractéristiques de Lap-Top EliteBook 8570P . . . . .	53
5.2	Tableau comparative des trois modèles . . . . .	66
5.3	Tableau Comparatif des Travaux . . . . .	67

# Table des matières

Remerciements . . . . .	i
Abstract . . . . .	iv
Résumé . . . . .	v
<b>Table des figures</b>	<b>viii</b>
<b>Liste des tableaux</b>	<b>ix</b>
<b>1 Introduction Générale</b>	<b>2</b>
1.1 Contexte et Problématique . . . . .	2
1.2 Objectif du travail . . . . .	3
1.3 Structure du mémoire . . . . .	3
<b>2 Etat de l'art sur les fermes intelligentes</b>	<b>5</b>
2.1 Introduction . . . . .	5
2.2 L'agriculture traditionnelle . . . . .	6
2.2.1 L'agriculture traditionnelle . . . . .	6
2.3 Smart agriculture . . . . .	8
2.3.1 Définition . . . . .	8
2.3.2 Les Avantages de l'agriculture intelligente : . . . . .	9
2.3.3 Architectures de Smart Farm : . . . . .	10
2.4 Serre intelligente . . . . .	11
2.4.1 Définition d'une serre intelligente : . . . . .	11
2.4.2 Architectur d'une serre intelligente . . . . .	12
2.5 L'IoT en Agriculture . . . . .	12

2.5.1	Des conseils avant la mise en mettre de IoT en Agriculture . . . . .	13
2.5.2	Les avantages des IoT en agriculture . . . . .	13
2.6	Réseaux de capteurs sans fil (RCSF) en agriculture : . . . . .	15
2.7	Comparaison entre l'agriculture traditionnelle et l'agriculture intelligente . . . . .	17
2.8	Conclusion . . . . .	19
<b>3</b>	<b>Travaux connexes et synthèses bibliographiques</b>	<b>20</b>
3.1	Introduction . . . . .	20
3.2	La détection des maladies chez les plantes . . . . .	21
3.2.1	Motivation . . . . .	21
3.2.2	Les maladies chez les plantes . . . . .	21
3.3	L'effet de facteur météorologique sur les maladies Agricole : . . . . .	22
3.4	Méthodes de détection des maladies des plantes . . . . .	23
3.5	Intelligence artificielle, l'apprentissage et le Big Data . . . . .	25
3.6	Les Travaux connexes . . . . .	27
3.7	La synthèse : . . . . .	29
3.8	Conclusion . . . . .	31
<b>4</b>	<b>Conception de système</b>	<b>32</b>
4.1	Introduction . . . . .	32
4.2	Description de l'Architecture . . . . .	33
4.2.1	Phase d'apprentissage : . . . . .	33
4.3	Phase de production : . . . . .	35
4.4	Description de la Base de données d'apprentissage : . . . . .	35
4.5	Processus de détection des maladies . . . . .	36
4.5.1	Acquisition de l'image : . . . . .	37
4.5.2	Prétraitement de l'image : . . . . .	38
4.5.3	La Segmentation d'image : . . . . .	38
4.5.4	Extraction des caractéristiques : . . . . .	39
4.5.5	Classification d'image : . . . . .	39
4.6	Méthode et Algorithme utilise : . . . . .	40

4.7	Le paramétrage des couches CNN :	40
4.8	Les modèles CNN proposés	42
4.8.1	- Modèle Proposé N° 01 :	42
4.8.2	- Modèle Proposé N° 02	44
4.8.3	- Modèle Proposé N° 03	46
4.9	Conclusion	49
<b>5</b>	<b>Résultats Expérimentaux et Discussions</b>	<b>50</b>
5.1	Introduction	50
5.2	Les outils de Développement et Platform utilisé	50
5.2.1	Google "Colaboratory" :	50
5.2.2	Jupyter Notebook	51
5.2.3	TensorFlow	51
5.2.4	Keras	52
5.2.5	Matplotlib	52
5.2.6	Equipment utilise :	52
5.2.7	Interface de Système :	53
5.3	Les Résultats Obtenus	55
5.3.1	Model 01 :	56
5.3.2	Model 02 :	57
5.3.3	Model 03 :	61
5.3.4	Etats de sortie de système (phase de prédiction) :	64
5.3.5	Comparaison des résultats obtenu :	66
5.4	Conclusion	68
<b>6</b>	<b>Conclusion Générale et Perspectives</b>	<b>69</b>
6.1	Conclusion Générale	69
6.2	Perspectives	70
	<b>Bibliographie</b>	<b>71</b>

<b>A Annexe</b>	<b>77</b>
A.1 Les Symptômes des maladies traités. . . . .	77

# Chapitre 1

## Introduction Générale

L'intelligence artificielle apporte des outils modernes et bouleverse les processus existants dans de très nombreux domaines comme la santé, l'hôtellerie, l'industrie et encore l'agriculture. Dans notre travail nous focalisons sur l'agriculture car ce secteur connaît depuis quelques années une véritable révolution numérique pour répondre aux défis économiques, sociaux et environnementaux actuels.

### 1.1 Contexte et Problématique

L'agriculture intelligente face au climat AIC (Climat-smart agriculture ) [2] c'est une approche qui aide les gérants des systèmes agricoles à faire face au changement climatique d'une manière efficace. L'approche de l'AIC vise trois objectifs, à savoir l'augmentation durable de la productivité et des revenus, l'adaptation au changement climatique et de réduire la maximum possible l'émissions de gaz à effet de serre. L'approche de l'AIC vise plutôt à minimiser les contreparties (corrélations négatives) et à promouvoir les synergies en tenant compte de ces objectifs pour éclairer les décisions, à court et à long terme. [1].

Les pays en développement devraient être les pays les plus touchés par le changement climatique. Ses effets incluent l'augmentation des températures, la modification des régimes de précipitations, la hauteur au niveau de la mer et la fréquence accrue des phénomènes météorologiques extrêmes. Tous ces effets posent des risques sur l'agriculture et l'approvisionnement en nourriture et en eau. Généralement; l'agriculture souffre d'un problème majeur; les épidémies non contrôlées mènent souvent à des pertes économiques énormes; à cause de l'incapa-

cité d'effectuer le traitement chimique au moment opportun contre les maladies. C'est pour ça il faut avoir un système de prédiction des maladies dès que les premiers symptômes s'apparaissent sur les feuilles des plants.

Existe-il une solution intelligente pour limiter l'effet des maladies agricoles?

## **1.2 Objectif du travail**

Actuellement, dans le secteur de l'agriculture on s'intéresse à la Machine Learning (ML) pour alimenter les algorithmes intelligents, la première étape consiste à récolter des données massives (Big Data) grâce à des capteurs plantés dans la terre ou installés sur des tracteurs, grâce à des caméras, ou encore grâce à une cartographie des sols effectuée avec des drones. Dans ce mémoire notre but est la conception et l'implémentation d'un système d'apprentissage automatique pour détecter et classer automatiquement les feuilles des plantes. Dans ce contexte, la Machine Learning permet d'analyser des feuilles capturées et d'envoyer comme résultat un rapport prédictif. Notre objectif est de mettre à la disposition des agriculteurs un système dédié à la prédiction des maladies des plantes; de telle façon que les gens pourront prendre une photo de leur plante et le transmettre vers le cloud afin d'obtenir un diagnostic en quelques secondes.

## **1.3 Structure du mémoire**

Ce mémoire est organisé en six chapitres : Dans le premier chapitre on présente une introduction générale de l'agriculture intelligente ainsi leurs avantages.

Dans le deuxième chapitre nous montrons l'état de l'art et les fermes intelligentes.

En troisième chapitre, nous arborons les travaux connexes et les synthèses bibliographiques associés à ce domaine.

En quatrième chapitre, nous présentons la conception de notre système et l'architecteur CNN proposée.

En cinquième chapitre nous exposons les outils d'implémentation et la plateforme utilisée dans notre travail ainsi que les résultats obtenus.

Ce mémoire est clôturé par le dernier chapitre qui présente la conclusion générale et les

perspectives de notre travail.

# Chapitre 2

## Etat de l'art sur les fermes intelligentes

### 2.1 Introduction

Avec la croissance exponentielle de la population mondiale, l'agriculteur devra produire plus de nourriture en utilisant moins de ressources. L'humanité doit consommer moins d'eau, et utiliser moins de produits chimiques. La disponibilité limitée des ressources naturelles telles que l'eau douce et les terres arables, ainsi que le ralentissement des tendances de rendement de plusieurs cultures de base, ont encore aggravé le problème.

Selon l'FAO (l'Organisation des Nations Unies pour l'alimentation et l'agriculture), le monde devra produire 70% de nourriture en plus en 2050 [2], la diminution des terres agricoles et l'épuisement des ressources naturelles limitées, la nécessité d'améliorer le rendement agricole est devenue critique [3]. De plus, la main-d'œuvre agricole dans la plupart des pays a diminué.

En raison de la baisse de la main-d'œuvre agricole, l'adoption de solutions de connectivité Internet dans les pratiques agricoles a été déclenchée, afin de réduire le besoin de travail manuel [1]. L'intelligence artificielle investit tous les pans de l'industrie y compris dans les secteurs les plus traditionnels comme l'agriculture. L'IA permet aux agriculteurs d'utiliser moins de pesticides, moins de désherbants et surtout moins d'engrais.

Dans cette chapitre ; je présente l'état de l'art de l'agriculture intelligente et plus précisément les serres intelligente avec les nouvelle technologies utilisé.

## **2.2 L'agriculture traditionnelle**

Dans cette section, nous présentons quelques définitions sur les concepts de base dans l'agriculture traditionnelles.

### **2.2.1 L'agriculture traditionnelle**

L'agriculture c'est un processus qu'il permet à l'être humain à aménager leurs écosystèmes pour satisfaire les besoins alimentaires de lui même en premier degré (l'autosuffisance) et pour les autres ou leurs sociétés. Elle désigne l'ensemble des savoir-faire et les activités ayant pour objet la culture des sols et plus généralement l'ensemble des travaux[5] sur le milieu naturel permettant de cultiver et prélever des êtres vivants;qu'ils sont utiles à l'être humain .

#### **Ferme traditionnel**

Une ferme c'est une exploitation agricole exploitée sous le régime d'une location de longue durée avec un loyer annuel fixe, ou fermage.

Il s'agit d'un contrat de louage entre le propriétaire et le fermier qui porte sur un domaine comportant selon les cas des terres, des forêts, des étendues d'eau, des bâtiments d'exploitation et d'habitation, parfois avec le cheptel et le matériel d'exploitation(voir fig.2.1), des droits de marque et d'appellation d'origine, des servitudes[4].



FIGURE 2.1 – Un Ferme traditionnel

Une Ferme traditionnel : ( sans production industrielle, pour l'autosuffisance Selon les pays, selon les productions auxquelles elles étaient destinées, les fermes ont adopté au fil des siècles une configuration fonctionnelle permettant une vie en autarcie avec utilisation des petits cours d'eau ou des éoliennes pour l'énergie nécessaire au puisage de l'eau.

### **Serre Traditionnel**

La serre est un abri exploitation le rayonnement solaire, destiné à la culture et à la protection des plantes. L'objectif étant de créer un environnement propice à leur développement en tirant parti de l'influence du climat. En créant un micro climat, la serre permet d'influencer le cycle végétatif des plantes [13].

La serre agricole existe en deux formes connues : Les serres tunnels (voir fig.2.2) et les serres d'horticulture.



FIGURE 2.2 – Exemple d'une serre traditionnel

### **-les Avantages de la production sous les serres traditionnel**

La température intervient de façon prépondérante dans la croissance et le développement de la végétation, L'humidité augmente dans les serres grâce à la transpiration de la plante, en l'absence de vent et par évapotranspiration en enceinte relativement close. Les concentrations de CO<sub>2</sub> et de vapeur d'eau, jouent un rôle déterminant dans la transpiration et sur la photo-

synthèse des plantes ainsi que dans le développement des maladies fongiques. Le rayonnement solaire intervient également dans la photosynthèse [13].

Un contrôle bien maîtrisé du bilan énergétique/massique du climat permet donc de gérer ces paramètres et d'améliorer le fonctionnement physiologique des plantes. Quelques avantages de la serre agricole peuvent être énumérés ci-dessous :

- Production et rendement satisfaisant.
- Production hors saisons des fruits, légumes et espèces florales.
- Diminution notable des maladies nuisibles aux plantes grâce à la climatisation.
- Exploitation réduite des terres agricoles.
- Qualité et précocité des récoltes.

## **2.3 Smart agriculture**

Pour répondre à l'explosion démographique future et nourrir une population mondiale croissante de façon durable, rentable et respectueuse de l'environnement, il n'y a d'autre solution que de faire une révolution agricole importante.

Depuis la fin du 20<sup>ème</sup> siècle, il apparaît une nouvelle forme de production agricole c'est : l'agriculture intelligente ou « agriculture de précision », plus connue sous le nom anglais « Smart Farming » [14]. Bienvenue dans l'agriculture de futur qui permet de produire proprement et durablement des denrées alimentaires pour nourrir les peuples.

### **2.3.1 Définition**

La « smart agriculture » ou « agriculture intelligente » c'est un système à forte intensité de capital et d'haute technologie pour cultiver des aliments proprement et durablement ; c'est l'application des TIC (technologies de l'information et de la communication) modernes à l'agriculture pour améliorer la performance et la qualité des productions agricoles. Cette technique introduit plusieurs services et outils qui sont intéressants d'évoquer ; on peut très bien penser aux systèmes de géo-positionnement, à l'utilisation du Big data, des drones et de la robotique, des objets connectés (IoT), en plus à d'autres technologies [16].

La smart agriculture est un ensemble d'outils, de concepts et de pratiques qui favorisent une

croissance économique des exploitations. Deux branches d'innovation peuvent être distinguées [13] :

**1) Des innovations physiques :**

Robots, drones, capteurs, internet des objets,...

**2) Des innovations numériques :**

Logiciels de gestion, plateformes collaboratives. Complémentaires et interdépendantes, elles prennent en charge le travail des sols, la gestion, la mise en marché, le matériel agricole, la mutualisation des investissements, ... .

Voici quelques exemples d'entreprises [46] actives dans ce domaine avec différentes offres et modèles de business :

— **Farmers Business Network :**

C'est un réseau d'informations agronomiques utilisant l'analyse de données pour aider les fermiers à prendre les meilleures décisions opérationnelles.

— **Granular :**

C'est une plateforme analytique conçue pour aider les fermiers à gérer et à visualiser les données pour opérer plus efficacement.

— **Farmers Edge :**

C'est une entreprise hardware et software. Son système FarmCommand permet d'automatiser la collecte de données [46].

### **2.3.2 Les Avantages de l'agriculture intelligente :**

les engins et les outils modernes utilisés dans l'agriculture devient très développer tels que les tracteurs ,les robots ,les drons ,... sont de plus en plus autonomes. Les engins sont équipés de GPS, pilotage automatique et encore les tableau de bord affichant des statistiques sur l'avancement de la récolte.

Voici certains des avantages qu'on peut les recensés pour l'agriculture intelligente :

- Optimiser la consommation de la ressource et des intrants telle-que l'énergie et d'eau, ... en utilisent des systèmes automatisés d'irrigation.
- Mise en place de processus visant à un meilleur rendement (agriculture de précision) avec moindre coût.

- Meilleure exploitation d'espace et compris les sous-espaces.
- Utilisation d'haute technologies moderne au lieu de main-d'œuvre tel que : systèmes de géolocalisations (GPS, SIG) , la robotique ,les drones ,..
- Permet de suivre en temps réel et de prédire l'évolution des exploitations en fonction de paramètres prédéfinis, dont bien évidemment le climat.

### 2.3.3 Architectures de Smart Farm :

L'architecture de Smart farming basée sur des appareils IoT. Ces derniers permettent de connaître l'état en temps réel des cultures en capturant les informations avec un réseau des capteurs. Le réseau des captures le plus connu nommé RCSF (Réseau Capteurs Sans File - Voir la section 2.6). Telle que les capteurs sont utilisés pour surveiller les variables environnementales telles que la luminosité, la température et l'humidité tandis que les actionneurs tels que les pompes à eau, les ventilateurs et les lampes sont utilisés pour la culture des plantes. Ces choses communiquent par des liens sans fil ad hoc (voir fig. 2.3).

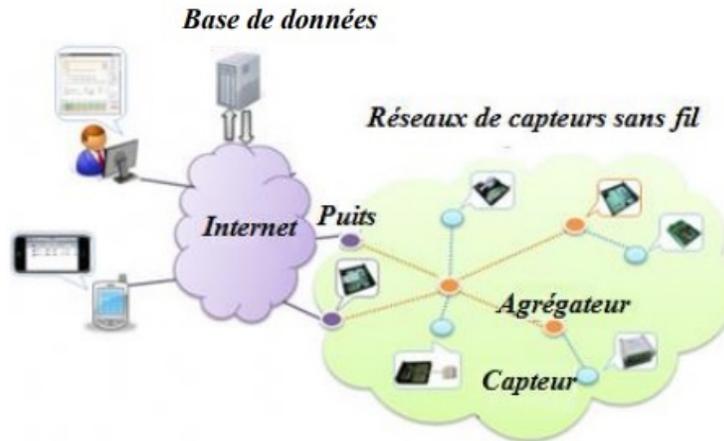


FIGURE 2.3 – Architectures de Smart farm [31]

À l'extérieur de la ferme se trouve le système de soutien aux agriculteurs. Il se compose d'un serveur Web, d'une base de données et d'une base de connaissances. Les données sont stockées dans la base de données tandis que les connaissances sont gérées dans la base de connaissances pour une utilisation ultérieure. De plus, les utilisateurs finaux, y compris les agriculteurs, peuvent accéder aux applications et services à partir du serveur Web via un réseau public. Le

système d'agriculture intelligente vise à aider les agriculteurs à résoudre les problèmes quotidiens tels-que l'arrosage correct et le maintien d'une santé végétale cohérente [8].

## **2.4 Serre intelligente**

Les serres contrôlent les paramètres environnementaux par une intervention manuelle de l'être humain ou un mécanisme de contrôle proportionnel c'est devient dépassé. Étant donné qu'une intervention manuelle provoque des pertes en production, d'énergie et des coûts élevés de main-d'œuvre, ces méthodes sont moins efficaces.

### **2.4.1 Définition d'une serre intelligente :**

L'agriculture en serre c'est une méthodologie qui aide à améliorer le rendement des cultures[47]. Une serre intelligente conçu principalement à l'utilisation d'IoT[48] afin de bénéficier le maximum possible à ces avantages ; cette conception surveille et contrôle intelligemment le climat,et éliminant l'intervention manuelle.Pour contrôler l'environnement dans une serre intelligente, différents capteurs qui mesurent les paramètres environnementaux en fonction des besoins de la plante sont utilisés ; comme exemple dans la figure (fig.2.4).



FIGURE 2.4 – Exemple d'une Serrer intelligente

Pour rendre nos serres intelligentes, l'IoT a permis aux stations météorologiques d'ajuster

automatiquement les conditions climatiques selon un ensemble particulier d'instructions.

