

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche
Scientifique
Université Abderrahmane Mira de Béjaïa
Faculté des Sciences Exactes
Département d'Informatique



Mémoire de fin de cycle

En vue de l'obtention du Diplôme de Master en Informatique

Option : Administration et Sécurité des Réseaux

Présenté par: HEBBACHE Lyna
et : KERRACHE Kanza

Thème

**Classification des maladies des
feuilles de la tomate avec Edge
impulse et Raspberry Pi**

Soutenu le 01/07/2024, devant le jury composé de :

D ^r SADI Mustapha	M.C.B	Président	à l'UAM - Bejaia.
D ^r Yani-Athmane BENNAI	M.C.B	Encadrant	à l'UAM - Bejaia.
D ^r KHENOUS Lachemi	M.C.B	Examineur	à l'UAM - Bejaia.

Année Universitaire 2023 – 2024

Remerciements

Avant tout, nous remercions Dieu, Le Tout-Puissant, qui nous a donné le courage, la volonté et la force pour accomplir ce travail. Nous le remercions de nous avoir éclairé le chemin de la réussite.

Nos remerciements les plus sincères vont à notre encadrant Monsieur Yani-Athmane BENNAI, pour son soutien inestimable, sa disponibilité et ses précieux conseils tout au long de la réalisation de ce projet. Son accompagnement, sa patience et son expertise ont été essentiels à la concrétisation de ce projet. Nous adressons également nos remerciements aux membres du jury, dont les remarques constructives et les recommandations avisées ont permis d'améliorer significativement la qualité scientifique de ce manuscrit.

Nous souhaitons remercier chaleureusement toutes les personnes qui ont contribué, de près ou de loin, à l'élaboration de ce travail. Nos remerciements vont tout particulièrement aux enseignants et au personnel administratif de la Faculté des Sciences exactes de l'Université Abderrahmane-Mira de Bejaia, et plus précisément au département d'Informatique, pour la qualité de leur enseignement et leur dévouement constant à offrir une formation de haute qualité à leurs étudiants.

Nous exprimons également notre reconnaissance à nos familles, pour leur soutien indéfectible, leur patience et leurs encouragements tout au long de cette aventure académique.

Enfin, nos pensées reconnaissantes vont à nos amis et proches, dont l'appui moral et les encouragements ont été une source constante de motivation.

Merci infiniment à toutes et à tous pour votre aide précieuse !

Dédicace

À mes chers parents,

Votre amour inconditionnel et votre soutien sans faille ont été les piliers sur lesquels j'ai construit ma vie et ma carrière. Chaque succès que je rencontre est une manifestation de votre devouemenet et de vos sacrifices. Je vous dédie ce travail avec une profonde gratitude et un amour infini.

À mes chers frères « Aissam et Imed » et sœurs « Lilia et Chaima »,

En tant qu'aînée, j'ai toujours ressenti le désir ardent d'être un modèle pour vous, de vous guider et de vous inspirer dans vos propres quêtes. À travers ce travail, je vous honore et je partage avec vous les fruits de nos liens indéfectibles.

À mon cher fiancé Abdallah SLIMANI,

Ta présence et ton soutien constant ont été la source de réconfort qui m'ont permis de franchir les obstacles. Merci d'être celui qui rend chaque défi plus surmontable!

À mon encadrant Dr Yani-Athmane BENNAI,

Je tiens à exprimer ma profonde gratitude pour votre présence constante, votre patience et votre confiance. Ce projet vous est dédié avec une immense reconnaissance.

À ma chère et unique amie Kahina LAIB

Merci pour ta présence et ton soutien. Je te dédie ce travail avec toute ma gratitude.

HEBBACHE Lyna

Dédicace

Je dédie ce travail à toutes les personnes que j'aime.

À la mémoire de mon père, qui restera à jamais dans mon cœur.

À ma chère mère, pour sa patience, son amour, son soutien et ses sacrifices.

À mes chers frères Alloua, Halim, Meziane, et mon beau-frère Achour, qui n'ont cessé d'être pour moi des exemples de persévérance, de courage et de générosité.

À mon cher fiancé Amir, qui a illuminé chaque étape de ce chemin avec amour et soutien.

À mes chères sœurs Sakina, Rebiha, et ma belle-sœur Ibtissam, avec lesquelles j'ai partagé des moments de joie et de bonheur.

À mon encadrant, pour son soutien et sa patience. Merci pour votre guidance tout au long de ce chemin.

KERRACHE Kanza

Table des matières

Table des matières	ii
Liste des figures	iv
Liste des Tableaux	v
Liste des abréviations et notations	vi
Introduction générale	1
1 Généralités et contexte	3
1.1 Présentation de la culture de la tomate	4
1.1.1 L'importance de la tomate dans l'agriculture algérienne	4
1.1.2 Les enjeux de la protection des cultures de tomate	5
1.2 Maladies courantes affectant les feuilles de tomate	6
1.2.1 Identification des principales maladies	6
1.2.2 Symptômes, causes et facteurs de chaque maladie	8
1.3 Solutions actuelles pour la détection de maladies des feuilles de la tomate	10
1.4 Méthodes modernes de détection des maladies des feuilles de la tomate	12
1.4.1 Aperçu de l'IA et de l'apprentissage automatique	12
1.4.2 Potentiel de l'intelligence Artificielle dans la détection de mala-	
dies de plantes	13
1.5 Objectifs de la solution	15
2 Etat de l'art sur la détection des maladies des feuilles de la tomate	17
2.1 Méthodes embarquées	18
2.2 Méthodes non-embarquées	21
2.3 Critique et discussion	29
3 Solution proposée	31
3.1 Motivation	32
3.2 Qu'est-ce que la vision par ordinateur ?	32
3.2.1 Principe de fonctionnement	33

3.2.2	Les étapes de fonctionnement	33
3.2.3	Applications de la vision par ordinateur	34
3.3	Le traitement d'image	34
3.4	Tiny machine learning	36
3.5	Les éléments de notre solution	39
3.5.1	Raspberry pi	39
3.5.2	Edge impulse	51
3.6	Fonctionnement de la solution	53
4	Mise en oeuvre et réalisation	56
4.1	Création d'un Compte Edge Impulse et Démarrage d'un Nouveau Projet	57
4.2	Collecte de Données (Data acquisition)	58
4.3	Choix d'un modèle d'entraînement	59
4.4	Extraction des caractéristiques	60
4.5	Entraînement des modèles	61
4.6	Test des modèles	64
4.7	Live classification	67
4.8	Déploiement du modèle sur Raspberry Pi	68
	Conclusion générale	75
	Bibliographie	75
	Résumé	83
	Abstract	83

Table des figures

1.1	Feuille de Tomate Affectée par le Mildiou	6
1.2	Feuille de Tomate Affectée par l'Oïdium	7
1.3	Pucerons de la tomate	7
1.4	Mineuse de la tomate	8
1.5	Relation entre l'Intelligence Artificielle et l'Apprentissage Automatique.	13
3.1	Système de vision humaine VS Système de vision par ordinateur. . . .	33
3.2	Exemple d'une image avant et après le traitement	35
3.3	Schéma d'un système TinyML.	37
3.4	Le Raspberry pi 3B+	40
3.5	Le Raspberry pi 1 modèle B	42
3.6	Le Raspberry pi 1 modèle A	42
3.7	Le Raspberry pi 1 modèle B+	42
3.8	Le Raspberry pi 1 modèle A+	43
3.9	Le Raspberry Pi 2 modèle B	44
3.10	Le Raspberry pi Zero W	45
3.11	Raspberry pi Zero WH	45
3.12	Le Raspberry pi 3 modèle A+	46
3.13	Le Raspberry pi 4	47
3.14	Raspberry Pi Pico	48
3.15	Le Raspberry pi 5	49
3.16	Logo d'Edge impulse	52
3.17	Schéma de fonctionnement de la solution.	54
4.1	Vue de l'interface utilisateur de la plateforme Edge Impulse.	57
4.2	Collecte des données d'entraînement et de test	59
4.3	Pré-entraînement du modèle	60
4.4	Graphe représentant l'Exploration des Caractéristiques.	61

4.5	Configuration du Réseau de Neurones.	62
4.6	Matrices de confusion	63
4.7	Résultat de test des modèles	65
4.8	Explorateur de caractéristiques du MobileNetV2 0.35.	66
4.9	Taux de précision	68

Liste des tableaux

1.2.1 Symptômes, causes et facteurs de chaque maladie	10
2.2.1 Tableau récapitulatif	29

Liste des abréviations et notations

AI	Artificial Intelligence
API	Application Programming Interface
CC	Courant Continu
CNN	Convolutional Neural Networks/ Réseaux de neurones convolutifs
CPU	Central Processing Unit
DNN	Deep Neural Networks
DCNN	Deep Convolutional Neural Network
DMRCNN	Deep Multiscale Residual Convolutional Neural Network
DPN	Dual Path Networks
FC-SNDPN	Fully Convolutional Switchable Normalization Dual Path Networks
F-RCNN	Faster Region-based Convolutional Neural Network
GAN	Generative Adversarial Network
GLCM	Gray Level Co-Occurrence Matrix
GPIO	General Purpose Input/Output
HAT	Hardware Attached on Top
HDMI	High-Definition Multimedia Interface
HSV	Hue, Saturation, Value
IoT	Internet of Things
LCD	Liquid Crystal Display
LED	Light Emitting Diode
mAP	mean Average Precision
ML	Machine Learning
OS	Operating System
PBI	Protection Biologique Intégrée / Integrated Biological Protection
PCA	Principal Component Analysis

PoE	P ower- o ver- E thernet
RAM	R andom A ccess M emory
R-CNN	R egion-based C onvolutional N eural N etwork
R-FCN	R egion-based F ully C onvolutional N etwork
RFID	R adio F requency I dentification
SSD	S ingle S hot M ulti B ox D etector
SoC	S ystem o n C hip
SRAM	S tatic R andom A ccess M emory
SVM	S upport V ector M achine
TinyML	T iny M achine L earning/ Apprentissage automatique embarqué
USB	U niversal S erial B us
ViT	V ision T ransformer
Wi-Fi	W ireless F idelity

Introduction générale

La culture de la tomate est d'une importance capitale pour l'agriculture algérienne, contribuant significativement à l'économie et à la sécurité alimentaire du pays. Cependant, cette culture est confrontée à de nombreux défis, notamment les maladies des feuilles, qui peuvent causer des pertes considérables en termes de rendement et de qualité des récoltes. Les méthodes traditionnelles de détection et de gestion de ces maladies, bien qu'efficaces, présentent des limitations telles que le coût élevé, le besoin en expertise spécialisée et le temps nécessaire pour un diagnostic précis.