L'adoption de l'IoT dans les serres a éliminé l'intervention humaine, rendant ainsi l'ensemble du processus rentable et augmentant la précision en même temps. Par exemple, l'utilisation de capteurs IoT à énergie solaire crée des serres modernes et peu coûteuses. Ces capteurs collectent et transmettent les données en temps réel, ce qui permet de surveiller très précisément l'état de la serre en temps réel. À l'aide des capteurs, la consommation d'eau et l'état de serre peuvent être surveillés via des e-mails ou des alertes SMS. L'irrigation automatique et intelligente est réalisée à l'aide de l'IoT. Ces capteurs aident à fournir des informations sur les niveaux de pression, d'humidité, de température et d'éclairage. L'intelligence artificielle s'invite dans les serres dans un scénario d'architecture très connu ( voir la section 2.6) ; imagine dans une serre, un algorithme intelligent capable de relever et d'analyser des millions des données, puis de contrôler et d'optimiser la production en temps réel pour prédire l'état de récolte final. Dans ce cas nous pouvons aussi créer un serveur cloud pour accéder à distance au système . Cela élimine le besoin d'une surveillance manuelle .

### **2.4.2 Architectur d'une serre intelligente**

Les techniques traditionnelles de suivi des données en serre souffrent souvent d'un manque de partage et de disponibilité, intensité de travail, faible résolution spatio-temporelle.

les applications en serre intelligente basé sur un réseau de capteurs sans fil (RCSF) peut être déployé avec une variété de scénarios ( voir la section 2.6) qu'il assure la centralisation des données et la gestion organisationnelle dans le respect des aspects environnementaux d'une serre.

Dans le monde de l'IoT, les capteurs sont la principale source de collecte de données à grande échelle; cette opération se fait à travers l'infrastructure RCSF; en suite ces données stocké sur le cloud. Ces données sont analysées et transformées en informations significatives à l'aide d'outils d'analyse et prennent ainsi de meilleures décisions.

## **2.5 L'IoT en Agriculture**

L'agriculture est ramenée à ses racines de prise de décision basée sur l'observation en donnant au fermier une pléthore d'yeux supplémentaires, qui à leur tour fournissent un niveau de

surveillance qui a été perdu depuis l'époque de la petite agriculture. Les avantages de l'agriculture à l'ancienne sont combinés avec les avantages de l'agriculture moderne à grande échelle, grâce à l'intégration de processus d'une grande variété de technologies, ce que l'on appelle l'Internet des objets (IoT).

L'agriculture de précision a introduit la technologie dans l'agriculture depuis le début de ce siècle [10]. L'émergence et l'adoption de la technologie IoT élèvent cette industrie à un niveau jamais vu auparavant.

### **2.5.1 Des conseils avant la mise en marche de IoT en Agriculture**

Les appareils et technologies intelligents ont de nombreuses façons d'aider les agriculteurs à augmenter les performances et les revenus de leur ferme. Cependant, les agriculteurs sont confrontés à des défis différents lorsqu'ils envisagent d'investir dans une agriculture intelligente [14]. Par conséquent, il devient nécessaire d'envisager et de suivre des conseils avant de mettre en œuvre une agriculture intelligente qu'on peut citer comme exemple les suivants [16] :

1. Le bon choix de matériel est nécessaire pour assurer une meilleure qualité des données collectées.
2. D'avoir une puissante capacité d'analyse de données. Au même temps, des algorithmes prédictifs et un apprentissage automatique pour obtenir des informations exploitables sur la base des données collectées.
3. Entretien périodique de matériel en exploitation, et en cas de panne doit être remplacer une technologie fréquente.
4. L'accès à distance aux données des fermes sera disponible via un Smartphone et un ordinateur de bureau.
5. Le système doit être sécurisé et sûr à utiliser afin qu'il n'y ait aucune possibilité de piratage des données.

### **2.5.2 Les avantages des IoT en agriculture**

Les nouvelles technologies reposant sur l'intelligence artificielle, l'IoT, le big data, la robotique et l'analyse avancée, permettent le développement d'une agriculture de précision. Donner

aux agriculteurs des outils pour observer, mesurer et analyser les besoins tant de leurs exploitations que de leurs employés permet une meilleure gestion des ressources tout en réduisant l'impact environnemental et le gâchis. Voici certains d'avantages de l'adoption de nouvelles technologies telles que l'Internet des objets IoT en agriculture [9] :

1. Agriculture de précision.
2. Surveillance de Conditions climatiques.
3. Analyse des données.
4. Drones Agricoles (*Carbon Bee*).
5. Robotisation et automatisation avancée.

les domaines d'applications de la technologie IoT à l'agriculture représenter dans la figure fig.2.5 suivante :



FIGURE 2.5 – Domaines d'application d'IoT à l'agriculture

Les solutions basées à sur l'IoT visent à aider les agriculteurs à combler l'écart de demande et d'approvisionnement, une rentabilité et une protection de l'environnement.

L'approche consistant à utiliser la technologie IoT [48] pour garantir une utilisation optimale des ressources afin d'obtenir des rendements élevés et de réduire les coûts d'exploitation est appelée agriculture de précision.

L'IoT dans les technologies agricoles comprend des équipements spécialisés [49], une connectivité sans fil, des logiciels et des services informatiques.

## 2.6 Réseaux de capteurs sans fil (RCSF) en agriculture :

Un réseau de capteurs sans fil (RCSF), ou "Wireless Sensor Network" (WSN) [11] c'est un réseau composé d'un ensemble de nœuds intégrant les fonctionnalités d'acquisition, de traitement, et de communication. Parmi les standards les plus aptes à être exploités dans les réseaux de capteurs sans-fil se retrouvent la double pile protocolaire Bluetooth / ZigBee[6]. Ce type de réseaux c'est un conclusion d'une fusion des systèmes embarqués et les communications sans fil Une fois déployés, les nœuds coopèrent entre eux d'une manière autonome afin de collecter et de transmettre des données telles que la température ou la pression de l'atmosphère... (voir la figure 2.6) ; afin de les acheminer vers une station de base[12] dans le but de surveiller et de contrôler les condition climatique dans une serre intelligente.

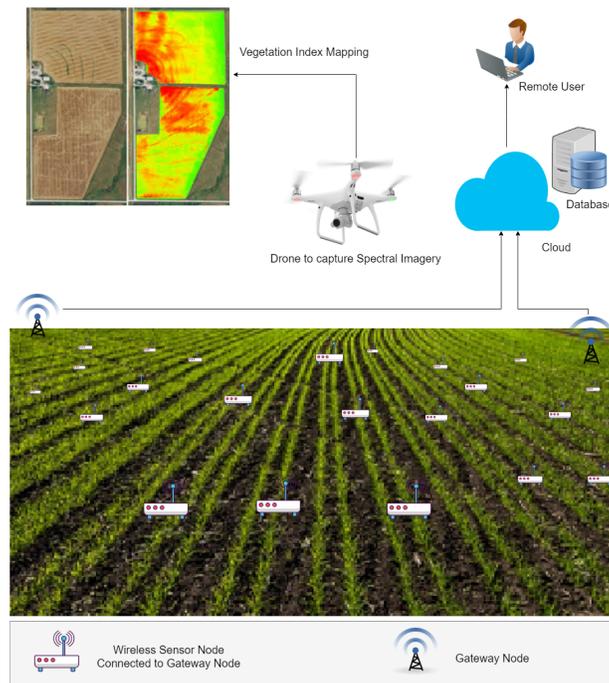


FIGURE 2.6 – Architecture général d'un RCSF en agriculture [22]

Les RCSF sont souvent considérés comme étant les successeurs des réseaux ad hoc. les RCSF partagent avec les MANET (Mobile Ad hoc NETworks) plusieurs propriétés en commun, telles que l'absence d'une infrastructure et les communications sans fil [31].

Aujourd'hui, l'un des domaines d'application prometteurs des RCSF c'est l'agriculture où la technologie des RCSF offre un support important qui permettra la gestion précise des ressources,

optimise l'irrigation et l'utilisation des Engrais, le suivi/prévention des maladies, la prédiction du moment adéquat de la récolte, ...

L'avantage principal de l'utilisation des RCSF dans l'agriculture est l'absence de câblage ce qui réduit considérablement le coût d'installation. Un autre avantage est la flexibilité de déploiement et la facilité d'entretien. En effet, les capteurs sont autonomes et nécessitent très peu d'intervention humaine sur les champs notamment dans le cas où les protocoles de communication sont tolérants aux panne et supportent la mobilité des nœuds[31]. Malheureusement, les RCSF ne sont pas parfaits! leur déploiement dans des zones parfois hostiles, les nœuds sont assez fragiles et vulnérables à diverses formes de défaillances [11].

## **2.7 Comparaison entre l'agriculture traditionnelle et l'agriculture intelligente**

l'agriculture intelligente jouera un rôle important dans la fourniture de produits agricoles et devient plus productifs et durables. savoir que les applications de l'agriculture intelligente basée sur l'IoT ciblent non seulement les grandes exploitations conventionnelles, mais pourraient également être un nouveau pour les ferme animale.

Une comparaison entre l'agriculture moderne et l'agriculture traditionnelle illustre dans le tableau (voir Tab.2.1). Par exemple; l'agriculture moderne optimise l'utilisation des espèces sous-utilisées.

TABLE 2.1 – Comparaison entre l'agriculture traditionnelle et intelligente[15][16].

<b>N°</b>	<b>Agriculture intelligente</b>	<b>Agriculture traditionnelle</b>
<b>01</b>	-Mise en œuvre de technologies et des méthodes agricoles à forte intensité (technologie modern).	-Adhère aux méthodes traditionnelles de l'agriculture.
<b>02</b>	-Utilise des équipements modernes et transformation alimentaire.	-Utilise l'équipement agricole traditionnel et séculaire.
<b>03</b>	-Se caractérise par un élevage à haut niveau d'rendement.	- Se caractérise par un élevage à faibles rendement.
<b>04</b>	-Peu de travail et de main d'œuvre puisque les machines prennent soin de tout.	-Nécessite beaucoup de travail et main d'œuvre.
<b>05</b>	-Utilisées des méthodes : Pesticides, sélection végétale, agronomie, antibiotiques liés à l'élevage, ...	- La plupart des méthodes comme les pesticides, etc... ne sont pas utilisées.
<b>06</b>	Basé sur un Système de connaissances scientifiques.	Basé sur l'expérience traditionnelle.
<b>07</b>	Peu d'espèce de base.	-De nombreuses espèces; (négligées les espèces sous utilisées).
<b>08</b>	-Politique intensive, y compris concurrence avec subventionné.	-Négligé par les décideurs.
<b>09</b>	-Produits standardisés, pour répondre exigences du marché.	-Produits variables, absence des normes et réglementation.

## **2.8 Conclusion**

Suite à l'étude de comparative entre l'agriculture traditionnelle et l'agriculture intelligente on remarque que l'utilisation des nouvelles technologies permet de relever des défis multiples en matière d'agriculture. Par exemple dans les champs comme dans les élevages, telle-que la robotique, l'automatisation et la prédiction ont un rôle fondamental à jouer pour un meilleur exercice de l'agriculture.

En bref, avec la croissance énorme des technologies modernes telles-que : l'IA, le ML, l'IoT et le cloud computing permettent de l'agriculture intelligente jouera un rôle important dans la fourniture de produits agricoles et devient plus productifs et durables, qui seront basés sur une approche économe en ressources et de précision. Mais il reste le grand défi face à généralisé ces technologies modernes qu'il reste une solution coûteuse.

# Chapitre 3

## Travaux connexes et synthèses bibliographiques

### 3.1 Introduction

Dans cette chapitre, nous présentons la problématique de détection des maladies dans les plantes et aussi les facteurs météorologiques qu'ils peuvent causer de ces maladies chez les plantes, et par la suite nous discutons les différentes méthodes de détections des maladies agricole.

Ensuite nous citons quelques travaux connexes récentes et les techniques utilisé pour contrôler l'effet climatique dans les serres agricoles par l'application de l'intelligence artificielle; Telle-que les réseaux de neurones il s'agit particulièrement les réseaux de neurones convolutifs (CNN). Qu'ils sont été développés pour effectuer la détection et le diagnostic utilisant de simples images de feuilles de plantes saines et malades, grâce à des méthodologies d'apprentissage en profondeur ( Deep Learning DL).

Savoir que les maladies des plantes constituent non seulement une menace pour la sécurité alimentaire à l'échelle mondiale, mais peuvent également avoir des conséquences désastreuses pour les petits agriculteurs dont les moyens de subsistance dépendent de cultures saines. Savoir que dans le monde en développement, plus de 80% de la production agricole est générée par les petits exploitants agricoles [7].

## **3.2 La détection des maladies chez les plantes**

Le diagnostic rapide et précis des maladies des plantes est l'un des piliers de l'agriculture de précision [3], Savoir qu'il existe plusieurs façons de détecter les pathologies végétales; que on va presenter dans cette section.

### **3.2.1 Motivation**

L'agriculture souffre d'un problème majeur dans le monde entier, les épidémies non contrôlées mentent souvent à des pertes économiques énormes à cause de l'incapacité d'effectuer le traitement chimique au moment opportun [19]. Ainsi, beaucoup des travaux de recherche en épidémiologie des plantes ont focalise sur l'étude de la possibilité de prédire l'occurrence d'une maladie végétale[23] en suivant l'évolution des conditions climatiques .

La situation est encore compliquée par le fait qu'aujourd'hui, des nouvelles maladies se transmettent facilement que jamais auparavant. Certaines maladies ne présentent aucun symptôme visible [20], ou l'effet devient perceptible plus tard pour agir, et dans ces situations, une analyse sophistiquée est obligatoire. Cependant, la plupart des maladies [17] génèrent une sorte de manifestation dans le spectre visible, donc l'examen visuel d'un professionnel qualifié c'est la principale technique [18] adoptée en pratique pour la détection des maladies des plantes.

### **3.2.2 Les maladies chez les plantes**

Les agents responsables des maladies chez les plantes sont très semblables à ceux rencontres chez les hommes et les animaux.En général, il y a deux facteurs (voir fig.3.1) qui peuvent affecter la plante : agents vivants (biotiques) et non vivants (abiotiques).

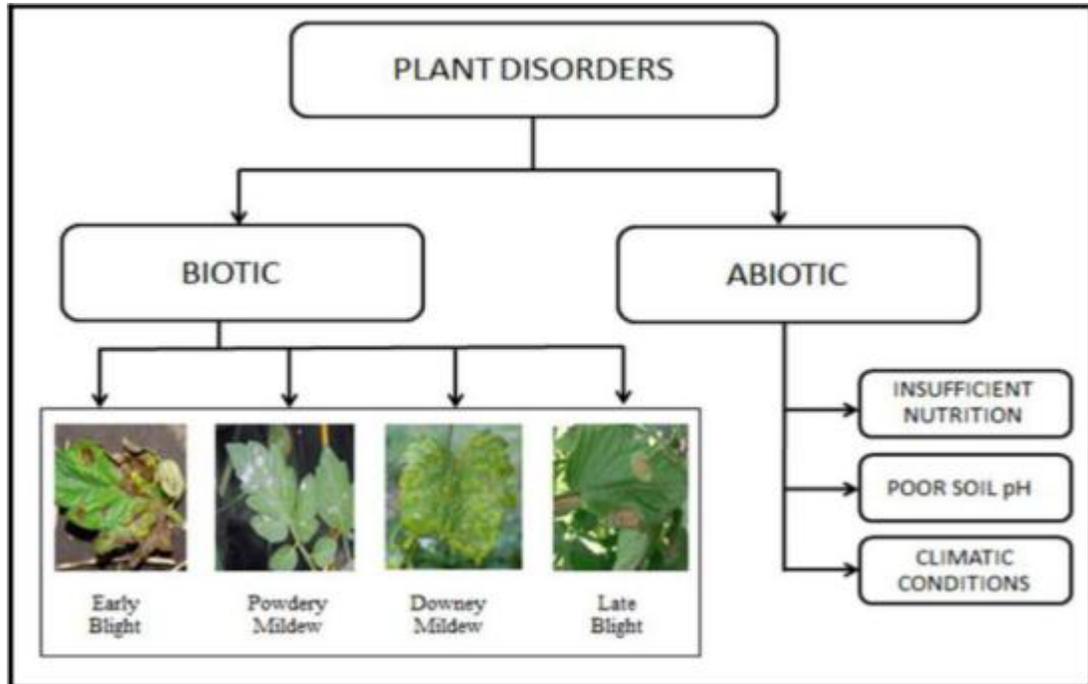


FIGURE 3.1 – Type des maladies Agricole [27].

- **Les facteurs biotiques :** Différents agents vivants comprennent les insectes, les bactéries, les champignons et les virus.
- **Les facteurs Abiotiques :** Agent non-vivant. Comprend divers effets de l’environnement tels que le changement rapide de température, l’excès d’humidité, l’insuffisance des nutriments, le pH du sol et les conditions d’humidité élevée[27].

### 3.3 L’effet de facteur météorologique sur les maladies Agricole :

Les résultats de la recherche indiquent que le changement climatique peut modifier les stades et les taux de développement d’agents pathogènes; il peut également modifier la résistance de l’hôte, ce qui entraîne des changements physiologiques des interactions hôte-pathogène [27]. Au plus de ça une utilisation inexpérimentée des pesticides peut provoquer le développement d’une résistance à long terme des agents pathogènes, réduisant considérablement la capacité de riposte.

Le développement des agents pathogènes devient très rapide si les conditions climatiques sont favorables. Ainsi, une interaction entre l’hôte (la plante), le climat et les agents pathogènes

peuvent cause des maladies. Cette interaction est appelée triangle des maladies[50][51] illustrée dans la figure (fig. 3.2).

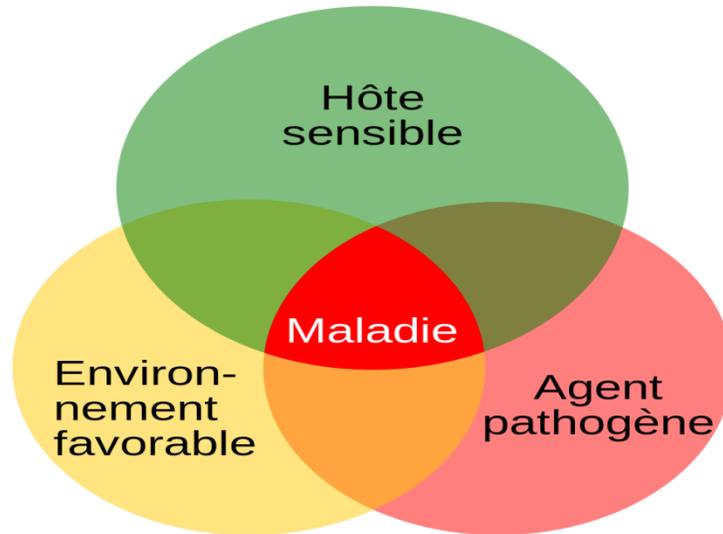


FIGURE 3.2 – Le triangle des maladies des plantes[50].