Avec l'avènement de l'intelligence artificielle (IA), de nouvelles opportunités émergent pour améliorer la détection et la gestion des maladies des cultures. L'IA, en particulier l'apprentissage automatique et la vision par ordinateur, permet une détection rapide, précise et en temps réel des maladies, réduisant ainsi les délais de réponse et les coûts associés.

Notre solution vise à détecter et classifier les maladies des feuilles de tomate en temps réel en utilisant Edge Impulse et Raspberry Pi. Le Raspberry Pi est un micro-ordinateur à faible coût, très populaire dans les applications embarquées, grâce à sa flexibilité et sa facilité d'utilisation. Edge Impulse est une plateforme de développement dédiée à l'apprentissage automatique pour les dispositifs embarqués, permettant de créer, entraîner et déployer des modèles de machine learning de manière simplifiée. Cette approche combine un modèle de classification d'images entraîné sur Edge Impulse, déployé sur une Raspberry Pi équipée d'une caméra, offrant une surveillance continue et autonome des cultures.

En fournissant une solution innovante et accessible pour la détection des maladies des feuilles de tomate, notre travail aspire à soutenir les agriculteurs dans la préservation de leurs récoltes, la réduction des pertes économiques et l'amélioration de leur productivité.

Le mémoire est structuré en quatre chapitres, qui sont repartis de la manière suivante :

1. Le premier chapitre présente la culture de la tomate, son importance dans l'agriculture algérienne et les défis liés à la protection des cultures. Il aborde également les maladies courantes affectant les feuilles de tomate, leurs symptômes, causes et facteurs, ainsi que les solutions actuelles et modernes pour la détection des maladies.

2. Le deuxième chapitre : dans ce chapitre nous procédons à une étude des différentes méthodes de détection des maladies des feuilles de tomate. Nous distinguons les méthodes embarquées des méthodes non-embarquées. Cette revue de la littérature permet de mieux comprendre le paysage actuel de la détection des maladies et les opportunités pour des améliorations futures.

3. Le 3eme chapitre : dans ce chapitre nous allons détailler notre solution de détection des maladies des feuilles de tomates, en utilisant la technologie de l'apprentissage automatique embarqué. Nous allons explorer les choix technologiques tels que la Raspberry Pi et Edge Impulse, soulignant leur importance dans le fonctionnement de notre solution.

4. Le dernier chapitre : dans ce chapitre nous allons entamer le processus de réalisation et les étapes nécessaires pour l'entraînement d'un modèle de la classification d'images en commençant par la collecte des données jusqu'au déploiement dans la Raspberry Pi.

Après la présentation générale du projet, nous terminerons ce manuscrit par une conclusion générale et des perspectives.

Chapitre 1

Généralités et contexte

Introduction

Dans le paysage agricole algérien, la culture de la tomate est importante économiquement et nutritionnellement. Cependant, elle fait face à de nombreux défis, notamment des maladies des feuilles qui réduisent la quantité et la qualité des produits. La détection précoce de ces maladies reste aujourd'hui un défi majeur.

Ce chapitre examine en détail les maladies courantes des feuilles de tomate, leurs symptômes, causes et facteurs. Nous analyserons les solutions de diagnostic actuelles ainsi que leurs limites. Enfin, nous définirons les objectifs de notre solution en explorant comment les technologies modernes, comme l'intelligence artificielle et l'apprentissage automatique, peuvent améliorer la détection des maladies et contribuer à une agriculture durable.

1.1 Présentation de la culture de la tomate

La tomate, également connue sous le nom scientifique de *Solanum lycopersicum*, est un légume largement cultivé à travers le monde pour sa saveur délicieuse et sa polyvalence culinaire. Originnaire d'Amérique du Sud, elle est désormais cultivée dans presque tous les pays, jouant un rôle crucial dans l'agriculture tant sur le plan économique que nutritionnel.

La réussite de la culture de la tomate nécessite des conditions de croissance appropriées, une préparation minutieuse du sol, un arrosage régulier et une surveillance constante pour obtenir des plantes robustes et productives. [1]

1.1.1 L'importance de la tomate dans l'agriculture algérienne

Les autorités algériennes accordent une grande importance à l'agriculture, en particulier à la culture de la tomate. Ce légume occupe une place centrale dans la cuisine locale en raison de sa polyvalence et de son importance nutritionnelle.

La demande croissante de tomates sur le marché, en raison de l'augmentation de la population, incite les agriculteurs à intensifier leurs efforts pour atteindre l'autosuffisance et soutenir l'économie. La tomate est le deuxième produit le plus demandé sur le marché après la pomme de terre [2], en raison de sa valeur nutritive élevée, riche

en minéraux, protéines, glucides, calcium et phosphore.

L'Algérie a réalisé des progrès significatifs dans la production de tomates, se classant parmi les principaux producteurs mondiaux, notamment de tomates industrielles. En 2021, la production de tomates industrielles a dépassé les 23 millions de quintaux, enregistrant une croissance de plus de 17% par rapport à l'année précédente. Cette augmentation a permis à l'Algérie d'atteindre l'autosuffisance en double concentré et triple de tomates.[2]

1.1.2 Les enjeux de la protection des cultures de tomate

La culture de la tomate requiert une vigilance particulière en raison de la sensibilité de la plante à diverses maladies. Pour maximiser le rendement tout en minimisant les risques, plusieurs méthodes de protection sont envisagées :