On peut considérer une quatrième dimension qui est le temps , on parle maintenant d'une pyramide des maladies vu que l'épidémie végétale apparait lorsque les périodes d'interférence entre les éléments du triangle sont prolongées (des jours, des heures ...).

L'interaction entre les éléments de la pyramide (la plante, le climat, le pathogène et le temps) constitue la base des systèmes de prévision des épidémies végétales. En effet, la surveillance des conditions climatiques permet d'estimer le stade de développement de l'agent pathogène (actif ou passif) et donc prévenir l'occurrence de la maladie.

### 3.4 Méthodes de détection des maladies des plantes

Après l'apaisement des symptômes de la maladie végétale, la présence de la maladie dans les plantes est vérifiée utilisant des techniques de détection de la maladie. Aujourd'hui; les techniques de détection des maladies végétales disponibles sont d'essai immunosorbent lié à des enzymes (ELISA), à base de protéines produit par l'agent pathogène, et la réaction en chaîne de

polymérase (PCR), sur la base de séquences spécifiques d'acide nucléique désoxyribose (ADN) de la pathogène.

Malgré disponibilité de ces techniques, il y a une demande pour la méthode sélective pour la détection rapide des maladies des plantes. Les techniques de détection des maladies peuvent être des méthodes direct ou indirectes ; la figure 3.3 résume ces méthodes [22].

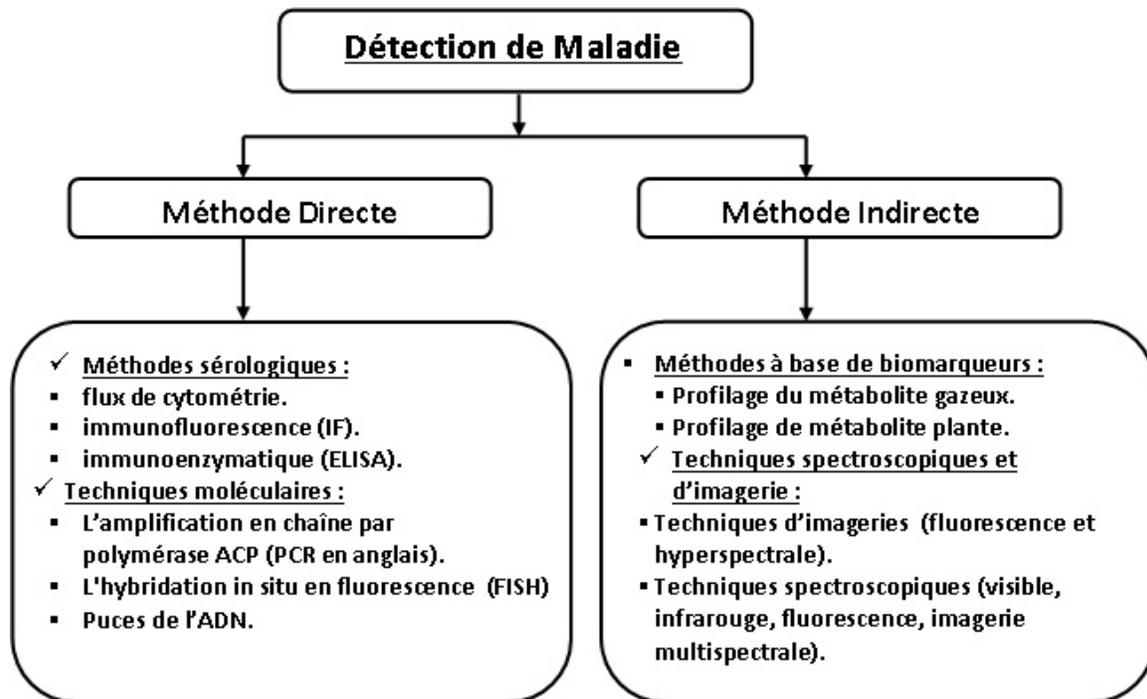


FIGURE 3.3 – Les méthodes de détection des maladies des plantes[22]

Deux approches prises pour détecter les maladies des plantes ; la première approche implique l'application des techniques d'imagerie pour la détection des maladies, et la deuxième décrit l'application de métabolites organiques volatils bio-marqueurs pour la détection des maladies. Ces deux approches sont sélectionnées car ils pouvaient d'être facilement intégrés à un véhicule pour une surveillance rapide, fiable et en temps réel des maladies végétales. Une technique avancée de détection des maladies végétales peut fournir une détection rapide, précise et fiable des maladies à un stade précoce pour l'économie, la production et l'agriculture avec plusieurs d'avantages.

Les études sur le terrain se réfèrent à des études qui impliquent la collecte de données spectrales dans des conditions de terrain, considérant que les études en laboratoire se réfèrent à la

collecte de données sous conditions de laboratoire [22].

1. **Techniques moléculaires de détection des maladies végétales :** Ces techniques moléculaires utilisées pour la détection des maladies sont ELISA et PCR [22]. D'autres techniques moléculaires incluent immunofluorescence (IF), cytométrie de flux, fluorescence in situ l'hybridation (FISH) et les puces d'ADN.
2. **Techniques spectroscopiques et d'imagerie pour la maladie :** Les techniques spectroscopiques [22] et d'imagerie sont les méthodes uniques de surveillance des maladies qui ont été utilisées pour détecter maladies dès les premiers symptômes s'apparu sur les plantes.

Savoir-que les techniques spectroscopiques et d'imagerie peuvent être intégrées dans un véhicule agricole autonome qui peut fournir des informations sur la détection des maladies à un stade précoce pour contrôler la propagation maladies des plantes.

### 3.5 Intelligence artificielle, l'apprentissage et le Big Data

L'apprentissage automatique c' est une technologie d'intelligence artificielle permettant aux ordinateurs d'apprendre sans avoir été programmés explicitement à cet effet. Pour apprendre et se développer, les ordinateurs ont toutefois besoin des données à analyser et sur lesquelles s'entraîner. Alors que , les données massives represente l'énergie du notre ML , et c'est la technologie qui permet d'exploiter pleinement ce volume important de données.l'apprentissage automatique peut être vu comme un processus informatique d'extraction de résultat que l'utilisateur cherche à analyser en fonction d'un objectif. Les méthodes utilisées peuvent être extrêmement diverses, mais concernent essentiellement des techniques issues de processus d'analyse statistique, ou de mise en œuvre de réseaux de neurones artificiels [54];la figure (fig. 3.4) explique ce positionnement de façon simplifiée.

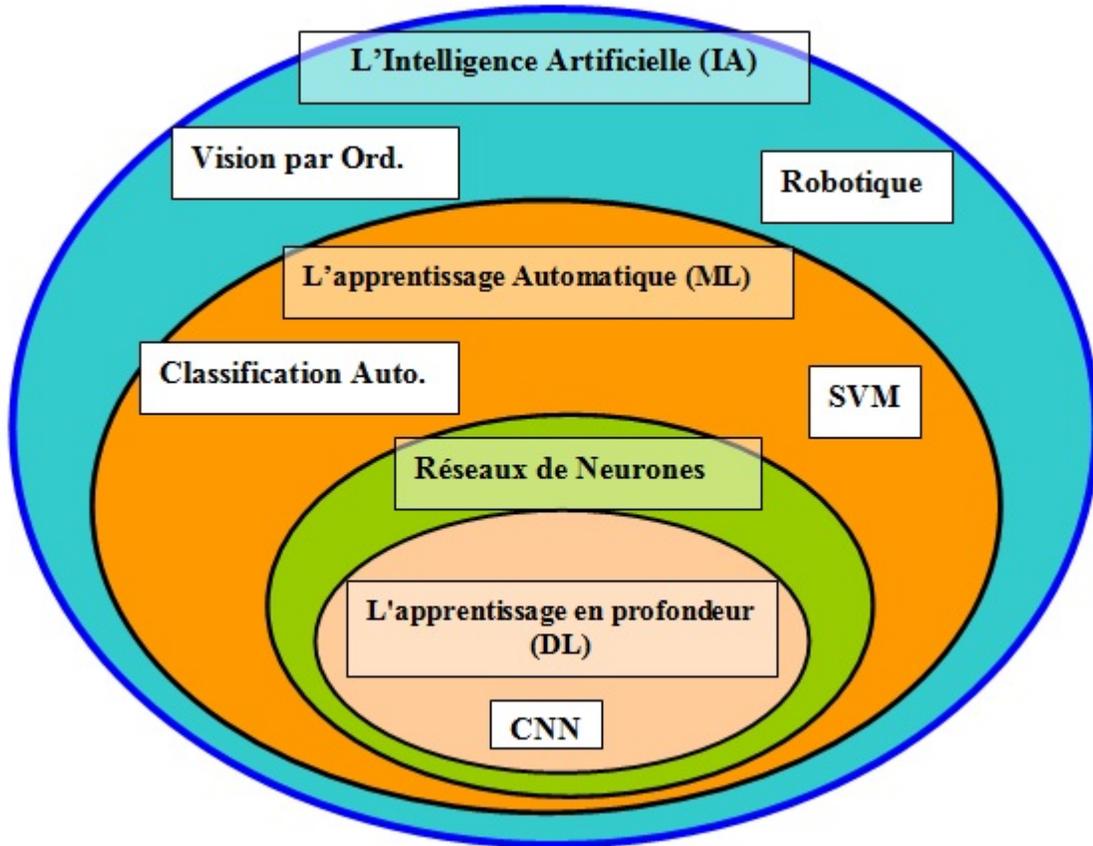


FIGURE 3.4 – Liens entre l'IA et l'apprentissage [32][24].

Même s'il existe des frontières et des intersections multiples, l'intelligence artificielle, l'apprentissage et le traitement des données sont des disciplines différentes.

On peut constater que la plupart des méthodes modernes s'appuient sur l'apprentissage et sur l'analyse d'un volume important de données[24].

L'approche des réseaux neuronaux est vue comme une nouvelle technique de programmation adaptée à des problèmes pour lesquels l'approche traditionnelle de conception des algorithmes est peu satisfaisante. Notons que les algorithmes de classification, que l'on peut considérer comme des algorithmes d'apprentissage supervisé; qu'il nous offre plusieurs avantages par rapport à l'apprentissage non-supervisé (voir Tab 3.1).

TABLE 3.1 – Comparaison entre l'apprentissage supervisé et non-supervisé [36][41].

	<b>Apprentissage supervisé (Classification)</b>	<b>Apprentissage non- supervisé (Clustering)</b>
<b>Données d'entrée</b>	Utilise les données connues et étiquetées comme entrées	Données inconnues en entrée
<b>Complexité informatique</b>	Très complexe	Moins de complexité informatique
<b>Temps réel</b>	Utilise l'analyse hors ligne	Utilise l'analyse en temps réel des données
<b>Sous-domaines</b>	Classification et régression	Exploitation de règles de clustering et d'association
<b>Précision</b>	Produit des résultats précis	Génère des résultats modérés
<b>Nombre de classes</b>	Nombre de classes connues	Le nombre de classes n'est pas connu

Les systèmes d'apprentissage automatique supervisé alimentent les algorithmes d'apprentissage (c'est bien le CNN dans notre travail) avec des quantités connues qui étayeront les futures décisions.

### 3.6 Les Travaux connexes

Aujourd'hui, les réseaux de neurones convolutifs (CNN) sont les plus performants et qu'il avoir les meilleures précisions pour la classification d'images. Une étude comparative entre ces approches utilisé dans la classification (voir Tab 3.2) :

TABLE 3.2 – Tableau comparative des techniques de classification [37]

N°	Techniques	Description	Avantages	Désavantages
01	Méthode k plus proches voisins (KNN)	Calculez la distance minimale entre les points.	Facile à mettre en œuvre et assez bon résultat.	Apprentissage lent, pas robuste aux données de bruit dans une grande BD.
02	SVM (support Vector Machine)	Construit Hyper plan dans un espace de dimension infinie.	-Précision de prédiction élevée et fonctionne correctement lorsque l'exemple de formation contient des erreurs.	-Difficile à comprendre la fonction apprise. -Grande nbr des vecteurs de support utilisés pour la formation. -Apprentissage lent
03	Réseau Neuronal Probabiliste (PNN)	Bassé à une structure à quatre couches qui implique le calcul de la distance, le stockage de la variable prédictive et la comparaison des votes.	Beaucoup plus rapide et plus précis	Nécessite un grand espace de stockage.
04	Logique flou	Utilisez la fonction d'adhésion pour convertir la valeur des données du monde réel en degré d'adhésion.	Haute vitesse, préférable en précision limitée	Dimensionnalité (grand nombre de fonctionnalités), performances médiocres.
05	RNA (Réseaux de Neurones Artificiels)	La perception multicouche est une forme de base d'RNA qui MAJ le poids via la propagation de base.	Bon potentiel avec capacité à détecter la maladie des feuilles des plantes.	Nécessite plus de temps

Dans ce cadre plusieurs approches sont actuellement utilisées pour détecter les maladies des plantes dans littérature [35] (voir Tab 3.2) ; cela suit à un progrès énorme de la technologie de l'IOT et même l'utilisation de la vision par ordinateur[39] ; ces dernières améliorent la pratique de l'agriculture de précision . Dans cette section, nous présentons quelques travaux [26][28][29] concernant le même contexte (voir Tab 3.3) :

TABLE 3.3 – Tableau connexes

<b>Travail</b>	<b>Pays</b>	<b>Récolte</b>	<b>Classificateur Et Méthode</b>	<b>Nbr D'Echenillions</b>	<b>Précision</b>	<b>Nbr Maladies Traiter</b>
Keke Zhang, 2018 [28].	La chine	Tomate	CNN (SGD , ADM)	5550 (feuille de tomate)	95%	8
José G. 2019 [26]	Brazil	café	CNN (t-SNE)	1747 (feuille de café)	94 ,05 %	4
Jie Hang 2019 [29]	La chine	Blé Cerise Pomme	CNN (SE)	6108 (Feuilles de : Blé, Cerise et pomme).	91.70 %	7

Notre travail consiste à mettre en disposition une machine learning à la base du CNN ; notre objectif c'est la prédiction des maladies dès que les premiers symptômes s'apparurent sur les feuilles des plants.

### 3.7 La synthèse :

Une étude comparative entre les travaux connexes qui sont pris comme exemple des études récentes illustre dans le tableau ( Tab.3.4). Ce qu'il est remarquable que ces travaux basés sur les réseaux de neurones convolutifs (CNN) comme meilleure approche de classification ; mais ils utilisent des bases de données limitées par rapport aux nombres des maladies traitées pour chaque travail (entre 4 et 8 classes de maladies).

TABLE 3.4 – Tableau Synthèse des Travaux connexes

<b>Etude</b>	<b>Avantages</b>	<b>Inconvénients</b>
Ke.Zhang[28] Sept.2018 La chine	Emergée Plusieurs approche (AlexNet, GoogLeNet ResNet avec SGD et ADM)	- Temps execution élevé (44 min et 13 sec) Et de 19 min et 31s avec une précision de 92.69%.
José G. [26] Juilly 2019 Brazil	Utiliser Plusieurs approche (AlexNet, GoogLeNet ResNet avec t-SNE).	-Base de données très limité et traite seulement 4 maladies.
Jie Hang [29] Sept.2019 La chine	-Base de données hétérogène (Blé, Cerise et pomme).	-Meilleure adaptabilité au changement de position spatiale de l'image. -Base de données un peu limité (6108 échenillons pour 10 classes).

Dans le même cadre ; notre travail basé sur le même algorithme CNN mais c'est plus pratique le fait qu'il ce base sur une méthode différente et une base de donnés récente qu'il regroupe plus de 16 mille images comme échantillons des feuilles de tomate et qu'ils sont classé en dix (10) classes et traite neuf (09) maladies détaillé dans le chapitre suivant.

### **3.8 Conclusion**

La détection précoce des plantes (avant l'début des symptômes de la maladie) pourraient être un source d'information pour l'exécution d'une bonne gestion de ravageuses stratégies et des mesures de lutte contre les maladies pour prévenir le développement et la propagation des maladies. Les techniques avancées de détection des maladies au sol qui pourrait éventuellement être intégrée à un véhicule agricole représente l'un des solutions.

Aujourd'hui il est indispensable de faire la mise en œuvre des stratégies de gestion appropriées telles-que les applications de fongicides, des produits chimiques spécifiques contre les maladies. Ces stratégies qu'ils nos permettons l'application de pesticides grâce à des informations instantanée sur la santé des agricultures et la détection des maladies; Cela pourrait faciliter le contrôle des maladies et améliorer la productivité. Les dernier années; des nombreuses applications d'apprentissage profond (DL)[53] qu'ils sont basé sur les réseaux de neurones convolutifs (CNN) sont utiliser dans le domaine de l'agriculture.

# Chapitre 4

## Conception de système

### 4.1 Introduction

L'objectif de la classification des images consiste à élaborer un système capable d'effectuer une tâche d'expertise de façon automatique;et qu'il peut s'avérer coûteuse à acquérir pour un être humain en raison notamment de contraintes physiques. La méthode de reconnaissance des maladies végétales décrite dans notre projet est ciblée pour le téléphone mobile. L'algorithme d'apprentissage constitue la méthode avec laquelle le modèle statistique va se paramétrer à partir des données d'exemple.

La méthode proposée est basée sur l'extraction de diverses caractéristiques comprennent le nombre de taches, leur zone relative, la couleur des feuilles et des halos à partir d'une photographie d'une feuille.

Dans ce chapitre, je présente un aperçu sur l'architecture générale de notre système , et aussi l'algorithme du CNN utilisée dans mon travail.

Ensuite, on va présenter la processus de détection des maladies ,et par la suite nos présentons les trois modèles proposés de CNN , en ce terminer le chapitre par une conclusion.

## 4.2 Description de l'Architecture

Notre système conçu pour recevoir en entre une image de la feuille de tomate afin d'avoir le résultat de classification de ce dernier; notre système propose aussi des consignes contre la maladie [51] détecter s'il existe sous forme de rapporte final. l'architecture générale de notre système (illustré dans la fig. 4.1)est subdivisé en deux phases principale suivant :

- Phase d'apprentissage (Entraînement).
- Phase de production (Prédiction).