1. Culture en serre : Cette méthode offre une protection contre les maladies et les changements climatiques.
2. Protection contre les pluies : Les pluies violentes peuvent endommager les cultures de tomates en plein champ et favoriser les infections bactériennes.
3. Sélection de variétés résistantes : Le choix de variétés adaptées aux conditions climatiques telles que la température et le vent est essentiel.
4. Utilisation de serres intelligentes : Les serres équipées de technologies avancées permettent un diagnostic précoce des maladies et une gestion efficace des conditions environnementales.
5. Conservation de la qualité du sol : Des mesures sont prises pour préserver la qualité du sol.
6. Contrôle de la qualité sanitaire de l'eau : Il est essentiel de veiller à la qualité de l'eau utilisée pour l'irrigation.
7. Protection biologique intégrée (PBI) : Cette approche réduit l'utilisation de pesticides en favorisant des méthodes plus durables.
8. Utilisation de semences certifiées : Les semences certifiées de qualité garantissent des résultats optimaux.
9. Intégration de nouvelles technologies : L'utilisation de capteurs, de drones et d'autres technologies permet un diagnostic précis des maladies et une prise de décision automatisée pour une agriculture plus efficace.[3, 4]

1.2 Maladies courantes affectant les feuilles de tomate

Dans cette section, nous abordons la problématique des maladies affectant les feuilles de la tomate. Nous procéderons à l'identification de ces maladies, en exposant leurs symptômes, causes et facteurs associés.

La culture de la tomate est confrontée à d'importants défis, parmi lesquels figurent diverses maladies touchant spécifiquement les feuilles de la tomate. Ces maladies, aux origines variées, engendrent invariablement des dégâts, des échecs de récolte, et des pertes économiques considérables. Il est à noter que plus de 200 maladies, de natures diverses telles que fongiques, virales et bactériennes, ont été recensées, contribuant ainsi à la complexité du problème.[5]

1.2.1 Identification des principales maladies

Les maladies courantes touchant les feuilles de la tomate varient dans leur nature et leurs causes. Parmi celles-ci, on trouve des infections fongiques telles que le Mildiou et l'Oïdium, ainsi que des attaques d'insectes et de bactéries comme les pucerons, les mouches noires, le cul noir et les mineuses de la tomate. Chacune de ces maladies présente des symptômes distincts, ce qui permet un diagnostic précis et la mise en place de traitements appropriés.

1. Le Mildiou, causé par un champignon, est redoutable en raison de sa capacité à causer des dégâts importants, surtout dans les zones chaudes et humides pendant les étés pluvieux.



FIGURE 1.1 – Feuille de Tomate Affectée par le Mildiou

2. L'Oïdium, autre maladie fongique, prospère dans des conditions d'humidité et de fraîcheur, et ses symptômes sont souvent visibles au printemps et en fin d'été.



FIGURE 1.2 – Feuille de Tomate Affectée par l'Oïdium

3. Les pucerons, insectes piqueurs, affaiblissent les plantes en se nourrissant de leur sève, tandis que les mouches blanches se posent sur les feuilles pour se nourrir et pondre leurs œufs.



FIGURE 1.3 – Pucerons de la tomate

4. La mineuse de la tomate, un papillon gris, pond ses œufs sur les feuilles et les tiges de fruits, principalement en été.[6].



FIGURE 1.4 – Mineuse de la tomate

La reconnaissance des symptômes spécifiques de chaque maladie facilite le diagnostic et permet d'appliquer les traitements appropriés.

1.2.2 Symptômes, causes et facteurs de chaque maladie

La plante de tomate est réputée pour sa fragilité et sa sensibilité, la rendant sujette à des infections rapides par diverses maladies d'origines variées, notamment causées par des changements climatiques, des bactéries et des virus. Les principaux facteurs favorisant l'infection des feuilles de la tomate sont généralement liés au climat, tels que des pluies intenses, des températures élevées ou basses, et des vents. De plus, le sol, la qualité de l'eau, ainsi que la propagation à travers d'autres plantes présentes dans l'environnement contribuent également à ces infections.

Dans le tableau suivant, nous énumérerons les maladies affectant les feuilles de la tomate, décrivant leurs symptômes, leurs causes et les facteurs qui y sont associés : [7, 8]

Maladies	Symptômes	Causes et Facteurs
Mildiou	-Tâches huileuses puis jaunes sur les feuilles	Facteurs climatiques. Causes : humidité et courant d'air.
Oïdium	-Tâches jaunes à brun clair sur les feuilles. -Présence d'un feutrage blanc à la face inférieure des feuilles. -Dessèchement des feuilles. -Odeur et champignons.	Facteurs climatiques. Causes : Vent sur les zones à courant d'air. Contamination à partir d'autres plantes de l'entourage.
Pucerons	-Affaiblissement de la plante, jaunissement et déformation, enroulement et crispation des feuilles. -Champignons Noirs sur les feuilles.	Facteurs climatiques. Causes : Température élevée et manque de pluie.
Moisissure des feuilles de tomate (Tomato Leaf Mold)	-Taches jaunâtres diffuses sur la surface supérieure des feuilles. -Moisissure brune veloutée sur la surface inférieure. -Feuilles flétries, desséchées et mortes sans tomber. -Lésions noires irrégulières sur les fruits.	-Humidité relative >85%, températures de 22-24°C. -Infection limitée à <12°C, possible jusqu'à 4°C. -Apparition en juin ou juillet. -Cultivation de variétés sans résistance et émergence de nouvelles souches. -Mutation rapide du champignon.
Virus des feuilles jaunes en cuillère (Tomato Yellow Leaf Curl Virus)	-Croissance ralentie, plantes chétives et buissonnantes. -Feuilles enroulées vers le haut, aspect de cuillère. -Jaunissement internervaire, durcissement et parfois coloration violacée des nervures. -Chute des fleurs, fruits peu nombreux et petits.	-Transmission par les aleurodes. -Conditions de haute humidité et fluctuations soudaines de température. -Manque de rotation des cultures pour réduire la pression virale dans les champs.