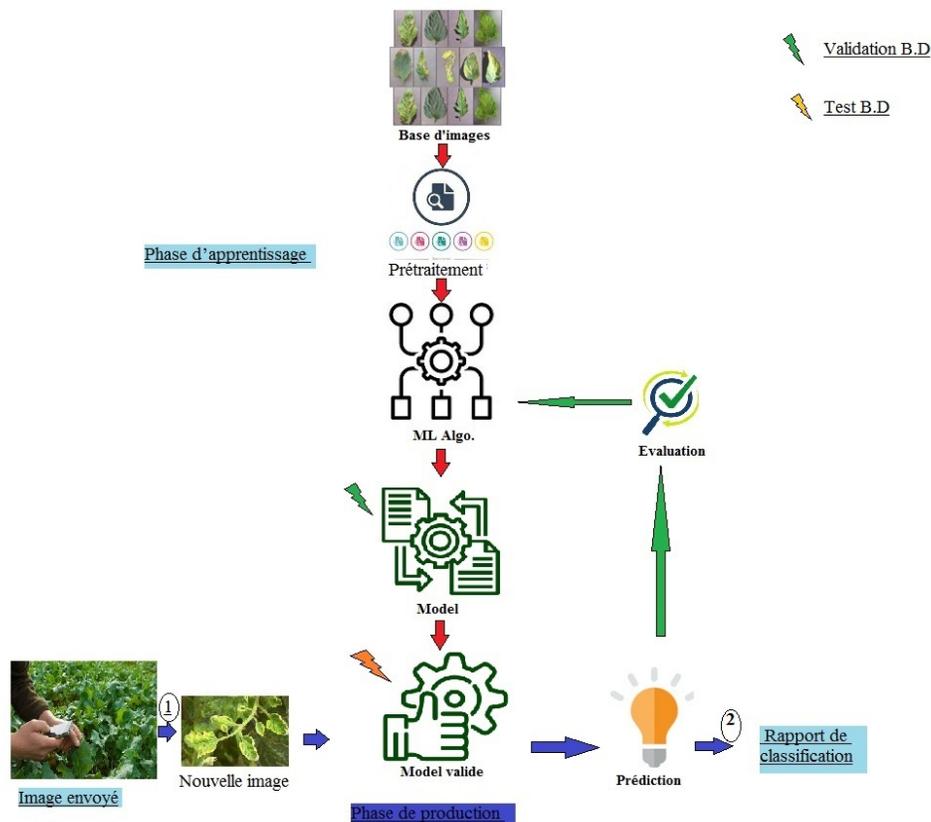
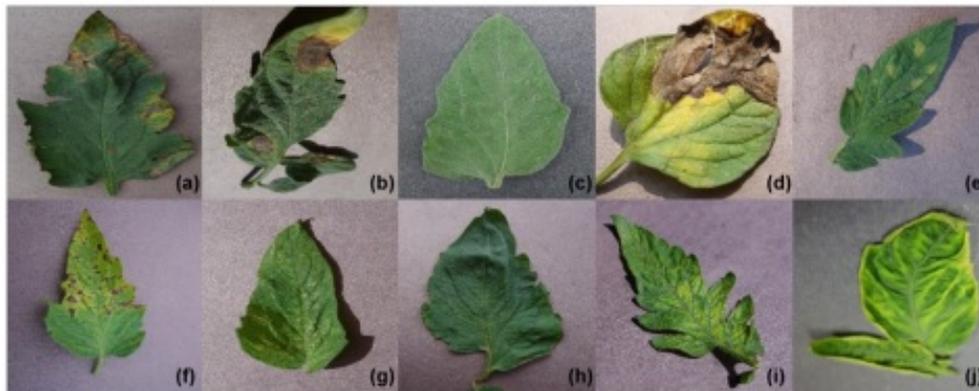


FIGURE 4.1 – Architecture générale de système.

### 4.2.1 Phase d'apprentissage :

La phase d'apprentissage ou d'entraînement; il s'agit d'un apprentissage supervisé dans notre système, l'apprentissage ce fait à travers une repertoire (monter à google drive) qu'il contient notre base de données et avec un nombre fini d'échantillons (voir quelque exemple dans la fi-

gure 4.2), cette étape consiste à l'augmentation des données d'apprentissages à travers l'algorithme d'apprentissage CNN pour obtenir un modèle du CNN (cette étape représenté par la fig 4.3), le première modèle obtenu ne sera pas validé que après la compilation par une ensembles des données dite des échantillons de validation pour obtenir comme résultat finale un modèle validé. Par la suite on teste le modèle validé par une autre repertoire différent qu'il contient la base de données pour test. L'étape final sera la mis en exploitation avec un contrôle et évaluation continu (voir la fig. 4.1).



(a) Bacterial Spot, (b) Early Blight, (c) Healthy, (d) Late Blight, (e) Leaf Mold. (f) Septoria Leaf Spot, (g) Spider Mites, (h) Target Spot, (i) Mosaic Virus, et (j) Yellow Leaf Curl Virus.

FIGURE 4.2 – Échantillons de la base des images [PlantVillage – Dataset]

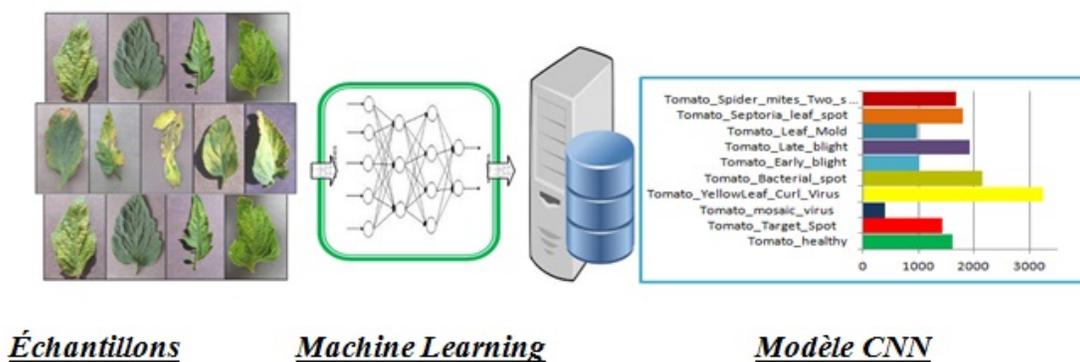


FIGURE 4.3 – Représentation de la phase d'apprentissage

L'évaluation d'un modèle consiste c'est un travail compliqué consiste à estimer une densité

de probabilité pour reconnaître la présence d'une telle maladie dans une image . On parle de classification ou de classement d'une image d'entre déclenché par la phase prédiction.

### **4.3 Phase de production :**

La deuxième phase correspond à la mise en production ou prédiction (classification des maladies) : le modèle étant déterminé, de nouvelles données peuvent alors être soumises afin d'obtenir le résultat correspondant à la tâche souhaitée. En pratique, l'acquisition d'une photo (d'une feuille de la tomate ) par un message indiqué dans le schéma passé par la transaction numéro (1) afin d'avoir une classification et diagnostic de l'image recevez suivante le modèle généré par la phase d'apprentissage et le résultat obtenu par le système sera retransmettre par la voie de transaction numéro (2) à l'émetteur de l'image.

Savoir que l'échange des données avec les deux mécanismes de transaction (1) et (2) se fait à travers une application Smartphone sous système Androïde.

### **4.4 Description de la Base de données d'apprentissage :**

Nous avons utilisé un Base de données récente du PlantVillage c'est un référentiel ouvert qui contient plus de 54 mille d'images regroupe 14 cultures et 38 classes des maladies et pour des différent types des plantes, De cet ensemble de données, seules des images de feuilles de tomates ont été extraites. Dans le tableau (Tab 4.1) on présente un résumé de notre base de données utilisé dans ce travail.

TABLE 4.1 – Description de la Base de données d’apprentissage

Désignation de classe	Classe de Maladie	Nombre d’échantillons	Pourcentage
Tomato healthy	NON	1591	9,94%
Tomato Target Spot	OUI	1404	8,77%
Tomato mosaic virus	OUI	373	2.33%
Tomato yellow leaf curl virus	OUI	3209	20.04%
Tomato Bacterial spot	OUI	2127	13.28%
Tomato Early blight	OUI	1000	6.25%
Tomato Late blight	OUI	1909	11.92%
Tomato Leaf Mold	OUI	952	5.95%
Tomato Septoria leaf spot	OUI	1771	11.06%
Tomato Spider mites Two spotted	OUI	1676	10.47 %
<b>Totale</b>		<b>16012</b>	<b>100 %</b>

Le nombre total d’images dans notre base de données contient plus de 16 mille image d’éche- nillent sont réparties en neuf (09) classes des maladies (Les symptômes de chaque maladies ex- plique dans le tableau (Tab. 4.2 voir annexe) qu’ils peuvent attaqués la plante de tomate ,au plus une classe des feuilles en bon santé. Toutes les images utilisées dans ce travail étaient déjà de taille (256x256) c’est la taille d’entrée du notre système.

## 4.5 Processus de détection des maladies

Le traitement d’images est une discipline de l’informatique et des mathématiques appli- quées qui étudie les images numériques et leurs transformations, dans le but d’améliorer leur qualité ou d’en extraire de l’information, Un système de traitement numérique d’images se compose essentiellement de Cinq étapes illustré dans la figure (fig. 4.4) suivante :

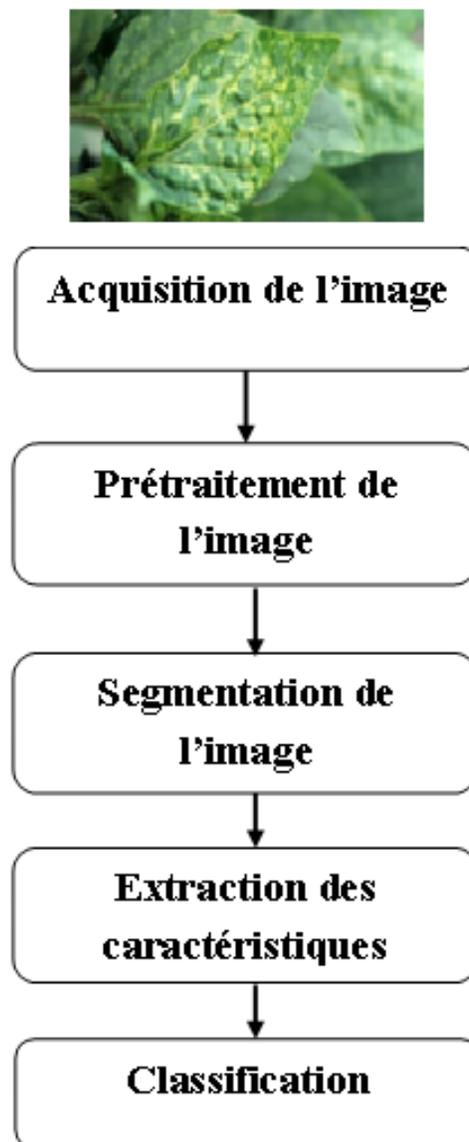


FIGURE 4.4 – Processus de détection des maladies

#### 4.5.1 Acquisition de l'image :

C'est la reception en ligne d'une image numérique d'une feuille de plante par une source qu'il peut etre un caméra ou Smartphone [1].

### 4.5.2 Prétraitement de l'image :

Le prétraitement regroupe un ensemble des opérations à pour objectifs de nettoyer et normaliser les images, et aussi d'améliorer les caractéristiques des images ; comme exemples de ces opérations on peut citer les suivants :

- Le lissage local : il s'agit de supprimer le bruit, ou les petites variations, présent dans une image. L'intensité d'un pixel est transformée en fonction des intensités sur un petit voisinage du pixel.
- L'amélioration d'images consiste à modifier les caractéristiques visuelles de l'image (contraste, ...) pour faciliter son interprétation par l'œil humain.
- La restauration d'images a pour but de supprimer les dégradations subies par une image à l'aide de connaissance a priori sur ces dégradations [39]. -La normalisation fait référence à la normalisation des dimensions des données (les images) afin qu'elles soient approximativement de la même échelle. Cela augmentera certainement la précision car les données sont mises à l'échelle dans une plage supérieure à des valeurs arbitrairement grandes ou trop petites.

### 4.5.3 La Segmentation d'image :

La Segmentation et la localisation des régions d'importance dans l'image[40], C'est une étape importante et primordiale dans le processus de traitement et d'analyse d'images qui a pour but de partitionner une image en régions homogènes (par exemple, même couleur) .Différentes approches de segmentation[38], les méthodes de segmentation sont regroupées en trois approches suivantes :

1. Segmentation basée sur les contours (edge-based segmentation) comme exemple la méthode Canny [42].
2. Segmentation basée sur les régions (régions-based segmentation).
3. Segmentation en utilisant la classification.

-Notre approche basé sur la les détecteurs de contour [38] avec la méthode l'espace HSV (teinte, saturation, luminosité) (voir fig. 4.5) qu'il été utilisé avec les avantages suivants : Bonne détection, Bonne localisation, Clarté de la réponse.

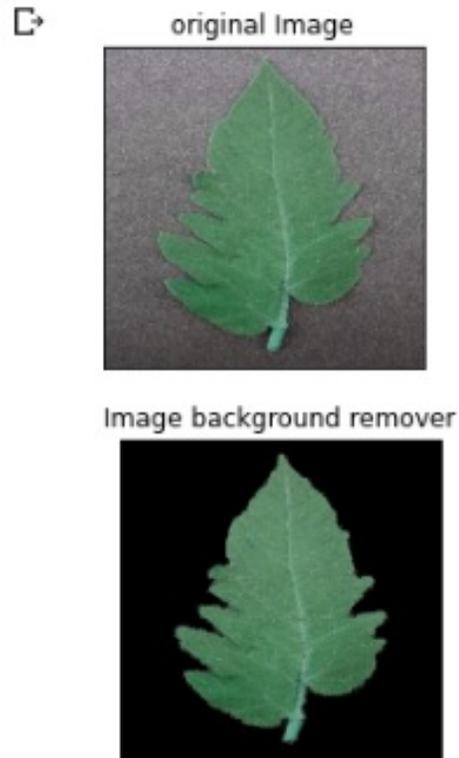


FIGURE 4.5 – Résultat de Méthode HSV

#### 4.5.4 Extraction des caractéristiques :

Extraction les caractéristiques des feuilles qui sont susceptibles de changer avec différentes contours de l'image en ce basent sur l'opération de segmentation.

#### 4.5.5 Classification d'image :

C'est la dernier étape de notre processus et qu'il signifié l'application de l'algorithme CNN à l'image obtenu par l'étape précédent afin d'avoir meilleur précision. La classification consiste à attribuer à l'image entrée une classe d'appartenance parmi les classes déjà vu à la phase d'apprentissage de notre modèle.

## 4.6 Méthode et Algorithme utilise :

Nous avons utilisé l'apprentissage en profondeur et en particulier le réseau de neurones Convolutifs (CNN)[41] comme approche alternative pour construire un modèle de classification des maladies[33]. Nous utilisons l'algorithme CNN pour extraire les caractéristiques de l'image d'entrée donnée de la plante afin de classer ce dernier et détecter la classe de maladie (s'il existe).

Un CNN est simplement un empilement de plusieurs couches(voir la figure (fig.4.6) qui représente un Schéma générale d'un classification CNN) et ca commence par une couche de convolution et par la suite une séquence de cette dernier et les couches suivantes : pooling, correction Relu et se termine par une couche fully-connected; tous ca selon le modèle utiliser comme on a vu dans le chapitre présidente. Chaque image reçue en entrée va donc être filtrée, réduite et corrigée plusieurs fois, pour finalement former un vecteur.

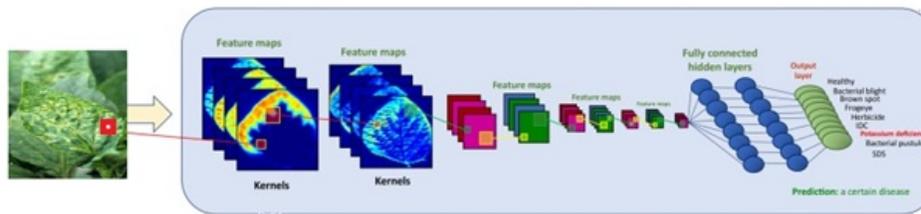


FIGURE 4.6 – Schéma générale d'un classification CNN [52]

## 4.7 Le paramétrage des couches CNN :

Un réseau de neurones convolutif se distingue d'un autre par la façon dont les couches sont empilées, mais également paramétrées. Les couches de convolution et de pooling possèdent en effet des hyperparamètres, c'est-à-dire des paramètres dont vous devez préalablement définir la valeur. Les features de la couche de convolution et les poids de la couche fully-connected ne sont pas des hyperparamètres, puisqu'ils sont appris par le réseau de neurones[41] lors de la phase d'entraînement.

La taille des feature maps en sortie des couches de convolution et de pooling dépend des hyperparamètres. Chaque image (ou feature map) est de dimensions  $W \times H \times D$ , telle-que :  $W$  c'est

sa largeur en pixels, et  $H$  : c'est sa hauteur en pixels et  $D$  : c'est le nombre de canaux égale à un pour une image en noir et blanc, et trois pour une image en couleur.

-La couche de convolution possède quatre hyperparamètres :

1. **Le nombre de filtres  $K$**
2. **La taille  $F$  des filtres** : chaque filtre est de dimensions  $F \times F \times D$  pixels.
3. **Le pas  $S$**  : avec lequel on fait glisser la fenêtre correspondant au filtre sur l'image. Par exemple; un pas de 1 signifie qu'on déplace la fenêtre d'un pixel à la fois.
4. **Le zero-padding  $P$**  : on ajoute à l'image en entrée de la couche un contour noir d'épaisseur  $P$  pixels. Sans ce contour, les dimensions en sortie sont plus petites. Ainsi; plus on empile de couches de convolution avec  $P=0$ .

- La couche de pooling possède seulement deux hyperparamètres :

1. **La taille  $F$  des cellules** : l'image est découpée en cellules carrées de taille  $F \times F$  pixels.
2. **Le Pas  $S$**  : les cellules sont séparées les unes des autres de  $S$  pixels Pour chaque image de taille :  $W \times H \times D$  en entrée, la couche de pooling renvoie une matrice de dimensions :  $WP \times HP \times DP$ , telle-que :  $WP = WFS + 1$ ,  $HP = HFS + 1$  et  $DP = D$ .

## 4.8 Les modèles CNN proposés

### 4.8.1 - Modèle Proposé N° 01 :

La premier modèle que nous présentons dans la figure (fig.4.7) ci-dessous est composé de quatre (04) couches de convolution et quatre (04) couches de pooling et de trois couches de fully-connected.

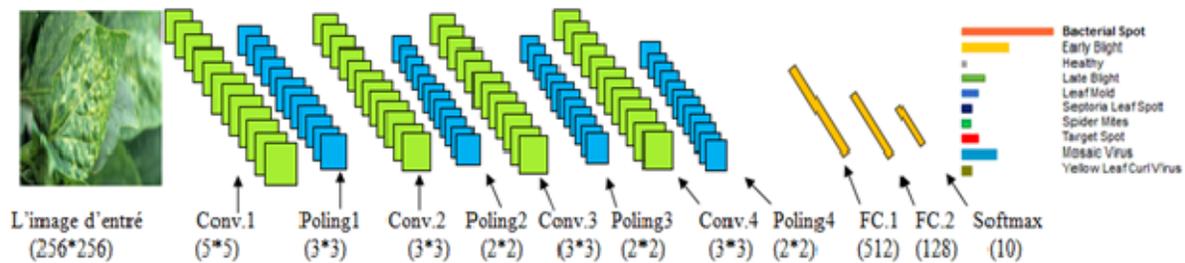


FIGURE 4.7 – -Le Modèle Proposé N° 01

L'image en entrée est de taille 256\*256, l'image passe d'abord à la première couche de convolution. Cette couche est composée de 32 filtres de taille (5\*5), la fonction d'activation ReLU est utilisé, cette fonction d'activation force les neurones à retourner des valeurs positives, après cette convolution 32 features maps de taille (32\*32) seront créés.

Ensuite, les 32 feature maps qui sont obtenus ils sont donnés en entrée de la première couche de pooling pour réduire la taille de l'image et des paramètres à la sortie de cette couche, nous aurons 32 feature maps de taille (3\*3). On répète la même chose avec les couches de convolutions deux, trois et quatre (la deuxième couche est composée de 32 filtres tandis que les couches trois et quatre sont composées de 64 filtres), la fonction d'activation ReLU est appliquée toujours sur chaque convolution; Une couche de pooling est appliquée après chaque couche de convolutions.

À la sortie de la dernière couche pooling, nous aurons 64 feature maps de taille (8\*8). Le vecteur de caractéristiques issu des convolutions a une dimension de 4096.

Après ces six couches de convolution, nous utilisons un réseau de neurones composé de trois couches fully connected. La première couche avec 512 neurones où la fonction d'activation utilisée est le ReLU, et la deuxième couche avec 128 neurones et la troisième couche est un Softmax

qui permet de calculer la distribution de probabilité des 10 classes (nombre des classes dans la base d'image).Le tableau (Tab 4.2) résume cette démarche.

TABLE 4.2 – les couches du Modèle N°01

<b>Input</b>	<b>Layer Type</b>	<b>Output Size</b>	<b>kernel size</b>	<b>Activation</b>
<b>01</b>	Conv1	252 × 252× 32	5x5	Relu
<b>02</b>	Pool1/max	84 × 84× 32	3x3	Relu
<b>03</b>	Conv2	82 × 82× 32	3x3	Relu
<b>04</b>	Pool2/max	41 × 41 × 32	2x2	Relu
<b>05</b>	Conv3	39 × 39 × 64	3x3	Relu
<b>06</b>	Pool2/max	19 × 19× 64	2x2	Relu
<b>07</b>	Conv4	17x17x64	3x3	Relu
<b>08</b>	Pool4/max	8 × 8 × 64	2x2	Relu
	Flotten	4096	-	Relu
<b>09</b>	Dens	512	-	Relu
	Droupt	512	-	Relu
<b>10</b>	Dens	128	-	Relu
	Dens	10	-	Softmax

- l'étape d'exécution de cette modèle comme dans la figure (fig.4.8)suivant :



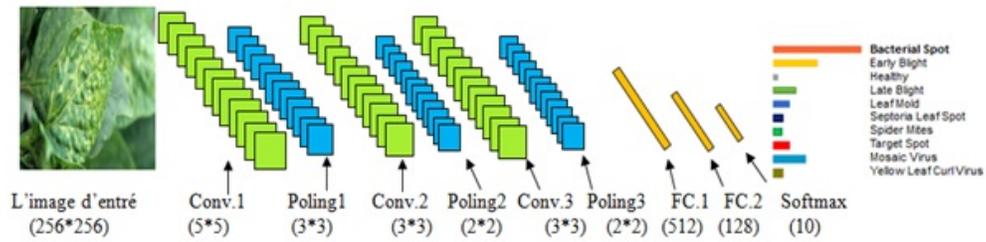


FIGURE 4.9 – Le Modèle Proposé N° 02

TABLE 4.3 – les couches du Modèle N° 02

Input	Layer Type	Output Size	kernel size	Activation
01	Conv1	252 × 252 × 32	5x5	Relu
02	Pool1/max	84 × 84 × 32	3x3	Relu
03	Conv2	82 × 82 × 32	3x3	Relu
04	Pool2/max	41 × 41 × 32	2x2	Relu
05	Conv3	39 × 39 × 64	3x3	Relu
06	Pool2/max	19 × 19 × 64	2x2	Relu
	Flotten	23104	-	Relu
07	Dens	512	-	Relu
	Droupt	512	-	Relu
08	Dens	128	-	Relu
	Dens	10	-	Softmax

- l'étape d'exécution de cette modèle dans la figure (fig.4.10) ci-dessous :

```

Model: "sequential_1"
Layer (type)                Output Shape                Param #
-----
conv2d_1 (Conv2D)           (None, 252, 252, 32)       2432
activation_1 (Activation)    (None, 252, 252, 32)       0
max_pooling2d_1 (MaxPooling2 (None, 84, 84, 32)         0
conv2d_2 (Conv2D)           (None, 82, 82, 32)         9248
activation_2 (Activation)    (None, 82, 82, 32)         0
max_pooling2d_2 (MaxPooling2 (None, 41, 41, 32)         0
conv2d_3 (Conv2D)           (None, 39, 39, 64)         18496
activation_3 (Activation)    (None, 39, 39, 64)         0
max_pooling2d_3 (MaxPooling2 (None, 19, 19, 64)         0
flatten_1 (Flatten)         (None, 23104)              0
dense_1 (Dense)             (None, 512)                11829760
activation_4 (Activation)    (None, 512)                0
dropout_1 (Dropout)         (None, 512)                0
dense_2 (Dense)             (None, 128)                65664
activation_5 (Activation)    (None, 128)                0
dense_3 (Dense)             (None, 10)                 1290
activation_6 (Activation)    (None, 10)                 0
-----
Total params: 11,926,890
Trainable params: 11,926,890
Non-trainable params: 0
    
```

FIGURE 4.10 – les couches du Modèle N° 02

### 4.8.3 - Modèle Proposé N° 03

La troisième modèle que nous présentons dans la figure (fig.4.11) ci-dessous est composé de quatre (04) couches de convolution de taille (3\*3) et deux (02) couches de pooling de taille entre (3\*3)et (2\*2) et par la suite trois couches de fully-connected. Le tableau (Tab.09) suivent résume cette démarche :

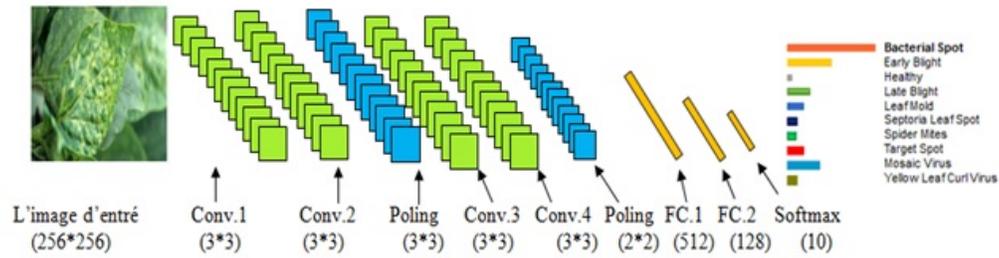


FIGURE 4.11 – Le Modèle Proposé N° 03

TABLE 4.4 – les couches du Modèle N° 03

Input	Layer Type	Output Size	kernel size	Activation
01	Conv1	254 × 254 × 32	5x5	Relu
02	Conv2	252 × 252 × 32	3x3	Relu
03	Pool1/max	84 × 84 × 32	3x3	Relu
04	Conv3	82 × 82 × 64	2x2	Relu
05	Conv4	80 × 80 × 64	3x3	Relu
06	Pool2/max	40 × 40 × 64	2x2	Relu
	Flotten	102400	-	Relu
07	Dens	512	-	Relu
	Droupt	512	-	Relu
08	Dens	128	-	Relu
	Dens	10	-	Softmax

- l'étape d'exécution de cette modèle comme suivant :

```

Model: "sequential_6"
-----
Layer (type)                Output Shape                Param #
-----
conv2d_21 (Conv2D)          (None, 254, 254, 32)       896
activation_36 (Activation)   (None, 254, 254, 32)       0
conv2d_22 (Conv2D)          (None, 252, 252, 32)       9248
activation_37 (Activation)   (None, 252, 252, 32)       0
max_pooling2d_13 (MaxPooling (None, 84, 84, 32)       0
conv2d_23 (Conv2D)          (None, 82, 82, 64)         18496
activation_38 (Activation)   (None, 82, 82, 64)         0
conv2d_24 (Conv2D)          (None, 80, 80, 64)         36928
activation_39 (Activation)   (None, 80, 80, 64)         0
max_pooling2d_14 (MaxPooling (None, 40, 40, 64)         0
flatten_6 (Flatten)         (None, 102400)             0
dense_16 (Dense)            (None, 512)                52429312
activation_40 (Activation)   (None, 512)                0
dropout_6 (Dropout)         (None, 512)                0
dense_17 (Dense)            (None, 128)                65664
activation_41 (Activation)   (None, 128)                0
dense_18 (Dense)            (None, 10)                 1290
activation_42 (Activation)   (None, 10)                 0
-----
Total params: 52,561,834
Trainable params: 52,561,834
Non-trainable params: 0

```

FIGURE 4.12 – les couches du Modèle N° 03

**Remarque :** Les résultats et les paramètres de classification obtenu avec de chacun des trois modèles proposés avec une étude comparative seront présentés en détails dans le chapitre suivant.

## **4.9 Conclusion**

Nous avons présenté dans ce chapitre une approche de classification basée sur les réseaux de neurones convolutifs, pour cela on a utilisé trois modèles avec différentes architectures afin de voir l'impact de ces changements d'architecture sur les résultats de chaque modèle en matière de fiabilité (précision) et performance (vitesse d'exécution), et ce que nous avons remarqué que la base d'apprentissage est également un élément déterminant dans les réseaux de neurones convolutifs et c'est pour cela qu'il faut avoir une base d'apprentissage de grande taille pour aboutir à des meilleurs résultats et c'est exactement ce que nous avons entraîné de faire dans notre projet.

# Chapitre 5

## Résultats Expérimentaux et Discussions

### 5.1 Introduction

Dans ce chapitre, on va présenter les résultats obtenu pour les trois modèles proposé avec une étude comparative détaillée. Pour cela, on va travailler sous Google Colab avec les bibliothèques Tensorflow et Keras pour l'apprentissage et la classification et afin d'améliorer les performances des modèles on va utiliser quelques techniques simple et efficaces comme data augmentation.

### 5.2 Les outils de Développement et Platform utilisé

#### 5.2.1 Google "Colaboratory" :

L'outil "Colaboratory" de Google est un outil collaboratif de développement. Basée sur la plateforme Jupyter et écrit dans le langage Python, cette plateforme permet à un groupe de développeurs d'écrire du code pour un même projet grâce à un système de Netbooks et de cellules de code. L'outil est pleinement intégré dans la famille des outils Google. Il est possible de faire appel aux autres services pour utiliser un fichier local ou alors de mettre en ligne un fichier depuis son ordinateur. Le service de stockage Google Drive permet de conserver en ligne ses fichiers afin de les retrouver sur n'importe quel appareil lié à son compte Google. Il est possible de monter son lecteur Google Drive dans l'interface de Colobotary. Pour effectuer cette opération, ouvrez une cellule de code et copiez le code suivant à l'intérieur [44] Colaboratory, souvent raccourci en "Colab", vous permet d'écrire et d'exécuter du code Python dans votre navigateur,

avec • Aucune configuration requise • Accès gratuit aux GPU • Partage facile Colab vous permet d'importer un ensemble de données d'images, d'entraîner un classificateur d'images sur cet ensemble et d'évaluer le modèle, tout cela avec quelques lignes de code. Les notebooks Colab exécutent ce code sur les serveurs cloud de Google. Vous avez donc à votre disposition toute la puissance du matériel Google, y compris les GPU et TPU, quelle que soit la puissance de votre ordinateur. Vous n'avez besoin que d'un navigateur.

### **5.2.2 Jupyter Notebook**

Elle a été publiée en 2015, Jupyter Notebook [43] c'est une application client-serveur créée par l'organisation à but non lucratif Project Jupyter. Elle permet la création et le partage de documents Webauformat JSON constitués d'une liste ordonnée de cellules d'entrées et de sorties et organisés en fonction des versions successives du document. Les cellules peuvent contenir, entre autres, du code, du texte au format Markdown, des formules mathématiques. Le traitement se fait avec une application client fonctionnant par Internet, à laquelle on accède par les navigateurs habituels. Il est nécessaire pour cela que soit installé et activé dans le système le serveur Jupyter Notebook. Les documents Jupyter créés peuvent s'exporter aux formats HTML, PDF, Markdown ou Python par exemple, ou bien se partager par email, avec Dropbox, GitHub ou un lecteur Jupyter Notebook.

### **5.2.3 TensorFlow**

TensorFlow est un outil open source d'apprentissage automatique développé par Google. Utilisée par : EBay, Twitter, Airbus, AirBnb et Intel. TensorFlow est l'un des outils les plus utilisés en IA dans le domaine de l'apprentissage automatique [56]. Elle a été utilisée pour la recherche et le déploiement de l'apprentissage automatique dans une grande variété de domaines, contenant la reconnaissance vocale, la vision par ordinateur, la robotique, la récupération d'informations, le traitement du langage naturel, ...

Le fonctionnement interne de Tensorflow est la clé de son succès. Un calcul TensorFlow est décrit par un graphe, qui se compose d'un ensemble de nœuds. Le graphe représente un flux de données et ses transformations, avec des extensions permettant à certains types de nœuds de

maintenir et de mettre à jour des états persistants.

#### **5.2.4 Keras**

C'est l'API de haut niveau de TensorFlow permettant de créer et d'entraîner des modèles de deep learning. Elle est utilisée dans le cadre du prototypage rapide, de la recherche de pointe et du passage en production. on présente quelques avantages de keras [55] :

-Convivialité : Keras dispose d'une interface simple et cohérente, optimisée pour les cas d'utilisation courants. Elle fournit des informations claires et concrètes concernant les erreurs des utilisateurs. -Modularité et facilité de composition :Les modèles Keras sont créés en connectant des composants configurables, avec quelques restrictions. -Facilité d'extension :Composez des éléments de base personnalisés pour exprimer de nouvelles idées de recherche. Créez des calques, des métriques et des fonctions de perte, et développez des modèles de pointe.

#### **5.2.5 Matplotlib**

Matplotlib Matplotlib est probablement l'un des packages Python les plus utilisés pour la représentation de graphiques en 2D.C'est une bibliothèque du langage de programmation Python ,qu'il été destinée à tracer et visualiser des données sous formes de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy. Sa version stable actuelle est compatible avec la version 3 de Python [45].Matplotlib est distribuée librement et gratuitement sous une licence de style BSD.

#### **5.2.6 Equipment utilise :**

Un seul lap-top EliteBook 8570P a été utilisé pour l'ensemble du processus de formation et de test du modèle de détection des maladies des plantes décrit dans cet article. Chaque itération de formation a pris plusieurs heures sur cette machine spécifiée dont les caractéristiques de base sont présentées dans le tableau (Tab 5.1)suivant :

TABLE 5.1 – Caractéristiques de Lap-Top EliteBook 8570P

Hardware et software	Caractéristiques
RAM	16 GB
Processeur	Intel Core i7-3520M CPU @ 2.90GHz
Système d'exploitation	Windows7 64 bits

### 5.2.7 Interface de Système :

L'interface graphique de notre application réaliser à la base de module d'interface Tk .l'interface sous forme d'une fenêtre principale (voir la fig.5.1) qu'il contient deux boutons pour le choix de fonctionnement :

- fenêtre pour mode apprentissage .
- fenêtre pour mode prédiction .

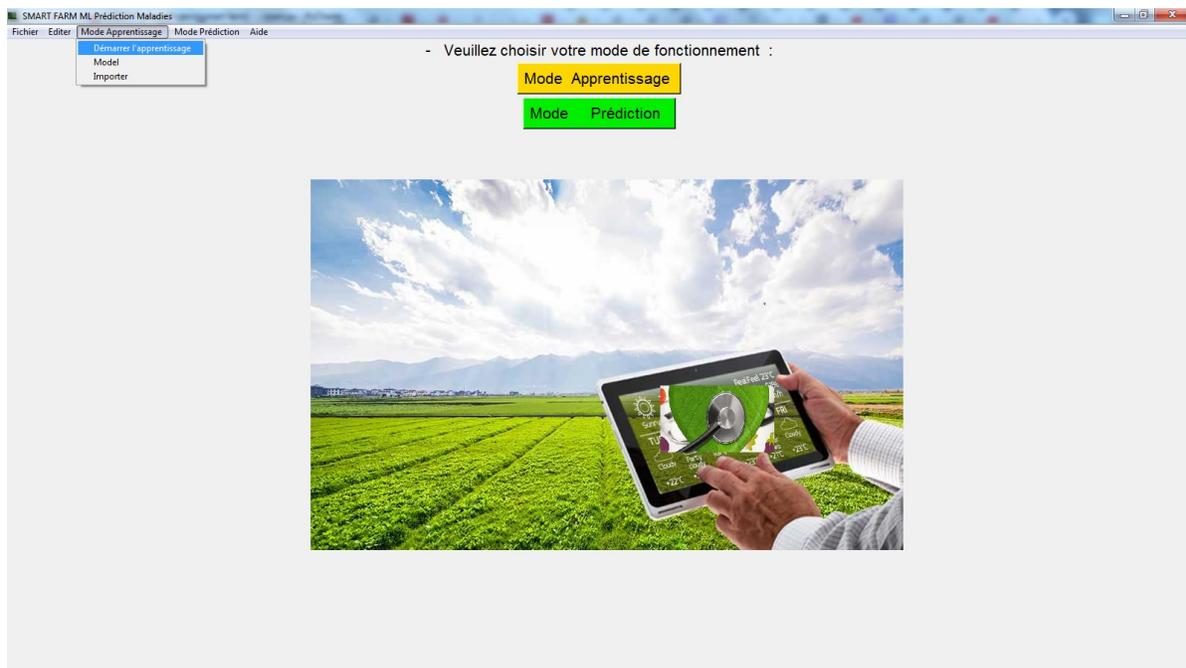


FIGURE 5.1 – La fenêtre principale de système.

- Mode apprentissage : Pour lance l'apprentissage de system ;il faut d'abord sélectionner le fichier qu'il contient la base de donnée et démarrer l'apprentissage(voir la fig.5.2).

L'entraînement du modèle CNN a été effectuée avec les base d'apprentissage et de validation importe sur Google Drive. Savoir que l'exécution ce fait enligne avec Google Colab. Je préfère de faire une description(voir la figure fig.5.2) des répertoires : training , validation et teste afin d'avoir une aider sur ces contenu avant de lancer directement la phase d'apprentissage.