Mouches blanches	-Affaiblissement et jaunissement des feuilles. -Présence d'une substance collante et des champignons de couleur noire sur les feuilles.	
Mosaïque de la tomate (Tomato Mosaic Virus)	-Ralentissement de la croissance des plantes. -Anomalies de coloration sur les feuilles. -Éclaircissement des nervures et mosaïque en plages vertes ou jaunes avec gaufrage du limbe. -Chute de fleurs. -Fruits de taille réduite et décolorations jaunes, parfois en anneaux.	-Transmission par contact. -Atténué par des températures élevées. -Alignement des plantes favorise la propagation. -Températures élevées. -Humidité élevée. -Stress des plantes.
Mineuse de la tomate	-Piqûres blanches sur le limbe localisé en bordure de foliole. -Galerie sinueuses dans les feuilles. -Pourriture grise secondaire. -Les feuilles tombent.	Facteurs climatiques. Causes : Chaleur et température très élevée.

TABLE

1.2.1 – Symptômes, causes et facteurs de chaque maladie

1.3 Solutions actuelles pour la détection de maladies des feuilles de la tomate

La détection rapide et précise des maladies des plantes, notamment celles affectant les feuilles de la tomate, revêt une importance capitale pour les agriculteurs soucieux de produire des récoltes de qualité et en quantité suffisante. Cette détection permet d'éviter les dommages significatifs pouvant être causés par ces maladies, préservant ainsi la santé des cultures.

Nous nous intéressons ici d'abord aux méthodes traditionnelles, nous aborderons ensuite les solutions basées sur les nouvelles technologies.

Méthodes traditionnelles de diagnostic des maladies des feuilles de la tomate

Pendant longtemps, les maladies des plantes ont été un obstacle significatif à la réussite de la production agricole, impactant à la fois la qualité et la quantité des récoltes. Plusieurs techniques sont employées pour détecter ces maladies, telles que l'analyse chimique des zones infectées de la plante, ainsi que des méthodes traditionnelles et indirectes, notamment des techniques physiques et d'imagerie spectroscopique (visible, infrarouge, imagerie multispectrale), reconnues pour leur précision et leur efficacité dans la détection des maladies des plantes.

Les techniques spectroscopiques et d'imagerie sont considérées comme des méthodes uniques de surveillance des maladies, capables de détecter les symptômes dès leur apparition initial sur les plantes, comme mentionné dans une approche d'apprentissage pour la détection des maladies dans les fermes intelligentes.

D'autres méthodes traditionnelles, utilisées depuis longtemps dans la détection des maladies des feuilles de la tomate, comprennent :

- Prélèvement d'échantillons pour des tests biologiques dans des laboratoires : Une technique nécessitant l'intervention de personnes qualifiées possédant des connaissances spécialisées, mais elle peut également être coûteuse.
- Tests chimiques en remplacement des tests biologiques : une alternative aux tests biologiques.
- Consultations d'experts : le recours à l'avis d'experts dans le domaine pour diagnostiquer les maladies. [9]

Limitations et problèmes associés à ces méthodes

Il est important de noter que les méthodes traditionnelles présentent des limites en termes de diagnostic précis et parfois tardif. Souvent complémentaires, elles nécessitent l'intervention d'experts et la combinaison de plusieurs approches pour obtenir un diagnostic plus précis. Ces méthodes impliquent des efforts considérables, des coûts supplémentaires et mobilisent une main-d'œuvre importante.

Les tests en laboratoire exigent des équipements spécialisés et du personnel qualifié, mais surtout, ils sont chronophages, ce qui permet aux maladies de se propager davantage pendant ce laps de temps. Cette lenteur dans le processus compromet la réactivité nécessaire pour contenir rapidement la propagation des maladies des plantes.

Voici pour résumer les principales limitations liées aux méthodes traditionnelles :

- Limites en termes de diagnostic précis et parfois tardif.
- Requier l'intervention d'experts et la combinaison de multiples approches.
- Implique des efforts considérables et des coûts supplémentaires.
- Mobilise une main-d'œuvre importante.
- Nécessite des équipements spécialisés et du personnel qualifié.
- Les tests en laboratoire prennent beaucoup de temps, ce qui favorise la propagation des maladies. [10]

1.4 Méthodes modernes de détection des maladies des feuilles de la tomate

1.4.1 Aperçu de l'IA et de l'apprentissage automatique

L'intelligence artificielle est un domaine de l'informatique qui vise à simuler des comportements intelligents humains. Son émergence remonte aux années 50 et englobe un large éventail de techniques et de méthodes permettant aux machines de traiter des informations et de prendre des décisions. Les fondateurs de l'IA, John McCarthy et Marvin Minsky de l'université de Dartmouth, ont introduit ce concept en 1956 pour désigner un système capable d'apprendre, de s'adapter et de raisonner, imitant délibérément le processus de décision humain. [11]

L'apprentissage automatique quant à lui est une branche de l'IA, se concentre sur la construction de systèmes capables d'apprendre et d'améliorer leur performance sans être explicitement programmés. Il repose sur des algorithmes et des modèles mathématiques pour analyser des données, détecter des schémas et des relations, et effectuer des prédictions ou des conclusions à partir de ces données. [12]