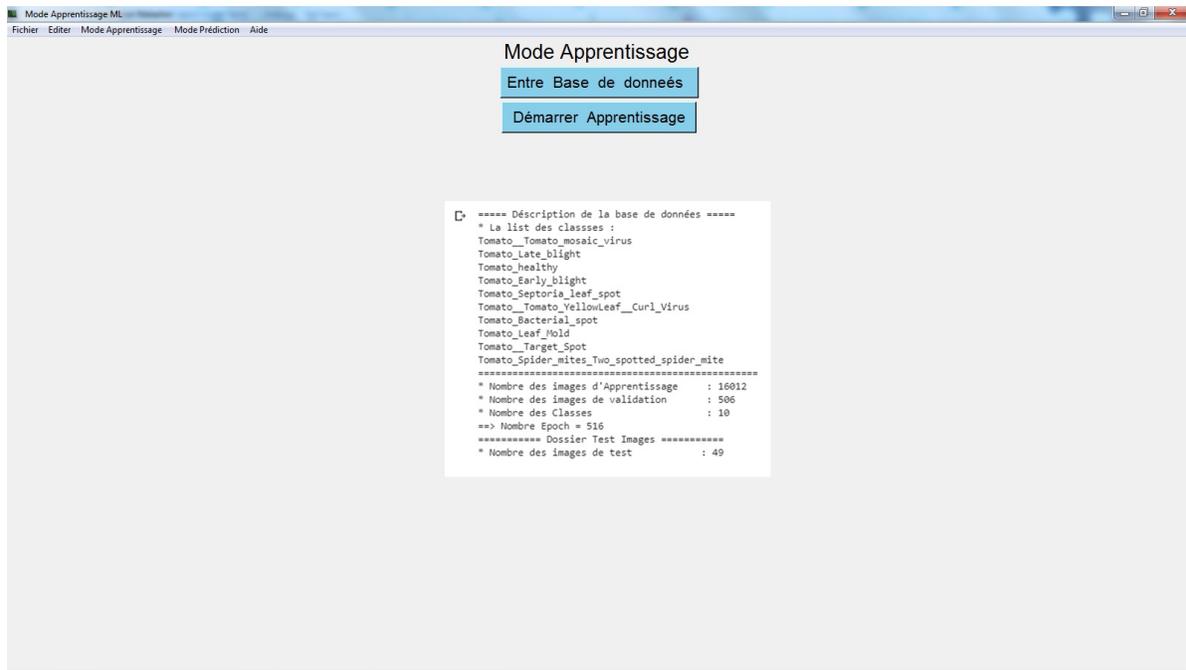


FIGURE 5.2 – La fenêtre Mode apprentissage.

-Mode prédiction : Pour lancer la prédiction d'une image il faut sélectionner l'image et démarrer la fonction de prédiction de telle façon que l'image et le rapporte de prédiction ce figure dans la même fenêtre (voir la fig.5.3).

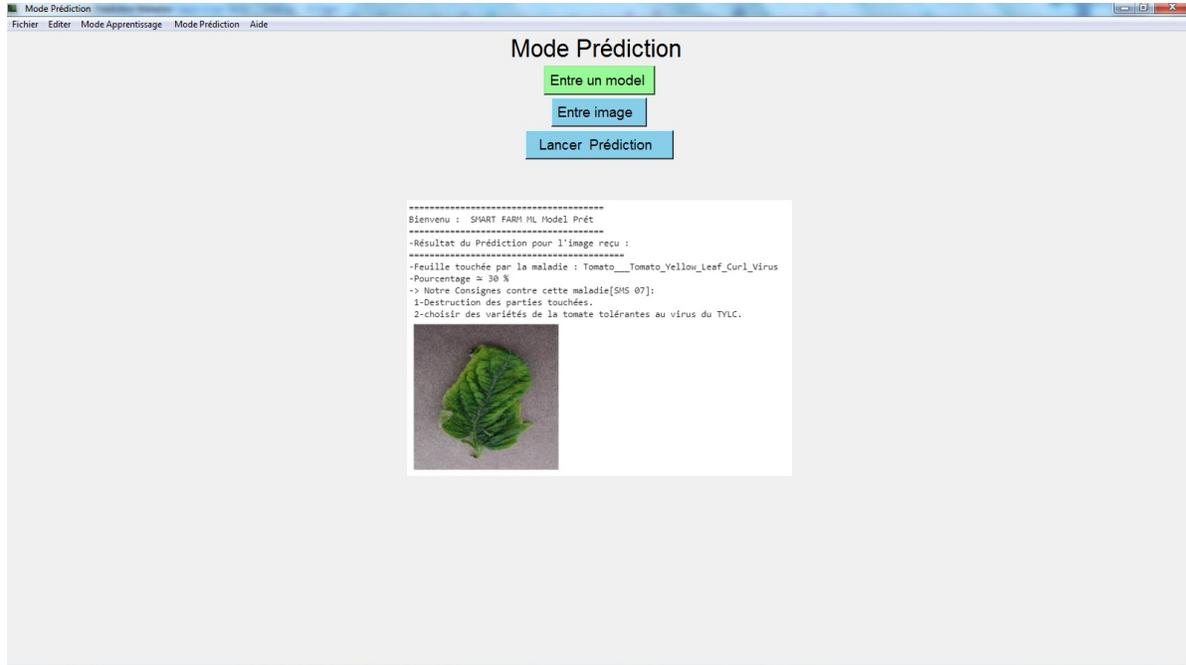


FIGURE 5.3 – La fenêtre Mode prédiction.

### 5.3 Les Résultats Obtenus

Dans cette section; je présente les résultat obtenu dans la phase d'apprentissage (training) et Après la compilation des trois modèle proposés; On observe que la précision augmente très rapidement à partir le Moitié des images.

je note ici que notre étude comparative fait avec des batch size différentes et aussi avec des jeux des images différentes; savoir que les images de validations sont différentes complètement en qualite et en quantité , et aussi l'ensemble des images de validation contient uniquement les données que le modèle ne voit jamais pendant l'apprentissage et la même chose pour le jeu de d'images de teste, l'ensemble des images de validation et de test représente que 20 à 30% par rapport au jeux des images d'apprentissage.

on peut présenter les résultats obtenu pour chaque modèle comme suite :

### 5.3.1 Model 01 :

Sur le premier graphique (voir la figure fig.5.5)qu'il représente les précisions des données de d'entraînement et de validation avec (batch size=32), on peut voir que la haute précision de 83.47% est atteinte après 16 époques. Dans les époques suivantes sur la parcelle, la précision ne s'améliore pas et diminue même dans l'intervalle 15 à17 époques(voir la figure fig.5.4).

Sur le deuxième graphique qu'il représente les pourcentages d'erreur (Loss) des données d'entraînement et de validation, on remarque que ces pourcentage se démunie rapidement dès que la précision de modèle s'augmente et cela ce tout à fait normale puisque le modèle est en entraînement et dès que la précision s'améliorer alors l'erreur de classification se démunie rapidement.

```

Epoch 1/18
16/16 [*****] - 58s 4s/step - loss: 2.3210 - accuracy: 0.2934 - val_loss: 1.6841 - val_accuracy: 0.4062
Epoch 2/18
16/16 [*****] - 54s 3s/step - loss: 1.6064 - accuracy: 0.4442 - val_loss: 1.1899 - val_accuracy: 0.5207
Epoch 3/18
16/16 [*****] - 55s 3s/step - loss: 1.4065 - accuracy: 0.4902 - val_loss: 1.1819 - val_accuracy: 0.5909
Epoch 4/18
16/16 [*****] - 52s 3s/step - loss: 1.2679 - accuracy: 0.5351 - val_loss: 1.1980 - val_accuracy: 0.5661
Epoch 5/18
16/16 [*****] - 54s 3s/step - loss: 1.1923 - accuracy: 0.5702 - val_loss: 1.2340 - val_accuracy: 0.6240
Epoch 6/18
16/16 [*****] - 55s 3s/step - loss: 1.1618 - accuracy: 0.5898 - val_loss: 1.0157 - val_accuracy: 0.6467
Epoch 7/18
16/16 [*****] - 53s 3s/step - loss: 1.0830 - accuracy: 0.6116 - val_loss: 1.0455 - val_accuracy: 0.5558
Epoch 8/18
16/16 [*****] - 52s 3s/step - loss: 1.0743 - accuracy: 0.5987 - val_loss: 1.3422 - val_accuracy: 0.5455
Epoch 9/18
16/16 [*****] - 54s 3s/step - loss: 1.3189 - accuracy: 0.5269 - val_loss: 1.0589 - val_accuracy: 0.6198
Epoch 10/18
16/16 [*****] - 54s 3s/step - loss: 1.0359 - accuracy: 0.6281 - val_loss: 0.9016 - val_accuracy: 0.7066
Epoch 11/18
16/16 [*****] - 54s 3s/step - loss: 0.9017 - accuracy: 0.6983 - val_loss: 0.8084 - val_accuracy: 0.7417
Epoch 12/18
16/16 [*****] - 58s 4s/step - loss: 0.7257 - accuracy: 0.7344 - val_loss: 0.4908 - val_accuracy: 0.7769
Epoch 13/18
16/16 [*****] - 53s 3s/step - loss: 0.7435 - accuracy: 0.7376 - val_loss: 0.7423 - val_accuracy: 0.7459
Epoch 14/18
16/16 [*****] - 54s 3s/step - loss: 0.9894 - accuracy: 0.6591 - val_loss: 0.9189 - val_accuracy: 0.7293
Epoch 15/18
16/16 [*****] - 53s 3s/step - loss: 0.8310 - accuracy: 0.7087 - val_loss: 0.8158 - val_accuracy: 0.7066
Epoch 16/18
16/16 [*****] - 54s 3s/step - loss: 0.7002 - accuracy: 0.7252 - val_loss: 0.6416 - val_accuracy: 0.8347
Epoch 17/18
16/16 [*****] - 53s 3s/step - loss: 0.6681 - accuracy: 0.7541 - val_loss: 0.1826 - val_accuracy: 0.8306
Epoch 18/18
16/16 [*****] - 50s 3s/step - loss: 0.8177 - accuracy: 0.6860 - val_loss: 0.8442 - val_accuracy: 0.7344

```

FIGURE 5.4 – Compilation de Modèle N°01

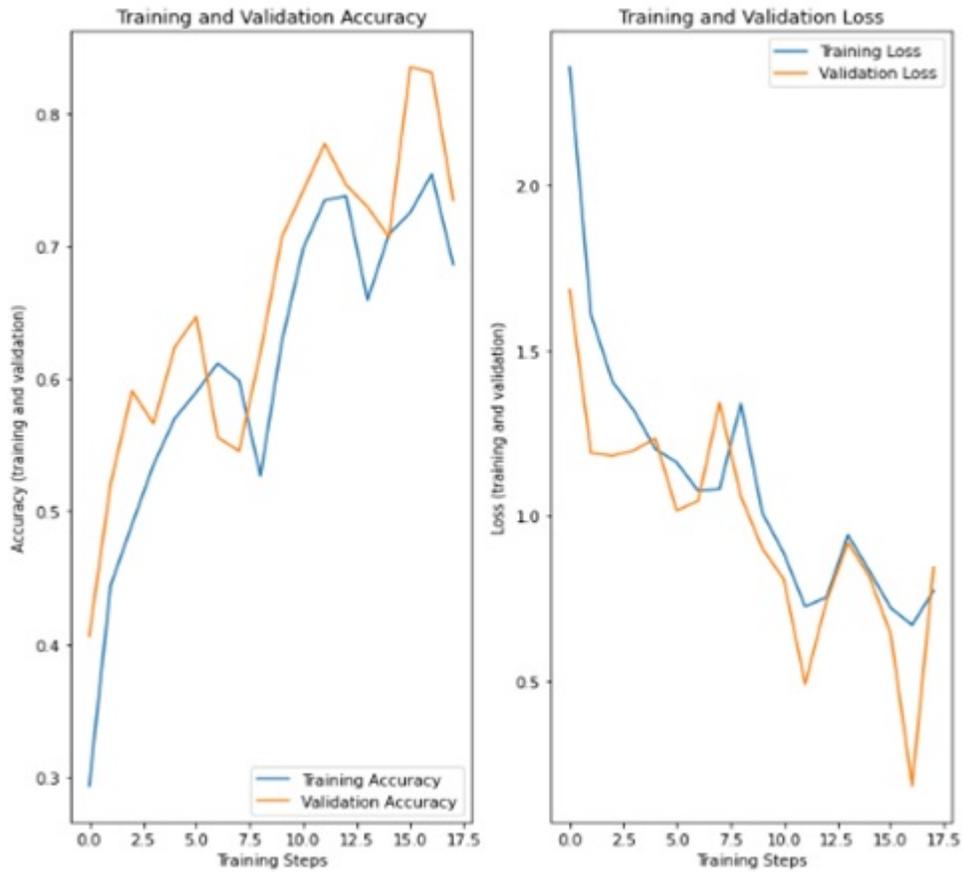


FIGURE 5.5 – Compilation de Modèle N°01

### 5.3.2 Model 02 :

Sur le premier graphique (voir la figure fig.5.7) représente les résultats obtenu avec (batch size =32), on peut voir que la haute précision de 96.28% est atteinte après 17 époques et continu à s'améliorer(voir la figure 5.6).

```

Epoch 1/18
16/16 [#####] - 56s 4s/step - loss: 1.5082 - accuracy: 0.5227 - val_loss: 1.1485 - val_accuracy: 0.5723
Epoch 2/18
16/16 [#####] - 61s 4s/step - loss: 1.0704 - accuracy: 0.6426 - val_loss: 0.7594 - val_accuracy: 0.6839
Epoch 3/18
16/16 [#####] - 54s 3s/step - loss: 0.8255 - accuracy: 0.7149 - val_loss: 0.6912 - val_accuracy: 0.7169
Epoch 4/18
16/16 [#####] - 56s 3s/step - loss: 0.7147 - accuracy: 0.7417 - val_loss: 0.5355 - val_accuracy: 0.7645
Epoch 5/18
16/16 [#####] - 56s 3s/step - loss: 0.5375 - accuracy: 0.8244 - val_loss: 0.3284 - val_accuracy: 0.8512
Epoch 6/18
16/16 [#####] - 57s 4s/step - loss: 0.5634 - accuracy: 0.8027 - val_loss: 1.0228 - val_accuracy: 0.7810
Epoch 7/18
16/16 [#####] - 54s 3s/step - loss: 0.7255 - accuracy: 0.7083 - val_loss: 0.4308 - val_accuracy: 0.8492
Epoch 8/18
16/16 [#####] - 55s 3s/step - loss: 0.4954 - accuracy: 0.8409 - val_loss: 0.6868 - val_accuracy: 0.8905
Epoch 9/18
16/16 [#####] - 55s 3s/step - loss: 0.4958 - accuracy: 0.8368 - val_loss: 0.6078 - val_accuracy: 0.8698
Epoch 10/18
16/16 [#####] - 55s 3s/step - loss: 0.8129 - accuracy: 0.7273 - val_loss: 0.5336 - val_accuracy: 0.7500
Epoch 11/18
16/16 [#####] - 57s 4s/step - loss: 0.6106 - accuracy: 0.7988 - val_loss: 0.5700 - val_accuracy: 0.9050
Epoch 12/18
16/16 [#####] - 55s 3s/step - loss: 0.3957 - accuracy: 0.8760 - val_loss: 0.3081 - val_accuracy: 0.9277
Epoch 13/18
16/16 [#####] - 58s 4s/step - loss: 0.4063 - accuracy: 0.8487 - val_loss: 0.1172 - val_accuracy: 0.9628
Epoch 14/18
16/16 [#####] - 55s 3s/step - loss: 0.2382 - accuracy: 0.9215 - val_loss: 0.2407 - val_accuracy: 0.9442
Epoch 15/18
16/16 [#####] - 57s 4s/step - loss: 0.2599 - accuracy: 0.9160 - val_loss: 0.0461 - val_accuracy: 0.9607
Epoch 16/18
16/16 [#####] - 53s 3s/step - loss: 0.2074 - accuracy: 0.9167 - val_loss: 0.1348 - val_accuracy: 0.9545
Epoch 17/18
16/16 [#####] - 57s 4s/step - loss: 0.2430 - accuracy: 0.9004 - val_loss: 0.2061 - val_accuracy: 0.9628
Epoch 18/18
16/16 [#####] - 51s 3s/step - loss: 0.2590 - accuracy: 0.9236 - val_loss: 0.2184 - val_accuracy: 0.9531

```

FIGURE 5.6 – Compilation de Modèle N°02 avec (batch size=32)

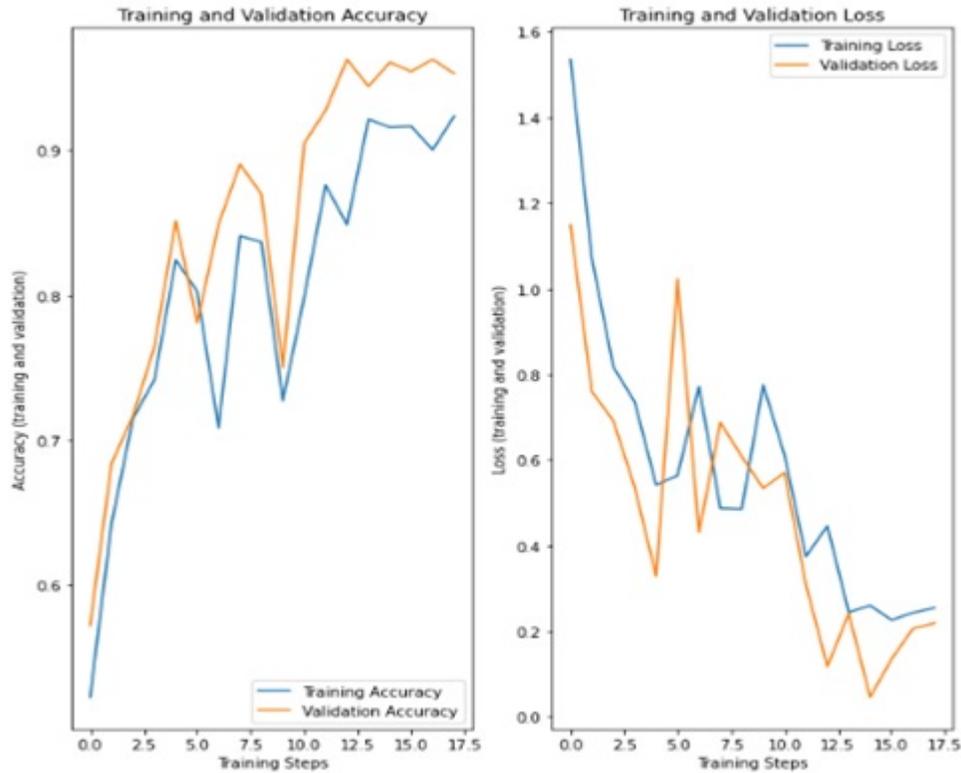


FIGURE 5.7 – Compilation de Modèle N°02 avec (batch size=32)