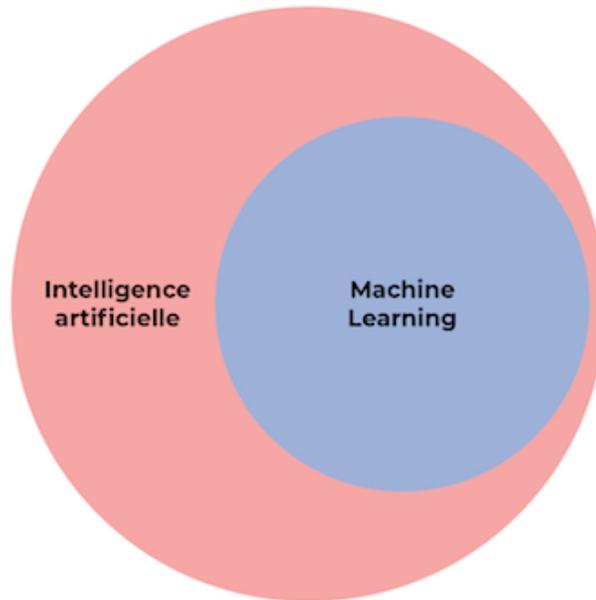


FIGURE 1.5 – Relation entre l'Intelligence Artificielle et l'Apprentissage Automatique.

Dans l'apprentissage automatique, les machines sont entraînées à partir de données pour apprendre à reconnaître des schémas spécifiques. Par exemple, pour classer des images de plantes de tomate et de plantes indésirables, les algorithmes d'apprentissage automatique peuvent être alimentés avec des milliers d'images préalablement étiquetées pour leur apprendre les caractéristiques distinctives de chaque plante. Une fois ces caractéristiques apprises, ils peuvent être utilisés pour classer de nouvelles images.

Il existe différentes approches d'apprentissage automatique, telles que l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. [9]

1.4.2 Potentiel de l'intelligence Artificielle dans la détection de maladies de plantes

Durant les dernières années, l'IA s'est révélée être un outil indispensable dans la détection des maladies des plantes, offrant aux agriculteurs un moyen puissant de gérer leurs cultures de manière plus efficace. Le deep learning, une branche de l'IA, est largement exploré dans le domaine de l'agriculture et ouvre de nouvelles perspectives pour relever les défis liés à la vie végétale. Il promet des solutions pour

surveiller avec précision et prévoir l'évolution des facteurs de production tels que le rendement et l'apparition de maladies ou de ravageurs.

L'IA peut utiliser des techniques d'apprentissage automatique et de traitement de l'image pour analyser de grandes quantités de données et accomplir des tâches spécifiques. Dans le domaine de la détection des maladies des plantes, l'IA offre plusieurs avantages significatifs. Tout d'abord, elle permet une détection précoce des maladies, facilitant ainsi une intervention rapide et ciblée pour arrêter la propagation de l'infection. Deuxièmement, elle peut identifier avec précision le type de maladie et recommander le traitement approprié. Enfin, elle offre la possibilité de surveiller en continu les cultures, fournissant une méthode efficace pour prévenir les épidémies et réduire les pertes. [13, 14].

Un exemple concret de l'utilisation de l'IA dans la détection des maladies des plantes réside dans l'exploitation des réseaux de neurones convolutifs (CNN) pour analyser des images de plantes infectées. Ces CNN apprennent à détecter et classifier automatiquement les symptômes caractéristiques des maladies des plantes en se basant sur une base de données d'images préalablement annotées. Une fois le modèle formé, il peut être déployé pour analyser rapidement de nouvelles images de plantes et détecter toute indication de maladie.

Un autre domaine où l'IA peut jouer un rôle crucial est la surveillance à distance des cultures à l'aide de drones équipés de caméras haute résolution. Les images capturées par ces drones peuvent être analysées à l'aide de techniques d'apprentissage automatique pour détecter les signes précoces de maladies ou de carences nutritionnelles chez les plantes. Les recommandations de traitement peuvent alors être transmises aux agriculteurs, leur permettant de prendre des mesures immédiates pour protéger leurs cultures.[4]

Le potentiel de l'IA dans la détection des maladies des plantes est donc considérable. Grâce à l'utilisation de techniques d'apprentissage automatique et de traitement de l'image, l'IA permet une détection précise des maladies, offrant ainsi aux agriculteurs la possibilité d'intervenir rapidement pour minimiser les pertes. De plus, l'IA peut contribuer à la surveillance continue des cultures grâce à l'utilisation de drones, facilitant ainsi une gestion efficace des cultures et la prévention des épidémies. En tant qu'outil informatique puissant, l'IA révolutionne l'agriculture en proposant des solutions technologiques innovantes pour lutter contre les maladies des plantes.

L'Internet des objets et notre solution

Notre solution s'inscrit dans le cadre de l'IoT dans le sens où la détection de maladies se fait par un objet intelligent et connecté, une fois la maladie détectée, cet objet peut envoyer un signal vers un serveur central par exemple, pour stocker le diagnostic et la position de la plante malade, ou bien pour demander plus d'informations.

1.5 Objectifs de la solution

Notre objectif est de développer une solution rapide pour détecter en temps réel les maladies des feuilles de tomate. Cela permet aux agriculteurs d'intervenir immédiatement pour protéger leurs cultures avant que les infections ne se propagent et n'affectent la récolte.