Le deuxième graphique illustrer dans la figure 5.9 de même modèle N°02 montre la précision avec un batch size=24.on peut remarquer la meilleur précision de 99.34% est atteinte après 19 époques (c'est la meilleur précision entre les trois modèle proposé) mais elle n'est à pas stable et continu avec certaine perturbation (voir la figure 5.8).

```

[ ] Epoch 7/28
19/19 [=====] - 52s 3s/step - loss: 0.2911 - accuracy: 0.9013 - val_loss: 0.1274 - val_accuracy: 0.9292
Epoch 8/28
[ ] Epoch 8/28
19/19 [=====] - 52s 3s/step - loss: 0.2968 - accuracy: 0.9181 - val_loss: 0.1597 - val_accuracy: 0.8850
Epoch 9/28
19/19 [=====] - 51s 3s/step - loss: 0.2406 - accuracy: 0.9286 - val_loss: 0.1758 - val_accuracy: 0.9248
Epoch 10/28
19/19 [=====] - 52s 3s/step - loss: 0.2353 - accuracy: 0.9254 - val_loss: 0.1068 - val_accuracy: 0.9181
Epoch 11/28
19/19 [=====] - 51s 3s/step - loss: 0.2172 - accuracy: 0.9159 - val_loss: 0.2849 - val_accuracy: 0.9469
Epoch 12/28
19/19 [=====] - 51s 3s/step - loss: 0.1660 - accuracy: 0.9420 - val_loss: 0.0346 - val_accuracy: 0.9381
Epoch 13/28
19/19 [=====] - 54s 3s/step - loss: 0.2635 - accuracy: 0.9137 - val_loss: 0.0424 - val_accuracy: 0.9712
Epoch 14/28
19/19 [=====] - 51s 3s/step - loss: 0.1441 - accuracy: 0.9561 - val_loss: 0.2978 - val_accuracy: 0.9801
Epoch 15/28
19/19 [=====] - 51s 3s/step - loss: 0.2361 - accuracy: 0.9115 - val_loss: 0.0733 - val_accuracy: 0.9602
Epoch 16/28
19/19 [=====] - 53s 3s/step - loss: 0.2197 - accuracy: 0.9330 - val_loss: 0.2364 - val_accuracy: 0.9248
Epoch 17/28
19/19 [=====] - 52s 3s/step - loss: 0.1271 - accuracy: 0.9605 - val_loss: 0.0095 - val_accuracy: 0.9845
Epoch 18/28
19/19 [=====] - 51s 3s/step - loss: 0.0795 - accuracy: 0.9777 - val_loss: 0.0277 - val_accuracy: 0.9823
Epoch 19/28
19/19 [=====] - 52s 3s/step - loss: 0.0927 - accuracy: 0.9693 - val_loss: 0.0031 - val_accuracy: 0.9757
Epoch 20/28
19/19 [=====] - 51s 3s/step - loss: 0.1102 - accuracy: 0.9668 - val_loss: 0.3351 - val_accuracy: 0.9425
Epoch 21/28
19/19 [=====] - 48s 3s/step - loss: 0.1686 - accuracy: 0.9425 - val_loss: 0.1292 - val_accuracy: 0.9539
Epoch 22/28
19/19 [=====] - 52s 3s/step - loss: 0.1258 - accuracy: 0.9580 - val_loss: 0.1139 - val_accuracy: 0.9801
Epoch 23/28
19/19 [=====] - 51s 3s/step - loss: 0.0896 - accuracy: 0.9668 - val_loss: 0.0149 - val_accuracy: 0.9823
Epoch 24/28
19/19 [=====] - 51s 3s/step - loss: 0.0977 - accuracy: 0.9668 - val_loss: 0.0264 - val_accuracy: 0.9934
Epoch 25/28
19/19 [=====] - 52s 3s/step - loss: 0.0939 - accuracy: 0.9671 - val_loss: 0.0147 - val_accuracy: 0.9535
Epoch 26/28
19/19 [=====] - 51s 3s/step - loss: 0.1151 - accuracy: 0.9643 - val_loss: 0.0059 - val_accuracy: 0.9912
Epoch 27/28
19/19 [=====] - 51s 3s/step - loss: 0.1704 - accuracy: 0.9336 - val_loss: 0.0207 - val_accuracy: 0.9845
Epoch 28/28
19/19 [=====] - 54s 3s/step - loss: 0.0792 - accuracy: 0.9801 - val_loss: 0.0119 - val_accuracy: 0.9889

```

FIGURE 5.8 – Compilation de Modèle N°02 avec (batch size=24)

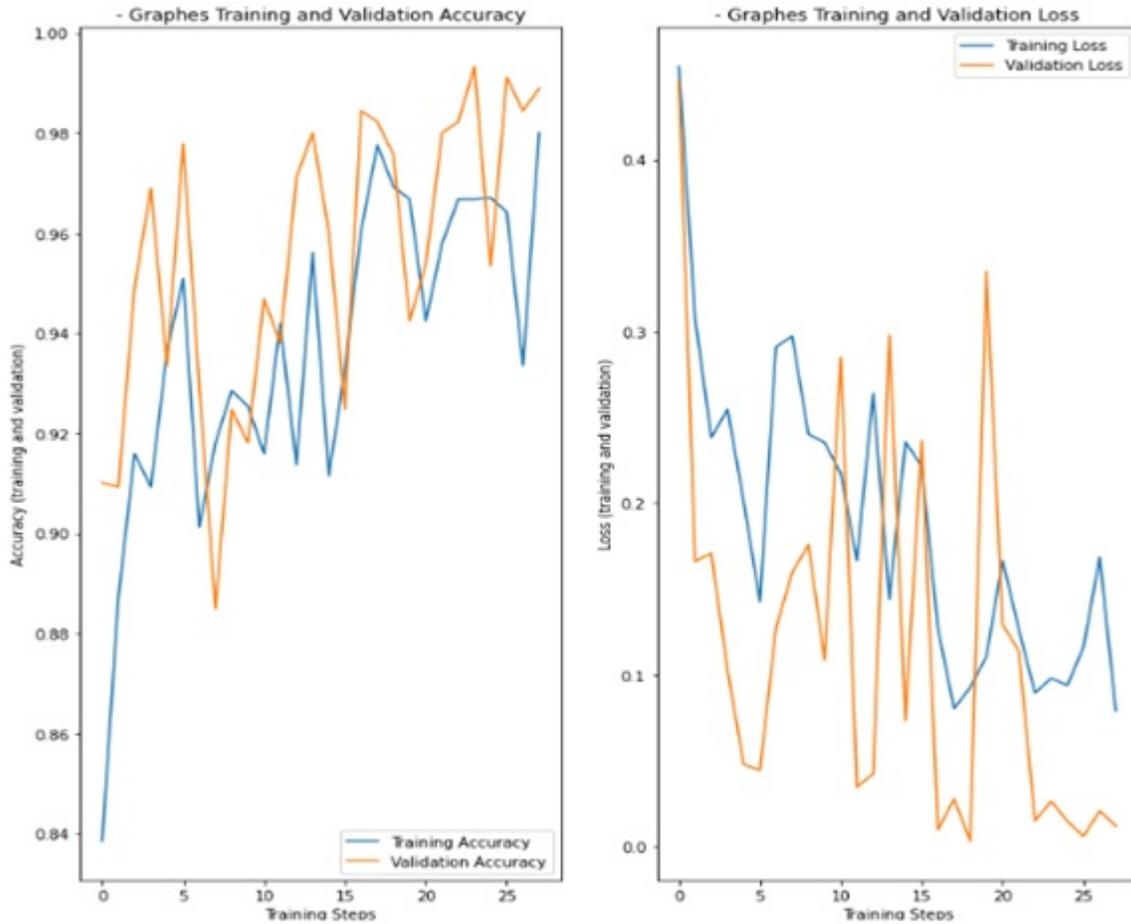


FIGURE 5.9 – Compilation de Modèle N°02 avec (batch size=24)

### 5.3.3 Model 03 :

Sur le premier graphique (voir la figure fig.5.11) qu'il représente les précisions des données de d'entraînement et de validation avec (batch size=32), on peut voir que la haute précision de 95.45% est atteinte après 17 époques. Dans les époques suivantes sur la parcelle, la précision ne s'améliore pas et diminue même après la 17 époques (voir la figure fig.5.10).

```

Epoch 1/18
16/16 [*****] - 147s 9s/step - loss: 1.5912 - accuracy: 0.5351 - val_loss: 1.0132 - val_accuracy: 0.7305
Epoch 2/18
16/16 [*****] - 146s 9s/step - loss: 0.9230 - accuracy: 0.7087 - val_loss: 0.6434 - val_accuracy: 0.7500
Epoch 3/18
16/16 [*****] - 144s 9s/step - loss: 0.8392 - accuracy: 0.6860 - val_loss: 0.7000 - val_accuracy: 0.8760
Epoch 4/18
16/16 [*****] - 151s 9s/step - loss: 0.6240 - accuracy: 0.7793 - val_loss: 0.4842 - val_accuracy: 0.7748
Epoch 5/18
16/16 [*****] - 145s 9s/step - loss: 0.4976 - accuracy: 0.8223 - val_loss: 0.4182 - val_accuracy: 0.8822
Epoch 6/18
16/16 [*****] - 141s 9s/step - loss: 0.6327 - accuracy: 0.8202 - val_loss: 0.5870 - val_accuracy: 0.8223
Epoch 7/18
16/16 [*****] - 151s 9s/step - loss: 0.8181 - accuracy: 0.7363 - val_loss: 0.5011 - val_accuracy: 0.7727
Epoch 8/18
16/16 [*****] - 145s 9s/step - loss: 0.6095 - accuracy: 0.7975 - val_loss: 0.2306 - val_accuracy: 0.8946
Epoch 9/18
16/16 [*****] - 140s 9s/step - loss: 0.4362 - accuracy: 0.8662 - val_loss: 0.4931 - val_accuracy: 0.8905
Epoch 10/18
16/16 [*****] - 144s 9s/step - loss: 0.5518 - accuracy: 0.8264 - val_loss: 0.3207 - val_accuracy: 0.8595
Epoch 11/18
16/16 [*****] - 150s 9s/step - loss: 0.3901 - accuracy: 0.8711 - val_loss: 0.1258 - val_accuracy: 0.9318
Epoch 12/18
16/16 [*****] - 144s 9s/step - loss: 0.4012 - accuracy: 0.8822 - val_loss: 0.1473 - val_accuracy: 0.9298
Epoch 13/18
16/16 [*****] - 144s 9s/step - loss: 0.3450 - accuracy: 0.8760 - val_loss: 0.2032 - val_accuracy: 0.9091
Epoch 14/18
16/16 [*****] - 139s 9s/step - loss: 0.3941 - accuracy: 0.8531 - val_loss: 0.1585 - val_accuracy: 0.9256
Epoch 15/18
16/16 [*****] - 149s 9s/step - loss: 0.3635 - accuracy: 0.8750 - val_loss: 0.0943 - val_accuracy: 0.9463
Epoch 16/18
16/16 [*****] - 144s 9s/step - loss: 0.4469 - accuracy: 0.8595 - val_loss: 0.3134 - val_accuracy: 0.8120
Epoch 17/18
16/16 [*****] - 143s 9s/step - loss: 0.4321 - accuracy: 0.8574 - val_loss: 0.2933 - val_accuracy: 0.9545
Epoch 18/18
16/16 [*****] - 142s 9s/step - loss: 0.2873 - accuracy: 0.8967 - val_loss: 0.1421 - val_accuracy: 0.9395

```

FIGURE 5.10 – Compilation de Modèle N°03

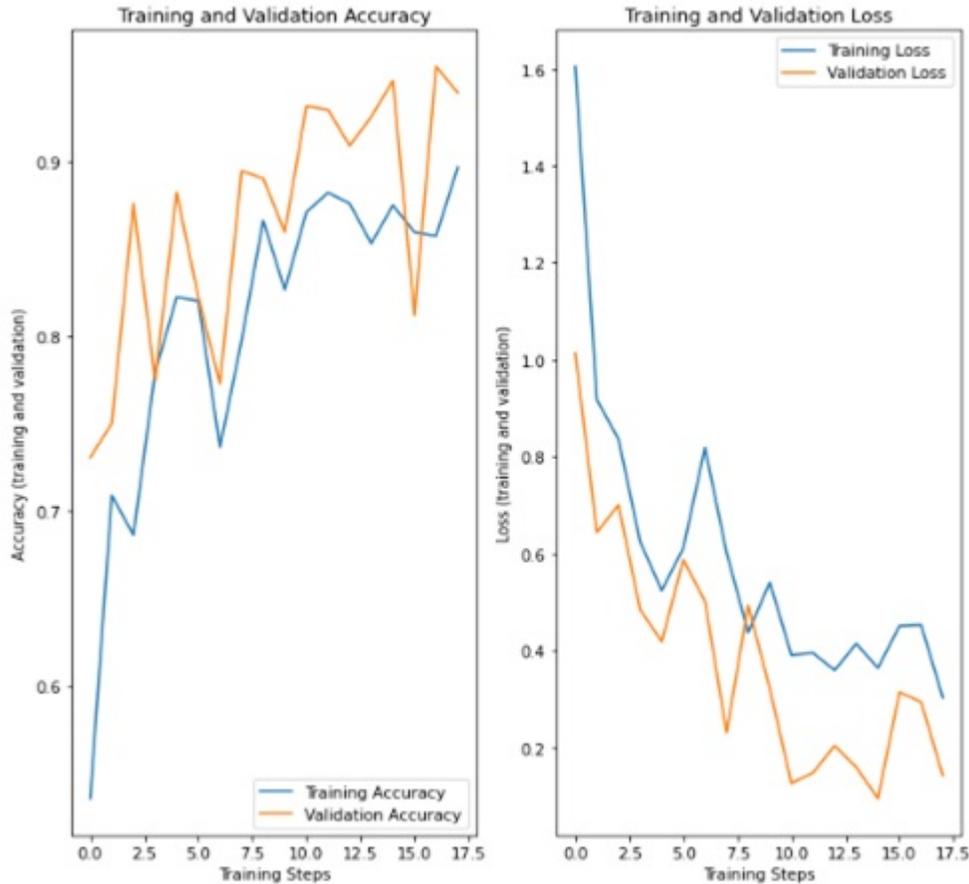


FIGURE 5.11 – Compilation de Modèle N°03

Nous obtenons des performances de classification entre 73% avec le premier modèle et plus 98% avec le deuxième modèle. On atteint à cette précision avec 467 images d'échantillons parmi l'ensemble des données d'entraînement répartie en 10 classes des maladies traitées .

Il est donc possible d'entraîner un classifieur performant avec peu d'images. À noter qu'il est possible de mettre en œuvre des techniques d'augmentation du jeu d'entraînement s'il est vraiment trop réduit. Il s'agit de créer des variations d'une même image par de légères transformations : rotation, zoom...

Notre travail aussi consiste à améliorer la précision (Acc) et au même temps avec des performances de traitement assez rapide, Savoir que la précision de la validation (Acc) permet au modèle de se généraliser à de nouvelles données.

### 5.3.4 Etats de sortie de système (phase de prédiction) :

Une fois notre modèle est valide et prêt d'être exécuté au niveau de cloud on peut recevoir des images afin d'obtenir en sortie de système le rapport de prédiction de l'image entrée (voir la figure fig.5.12) ,et la figure fig.5.13 représenter un ensemble des images de teste classifiées par notre système voici des quelques exemple :

```
=====
Bienvenu : SMART FARM ML Model Prêt
=====
-Résultat du Prédiction pour l'image reçu :
=====
Feuille sain : Tomato__healthy
** Bonne Courage **
```



FIGURE 5.12 – Exemple d'un rapport de prédiction.

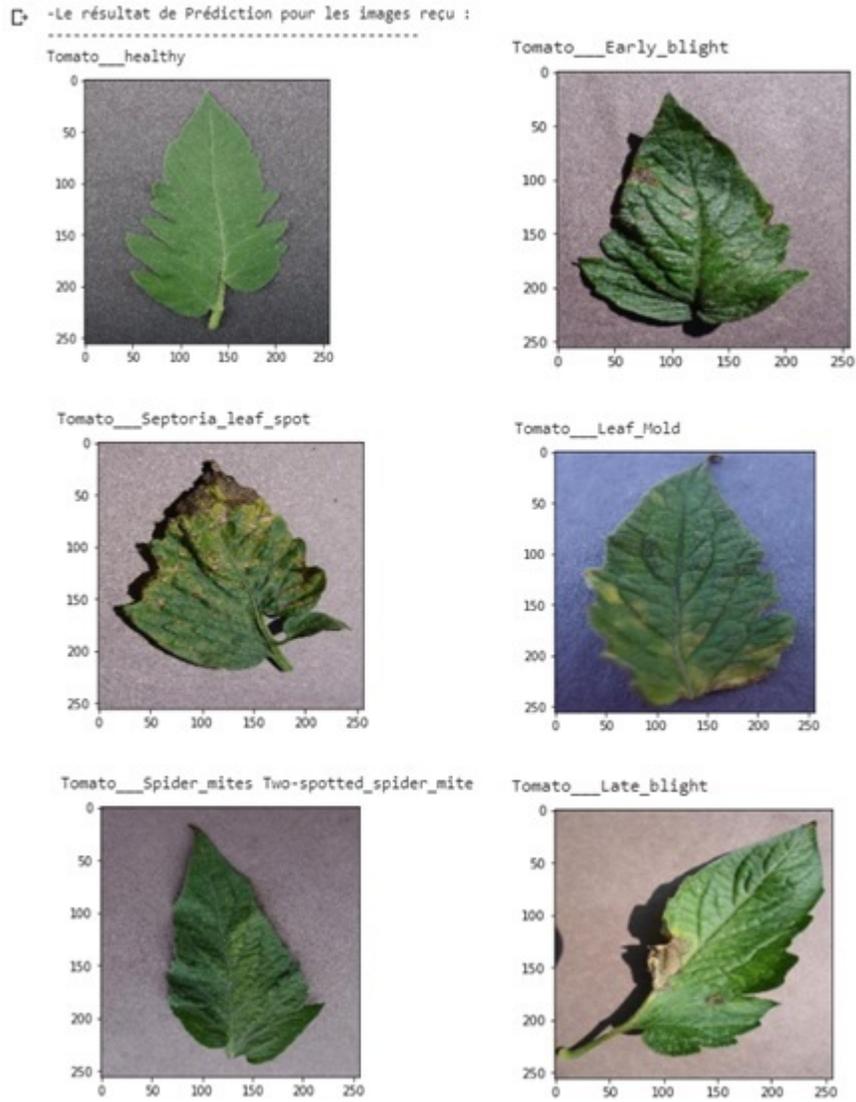


FIGURE 5.13 – Exemples des images de teste classifier.