Nous voulons créer une solution :

- Accessible à tous
- Simple à utiliser
- Ne nécessitant pas l'intervention d'experts

Ainsi, les agriculteurs peuvent facilement intégrer cet outil dans leur routine quotidienne.

En développant un système de classification efficace pour les maladies des feuilles de tomate, nous visons à fournir aux agriculteurs un moyen pratique de :

- Diagnostiquer rapidement les problèmes de santé des cultures
- Traiter immédiatement et sur place les maladies identifiées

Cette approche aide à préserver :

- Le rendement des récoltes et la qualité des produits agricoles

Cette solution peut aussi avoir un impact significatif sur l'économie agricole en :

- Réduisant les pertes de récolte et en améliorant la productivité

Conclusion

Dans ce chapitre, nous avons identifié les limites des méthodes traditionnelles de diagnostic des maladies des feuilles de tomate et mis en lumière le potentiel des

technologies modernes, telles que l'IA et l'apprentissage automatique dans l'amélioration de la détection précoce des maladies des feuilles de tomate. Notre objectif est de développer une solution innovante et efficace pour la détection de ces maladies.

Dans le prochain chapitre, nous présentons un état de l'art sur les solutions existantes pour la détection des maladies des feuilles de tomate.

Chapitre 2

Etat de l'art sur la détection des
maladies des feuilles de la tomate

Introduction

La détection précoce et précise des maladies affectant les feuilles de tomate revêt une importance cruciale pour assurer la santé des cultures et garantir de bons rendements. Face à ce défi, de nombreuses recherches ont été menées pour développer des méthodes de détection automatisées et efficaces, exploitant notamment les avancées en intelligence artificielle, et plus précisément en traitement d'images. Dans cette perspective, ce chapitre présenté sous forme d'état de l'art vise à explorer les principales différentes approches existantes pour la détection des maladies des feuilles de tomate et à identifier les opportunités d'amélioration, en vue de proposer une nouvelle solution.

2.1 Méthodes embarquées

Dans [15], les auteurs présentent une méthode utilisant l'apprentissage profond (Deep Learning) pour détecter les maladies des feuilles de tomates. Cette approche repose plus spécifiquement sur l'utilisation de réseaux neuronaux profonds (DNN, Deep Neural Networks) pour identifier différents types de maladies, avec pour objectif d'intégrer cette méthode dans un système opérant en temps réel sur un robot. Les maladies sont repérées en observant les altérations physiques des feuilles, détectables grâce à des caméras RVB (Rouge, Vert, Bleu).

Deux architectures de réseau, AlexNet et SqueezeNet, ont été testées pour cette tâche, avec entraînement et validation réalisés sur un NvidiaJetson TX1 à partir d'images de feuilles de tomates de l'ensemble de données (Dataset) PlantVillage. Les performances des réseaux entraînés ont ensuite été évaluées sur des images provenant d'Internet pour la validation.

Dans [16], Les auteurs ont proposé d'utiliser des drones pour repérer les maladies en se basant sur les réseaux de neurones convolutionnels (CNN). Dans leurs futurs travaux, ils envisagent d'exploiter également ces drones pour cibler précisément les zones infectées des plantes et pulvériser des pesticides en fonction de la gravité de l'infection. Ils ont utilisé un grand ensemble de données composé de 2 100 images de feuilles de tomate trouvées sur Internet et 500 images de fermes locales. Pour entraîner leur CNN à reconnaître les feuilles malades, ils ont utilisé une technique appelée apprentissage par transfert et se sont basés sur un CNN appelé Inception développé par Google. Ils ont ainsi classé les feuilles en trois groupes selon leur état :

bon, moyen et mauvais.

Dans l'article [17], la méthode de détection nommée PLPNet emploie un réseau de neurones pour détecter les maladies. Pour ce faire, elle utilise un module spécial de convolution qui permet d'extraire efficacement les caractéristiques clés des maladies. En outre, PLPNet intègre un mécanisme d'attention afin de focaliser son analyse sur les parties cruciales de l'image, tout en éliminant les distractions provenant de l'arrière-plan. Un autre aspect essentiel est l'utilisation d'un réseau de regroupement des caractéristiques similaires, qui contribue à une meilleure distinction entre les différentes maladies. Grâce à la combinaison de ces techniques, PLPNet atteint une précision moyenne de 94,5%.

Dans [18], les auteurs ont présenté une méthode, basée sur le modèle TomFormer. Ce dernier combine un transformateur visuel avec un réseau neuronal convolutif. Le transformateur visuel permet une analyse plus efficace des données visuelles en capturant les relations spatiales et contextuelles importantes. Cela améliore la capacité du modèle à reconnaître les motifs complexes et à fournir des prédictions précises. Les auteurs envisagent d'appliquer cette méthode au robot Hello Stretch afin de réaliser un diagnostic en temps réel.

Les résultats obtenus montrent que le modèle TomFormer offre des niveaux élevés de précision pour la détection des maladies des feuilles de tomate. Plus précisément, sur l'ensemble de données KUTomaDATA, le modèle a obtenu un score mAP (précision moyenne) de 87%. Sur l'ensemble de données PlantDoc, TomFormer a affiché un score mAP de 81%. Enfin, sur l'ensemble de données PlantVillage, TomFormer a atteint un score mAP de 83%.