### 5.3.5 Comparaison des résultats obtenu :

Le tableau ci-dessous résume les différents résultats obtenus sur les trois modèles proposer :

TABLE 5.2 – Tableau comparative des trois modèles

Modèle	Description	Batch Size	Précision sur Train Base	Précision sur validation Base	Erreur	Temps d'exécution
<b>Modèle N°01</b>	-C. Conv. : 04 -C. Pool : 04 -C. Fully C. :03	32	68.60%	73.44%	0.84%	1494 s ( 24.9 m)
<b>Modèle N°02</b>	-C. Conv. : 03 -C. Pool : 03 - C. Fully C. :03	32 24	92.36% 98.01%	95.31% 98.89%	0.21% 0.01%	1645 s ( 28 m) 2155 s (36 m)
<b>Modèle N°03</b>	-C. Conv. : 04 -C. Pool : 02 -C. Fully C. :03	32	89.67%	93.95%	0.14%	1575 s ( 26.5 m)

Le tableau montre l'architecture utilisée dans chaque modèle ainsi que le nombre d'époque. Les résultats obtenus sont exprimés en termes de précision d'apprentissage, de validation, de test et erreur et enfin de temps d'exécution. Le temps d'exécution est trop couteux. Ceci revient à la grande dimension de la base ce qui nécessite l'utilisation d'un GPU simultanément avec un CPU. Le modèle N°02 a présenté les meilleurs résultats trouvés. Le nombre d'époque et de couches de convolution reflètent ces bons résultats, cependant le temps d'exécution était très couteux (à cause du nombre d'époque).

Grâce au test du modèle N° 02 comme meilleur modèle , j'ai obtenu une très bonne précision de plus de 95% des échantillons de classification correcte après 17 époques. Le seul inconvénient était que j'ai dû attendre plus de 25 minutes jusqu'à la fin de 17 époques (en regardant le fait que j'avais un très petit nombre de photos pour la formation). À ce sujet, la question se pose , si je pouvais obtenir des résultats meilleurs que ca en moins d'époques et avec plus d'images de formation? Mais cela sa demande quelque heurs de traitement avec une station de travail per-

formant et doter d'un GPU. D'une manière générale, Les résultats obtenus se sont améliorés à mesure que nous avons augmenté le nombre d'époque. La base d'apprentissage est également un élément déterminant dans les réseaux de neurones convolutionnels, il faut avoir une base d'apprentissage de grande taille pour aboutir à des meilleurs résultats. Dans le tableau suivant on présente une étude comparative entre les résultats obtenus par notre travail réalisé et cela de Keke Zhang [28].

TABLE 5.3 – Tableau Comparatif des Travaux

<b>Etude</b>	<b>Récolte</b>	<b>Méthode utilisée</b>	<b>Nbr D'Echantillons (DATASET)</b>	<b>Précision</b>	<b>Nbr Maladies Traiter</b>
Keke Zhang [28].	La Tomate	CNN	5550	95%	8
Notre Travail	La Tomate	CNN	16000	98 %	9

Nous avons obtenu des meilleurs résultats (en précision et temps de réponse) par rapport à ce travail [28] en utilisant une base d'images plus grande nombre des échantillons et avec des modèles différentes de CNN.

## **5.4 Conclusion**

Nous avons présenté dans ce chapitre une approche de classification basée sur les réseaux de neurones convolutif, pour cela on a utilisé trois modèles avec différentes architectures et on a montré les différents résultats obtenus en termes de précision et d'erreur. La comparaison des résultats trouvés a montré que le nombre d'époque, la taille de la base et la profondeur de réseaux, sont des facteurs importants pour l'obtention de meilleurs résultats. D'une manière générale d'entraîner un réseau de neurones convolutif (CNN) c'est un travail compliqué et ça prend beaucoup de temps; et plus les couches se s'empilent, plus le nombre de convolutions et de paramètres à optimiser est élevé. L'ordinateur doit être en mesure de stocker une grande masse de données (Big data) et de faire efficacement les calculs. C'est pour cela les fabricants de matériel informatique multiplient les efforts pour fournir des processeurs graphiques (GPU) performants, capables d'entraîner rapidement un réseau de neurones profond en collaboration avec la CPU; c'est la meilleure solution pour notre travail.

# Chapitre 6

## Conclusion Générale et Perspectives

### 6.1 Conclusion Générale

Dans notre travail, nous avons exposé une approche d'apprentissage automatique afin de classer et détecter automatiquement les maladies des plantes (dans notre exemple c'est bien la tomate) à partir des images des feuilles. Le modèle développé a été en mesure de détecter la présence des maladies et de distinguer entre les feuilles saines et les neuf (09) maladies différentes, qui peuvent être diagnostiquées visuellement. La procédure complète a été décrite, respectivement, du prétraitement des images et à l'augmentation des images et enfin la procédure de l'apprentissage du CNN. Différents tests ont été effectués afin de vérifier les performances des modèles nouvellement créés. Le processus d'augmentation a eu une plus grande influence pour obtenir des résultats respectables. Dans notre travail, les résultats expérimentaux ont montré une précision comprise entre 73% et 98%.

## **6.2 Perspectives**

Nos travaux futurs auront pour objectif de développer un modèle ayant une précision plus de 98%. En outre, ils nous permettront d'assurer un mécanisme fiable pour la réception des images et la transmission des rapports en SMS. Notre objectif final sera d'avoir un modèle générique pour traiter les maladies reconnues dans les fruits, les légumes et d'autres plantes. En plus, notre modèle sera conçu pour les appareils mobiles intelligents afin d'être plus convenable pour sites éloignés, cela sur la base des images de feuilles capturées par les Smartphones. Cette application permettra d'aider les agriculteurs pour un diagnostic rapide et efficace des maladies des plantes, ce qui permet de faciliter le processus décisionnel en matière d'utilisation de pesticides chimique.

# Bibliographie

- [1] Article FAO; "L'agriculture intelligente face au climat", <http://www.fao.org/climate-smart-agriculture/overview/fr/>, consulté le :15/05/2020.
- [2] Le CCAFS publication;" Comment l'agriculture intelligente face au climat améliore-t-elle la vie de millions de personnes à travers le monde" (CCAFS),<https://ccafs.cgiar.org/fr/research-highlight/comment-l%e2%80%99agriculture-intelligente-face-au-climat-am%a9liore-t-elle-la-vie-de.Xj0hJq1YaM8>, consulté le :20/02/2020.
- [3] "Qu'est-ce que l'agriculture intelligente face au climat?" <https://fr.csa.guide/csa/what-is-climate-smart-agriculture>, consulté le :02/03/2020.
- [4] Plaine des Jarres, Laos, THÈSE DOCTORAT, "Evaluation agroécologique de systèmes de culture en zone tropicale humide", (2013), consulté le : 02/04/2020.
- [5] Janusz Wojciechowski, Luc Bas : "Approaches to sustainable agriculture", : <https://portals.iucn.org/library/sites/library/files/documents/2020-017-En.pdf>, INTERNATIONAL UNION FOR CONSERVATION OF NATURE (2020)
- [6] KAZEM SOHRABY, DANIEL MINOLI, TAIEB ZNATI : "WIRELESS SENSOR NETWORKS Technology, Protocols, and Applications"; (2007)
- [7] Per Rudebjer, Boudy van Schagen, Sebastian Chakeredza "Teaching agrobiodiversity : a curriculum guide for higher education". (2011)
- [8] Quang Tran Minh, Trong Nhan Phan, Akihiko Takahashi, "A Cost-effective Smart Farming System with Knowledge Base", Article researchgate (December 2017)

- [9] IoT in Agriculture 5 Applications of IoT in Agriculture - Making Agriculture Smarter :<https://www.biz4intellia.com/blog/5-applications-of-iot-in-agriculture/>, consulté le :07/03/2020.
- [10] Ivo van der Nagel, "Agriculture and the internet of things" : <https://itnext.io/agriculture-is-the-most-essential-form-of-food-production-for-humanity-c43d5621fe23?gi=bee209005a3>, (2016), consulté le :22/03/2020.
- [11] Yacine CHALLA; "Réseaux de capteurs sans fil (RCSF)"; <https://moodle.utc.fr/file.php/498/support-SIT60.pdf>. (2008).
- [12] Survey I.F. Akyildiz, W. Su, Y. Sankarasubramaniam, E. Cayirci "Wireless sensor networks".article researchgate (2002)
- [13] DIDI Faouzi :THÈSE DOCTORAT LMD Spécialité : Energies Renouvelables-"Optimisation de la gestion du microclimat de la serre par l'introduction de l'intelligence artificielle" (2018).
- [14] IoT in Agriculture : "5 Technology Use Cases for Smart Farming (and 4 Challenges to Consider)"; <https://easternpeak.com/blog/iot-in-agriculture-5-technology-use-cases-for-smart-farming-and-4-challenges-to-consider/> ,consulté le : 10/03/2020.
- [15] "A QUOI RESSEMBLERA LA FERME INTELLIGENTE DU FUTUR?"; <http://tractorexport.com/quoi-ressemblera-la-ferme-intelligente-du-futur/> ,consulté le :10/05/2020.
- [16] "How Smart Farming Is Renovating Traditional Farming Methods And Tools?" <https://www.mirrorreview.com/smart-farming-renovating-traditional-farming-methods/> , consulté le :05/03/2020.
- [17] Srdjan Sladojevic, Marko Arsenovic, Andras Anderla, "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification", <https://www.hindawi.com/journals/cin/2016/3289801/>, researchgate, Published 22 Jun 2016.consulté le :05/03/2020.

- [18] S. A. Miller, F. D. Beed, C. L. Harmon, "Plant disease diagnostic capabilities and networks", *Annual Review of Phytopathology*, (2009).
- [19] M. B. Riley, M. R. Williamson, O. Maloy, "Plant disease diagnosis. The Plant Health Instructor", *Article researchgate* (2002).
- [20] T. Van der Zwet, "Present worldwide distribution of fire blight," in *Proceedings of the 9th International Workshop on Fire Blight*, vol. 590, Napier, New Zealand, (Oct. 2001).
- [21] Sharada P. Mohanty, David P. Hughesa Marcel Salathé," Using Deep Learning for Image-Based Plant Disease Detection", <https://www.frontiersin.org/articles/10.3389/fpls.2016.01419/full>
- [22] Sindhuja Sankarana, Ashish Mishraa, Reza Ehsania, Cristina Davisb "A review of advanced techniques for detecting plant diseases" <http://agri.ckcest.cn/ass/NK003-20161121003.pdf>
- [23] Karouche Ikram, and Sarra Bouhenni. "Classification Algorithms for Plant Disease Forecasting." Unpublished, Unpublished, 2017, doi:10.13140/RG.2.2.22515.84009.
- [24] Sotiris Kotsiantis, I. D. Zaharakis, P. E. Pintelas; "Machine learning: A review of classification and combining techniques", *Article in Artificial Intelligence Review*, researchgate (2006)
- [25] Muhammad Shehzad Hanif, Muhammad Bilal; "Competitive residual neural network for image classification", <https://www.sciencedirect.com/sdfe/reader/pii/S2405959519300694/pdf>, *Article ScienceDirect*, (2020).
- [26] José G. M. Esgaríoa b, Renato A. Krohlinga,b,c, José A. Venturad, "Deep Learning for Classification and Severity Estimation of Coffee Leaf Biotic Stress". *Article ScienceDirect* (juill.2019).
- [27] Saiqa Khana, Meera Narvekarb, Anam Ayesha Shaikh c, Hera Ansarid, Nida Ansari "Disorder Detection in Tomato Plant Using Deep Learning". *Article ScienceDirect* (2019).

- [28] Keke Zhang , QiufengWu , Anwang Liu , XiangyanMeng, "Can Deep Learning Identify Tomato Leaf Disease?" ,Article Research .(Sept.2018)
- [29] Jie Hang , Dexiang Zhang , Peng Chen, Jun Zhang and Bing Wang, "Classification of Plant Leaf Diseases Based on Improved Convolutional Neural Network".Article ScienceDirect (sept. 2019).
- [30] Julien Dejasmin, "Etat de l'art sur la classification d'images a grande échelle. Etudier les architectures récentes orant les meilleures préformantes sur la base ImageNet", Article ScienceDirect(2019).
- [31] Abdellatif Chafik ,THÈSE DOCTORAT : "Architecture de réseau de capteurs pour la surveillance de grands systèmes physiques à mobilité cyclique".(2019)
- [32] Stephanie Chan, Vidhatha Reddy, Bridget Myers, "Machine Learning in Dermatology : Current Applications, Opportunities, and Limitations",Article ScienceDirect (2020)
- [33] Valeria Maeda-Gutiérrez , "Comparison of Convolutional Neural Network Architectures for Classification of Tomato Plant Diseases".Article research(Fev 2020)
- [34] Hand, D.J., Till, R.J,David W. Aha "A simple generalisation of the area under the ROC curve for multiple class classification problems". Article researchgate (2001)
- [35] Muhammad Hammad Saleem , Johan Potgieter , and Khalid Mahmood Arif, "Plant Disease Detection and Classification by Deep Learning".Article ScienceDirect (jui.2019).
- [36] Zakariyaa ISMAILI, "Différence entre apprentissage supervisé et non supervisé "; <https://le-datascientist.fr/apprentissage-supervise-vs-non-supervise>, Article DATA SCIENCE (2019) consulté le :01/05/2020.
- [37] Ashish Nandkumar Patil , " Survey on Detection and Classification of Plant Leaf Disease in Agriculture Environment".Article research (Jan. 2017)
- [38] Laingrand Diane, "cours de Traitement d'images", <http://www.i3s.unice.fr/mh/RR/2004/RR-04.05-D.LINGRAND.pdf>. Rapporte de recherche (2004),

- [39] Elise Arnaud, " Informatique visuelle - Vision par ordinateur Prétraitement d'images".(2015), consulté le :04/06/2020.
- [40] PASCAL manasse, Kimia Nadjahi "Classez et segmentez des données visuelles"; <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/4470538-comprenez-comment-un-ordinateur-voit-une-image>,(2020) ,consulté le :12/05/2020.
- [41] Albawi, S., Mohammed, T. A., Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In 2017 International Conference on Engineering and Technology (ICET) (pp. 1-6). IEEE.
- [42] R. Pradeep Kumar Reddy, Dr. C. Nagaraju, I. Rajasekhar Reddy : "CANNY SCALE EDGE DETECTION",[https://www.researchgate.net/publication/319701466\\_Canny\\_Scale\\_Edge\\_Detection](https://www.researchgate.net/publication/319701466_Canny_Scale_Edge_Detection), Article researchgate (jan. 2016)
- [43] "Jupyter Notebook Documentation Release 5.3.1"; [https://jupyter-notebook.readthedocs.io/\\_/downloads/en/5.3.1/pdf/](https://jupyter-notebook.readthedocs.io/_/downloads/en/5.3.1/pdf/),consulté le :06/07/2020.
- [44] Article journal JDN;"Comment importer des données dans les notebooks Google Colaboratory?" <https://www.journaldunet.fr/web-tech/developpement/1441251-comment-importer-des-donnees-dans-les-notebooks-google-colaboratory/> (MAJ 2019),consulté le :16/05/2020.
- [45] " Matplotlib -Tutorialspoint"; [https://www.tutorialspoint.com/matplotlib/matplotlib\\_tutorial.pdf](https://www.tutorialspoint.com/matplotlib/matplotlib_tutorial.pdf) ,consulté le :04/07/2020.
- [46] Ag Tech – "Top des meilleures startups agriculture et big data "; <https://www.lebigdata.fr/ag-tech-top-startups>,Agriculture Tech journal ,(2019)
- [47] Vishesh K. Oza, Zarana C. Parekh, Ami D. Patel "Smart Green House for Home Farming", Article International Journal of Engineering Research Technology (IJERT) (2019).
- [48] Mohammad Woli Ullah, Mohammad Golam Mortuza, Md Humayun Kabir,"Internet of Things Based Smart Greenhouse : Remote Monitoring and Automatic Control" ENVIRONMENT ENERGY and EARTH SCIENCES, Article IEEE.,(Févr. 2016).

- [49] Ravi Kishore Kodali, Vishal Jain and Sumit Karagwal, "IoT based smart greenhouse", Article IEEE (2016).
- [50] Ikram Karouche , Sarra Bouhenni : "Classification algorithms for plant disease forecasting" Article researchgate (2017).
- [51] Néji Aydi, "Maladies de la tomate d'origine fongique" MONASTIR 2/04/2013, consulté le :04/08/2020.
- [52] Deb Wiley , "Watch Out for These 10 Tomato Plant Diseases in Your Garden This Summer", (2020) , <https://www.bhg.com/gardening/vegetable/vegetables/tomato-plant-diseases/> , better homes and gardens magazine, consulté le :04/05/2020.
- [53] Asheesh Kumar Singh , Baskar Ganapathysubramanian, Soumik Sarkar , "Deep Learning for Plant Stress Phenotyping : Trends and Future Perspectives". Article ScienceDirect (2018)
- [54] Pirmin Lemberger, Marc Batty, Médéric Morel, "Intelligence artificielle : Comprendre le Deep et le Machine Learning"; <https://blogs.mediapart.fr/marc-tertre/blog/130318/intelligence-artificielle-comprendre-le-deep-et-le-machine-learning>. (2017), consulté le :22/04/2020.
- [55] Tensorflow guide , <https://www.tensorflow.org/guide/keras?hl=fr>, consulté le :04/07/2020.
- [56] M. MATTHIEU LE GOFF, Thèse DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE; "Techniques d'analyse de contenu appliquées à l'imagerie spatiale", (2017).

# Annexe A

## Annexe

### A.1 Les Symptômes des maladies traités.

Tab.4.2-Les Symptômes des maladies[51][52].

N°	Classe de Maladie	Les Symptômes	Echenillions
01	Corynesporiose Sur Tomate (Tomato Target Spot)	Des petites lésions humides apparaissent à la face supérieure des feuilles ou des tiges.	
02	Virus de la Mosaïque (Tomato Mosaic virus), ToMV	Eclaircissement des nervures suivi d'une marbrure ou d'une mosaïque, les alternances de plages vertes, jaunes;	
03	Feuilles jaunes en cuillère (Tomato yellow leaf curl virus) TYLCV	Les folioles sont de taille réduite, incurvées en forme de cuillère, parfois enroulées	

04	Bactérie spot (Tomato Bacterial spot)	les lésions foliaires sont circulaires et peuvent être entourées d'un halo jaune pâle ou brun foncé à noir et circulaires sur les feuilles et les tiges.	
05	Maladie l'alternariose (Tomato Early blight)	Des taches ont des centres bruns avec des anneaux concentriques et des halos jaunes sur les bords.	
06	Maladie Brûlure tardive (Mildiou) (Tomato Late blight)	Des taches qui commencent au vert pâle, généralement près des bords des pointes du feuillage et deviennent brunes à noir violacé.	
07	Maladie Passalora fulva (Cladosporiose) (Tomato Leaf Mold)	Feuille apparaît en couleur jaune ou vert irrégulier	
08	Tache septorienne (Tomato Septoria leaf spot)	Des taches apparaissent sur les feuilles inférieures avec des marges brun foncé et des centres brun clair à gris.	
09	Tomato healthy	feuilles en bonne santé	

10	Tetranychus spp. Acariose (Tomato Spider mites Two spotted)	Les acariens (mites), qui font partie, comme les insectes, de l'embranchement des arthropodes,	
----	--	--	---