Dans [19], les auteurs ont conçu une méthode de détection en serre utilisant une application Android pour évaluer le degré de maladie en temps réel. Ils ont utilisé l'appareil photo d'un téléphone portable pour capturer des images des feuilles de tomate malades. Le système de détection a été développé sur Eclipse dans un environnement de développement Android. Ils ont ensuite utilisé un algorithme de segmentation par seuillage itératif pour isoler les zones affectées, suivi de l'application de l'algorithme de fuzzy C-means cluster pour extraire les taches de maladie. Une fois le degré de maladie déterminé selon les normes établies, les données sont téléchargées sur un serveur réseau pour une analyse ultérieure.

Dans [20], les auteurs ont développé une architecture complète pour la détection

des maladies des feuilles de tomates. Ils ont commencé par collecter un ensemble de données d'images de feuilles de tomates saines et malades, qu'ils ont ensuite divisé en ensembles d'entraînement, de test et de validation. En utilisant le modèle EfficientNetV2B2, ils ont construit un système d'apprentissage en profondeur en ajoutant une couche dense de 256 neurones, puis ont développé un système basé sur ce modèle. Ils ont également créé une application web et une application smartphone permettant aux utilisateurs de soumettre des images de feuilles de tomates pour obtenir des résultats de diagnostic. Pour maintenir le système de détection à jour, le modèle est continuellement entraîné avec de nouvelles images.

La méthode de détection repose sur l'architecture EfficientNetV2B2, un modèle pré-entraîné sur le jeu de données ImageNet, et utilise des techniques de fine-tuning pour adapter le modèle à la détection des maladies spécifiques des feuilles de tomates.

Dans [21], les auteurs proposent une approche novatrice pour détecter les maladies de la tâche septorienne de la tomate et le virus de la mosaïque. Cette approche repose sur l'utilisation d'un réseau neuronal convolutif profond (DCNN). En utilisant les bibliothèques de machine learning Python Keras et TensorFlow, un modèle a été développé et déployé sur un dispositif Raspberry Pi portable pour la classification des maladies des plantes sur site. Les images d'entraînement ont été collectées à partir de plantvillage.org, puis divisées en ensembles d'entraînement, de test et de validation. Après avoir augmenté les images d'entraînement, elles ont été introduites dans le modèle DCNN pour l'entraînement. Le modèle a montré une précision de validation de 99,01%.

Dans [22], Les auteurs proposent une méthode basée sur plusieurs étapes : acquisition d'image, prétraitement, segmentation et classification. Les images RGB des feuilles sont capturées à l'aide d'une caméra numérique connectée à une carte Raspberry Pi, puis transformées en format HSV pour faciliter la perception des couleurs. Les pixels verts, représentant les parties saines des feuilles, sont masqués et éliminés, et les zones contaminées sont segmentées et analysées pour leurs caractéristiques de texture. Ces caractéristiques sont ensuite utilisées pour classifier les maladies des plantes à l'aide d'algorithmes d'apprentissage automatique.

Dans [23], Les auteurs proposent une méthode embarquée pour détecter et classer les maladies des feuilles de tomate, ils ont eu recours aux services Microsoft Azure tels qu'Azure IoT Hub, Azure IoT Edge et Custom Vision. Le système est déployé sur un Raspberry Pi, agissant en tant que dispositif IoT Edge, pour la capture d'images

en temps réel des feuilles de plantes. Ces images sont ensuite envoyées à un service de classification d'images hébergé dans Azure pour prédire les maladies. Les performances du modèle sont évaluées, et les résultats démontrent une précision de 96,7%.

Dans [24], La méthode présentée passe par plusieurs étapes. Les images des feuilles sont prétraitées, notamment redimensionnées et converties en tableaux NumPy, puis divisées en ensembles d'entraînement et de validation, auxquels des techniques d'augmentation sont appliquées. Trois architectures de CNN : LeNet, AlexNet et VGG-16, sont utilisées et entraînées sur les ensembles d'entraînement pour la classification. Les modèles CNN sont ensuite évalués sur les ensembles de validation. Une fois entraînés, les modèles sont déployés sur un robot TurtleBot3 équipé d'une caméra, permettant une analyse en temps réel des images pour la détection des maladies et l'évaluation de la maturité des tomates.

Les performances des différentes architectures de CNN sont ensuite comparées, la précision de la méthode pour la classification des maladies varie : LeNet-5 atteint une précision de 13,5%, AlexNet obtient une précision de 88,25% et VGG-16 atteint une précision de 61,03%.

Dans [25], La méthode proposée repose sur une approche embarquée de classification. Tout d'abord, les images des feuilles de tomate affectées sont prétraitées, ce qui comprend des étapes telles que l'amélioration de la qualité de l'image et la suppression du bruit. Ensuite, les parties infectées des feuilles sont segmentées pour les isoler du reste de l'image. Cette segmentation est réalisée à l'aide de techniques telles que l'algorithme K-means, qui partitionne les données extraites en clusters représentant différents types de maladies. Une fois les images prétraitées et segmentées, les données sont transférées au Raspberry Pi qu'elles soient traitées à l'aide de Python et MATLAB. Enfin, à partir de ces segments, des caractéristiques pertinentes sont extraites pour représenter les symptômes des maladies. Les résultats obtenus démontrent une précision de classification de 99%.

2.2 Méthodes non-embarquées

Dans [26], les auteurs ont développé un modèle de CNN en utilisant l'apprentissage par transfert et le réseau VGG16 dans le but d'identifier les ravageurs et les maladies affectant les plants de tomates. Dans l'étude initiale sur laquelle se sont basés les auteurs, le modèle VGG16 a été entraîné pour être capable de reconnaître mille catégories à partir d'un ensemble de données comportant jusqu'à 1,26 million

d'images. L'auteur a constitué un ensemble de 7040 images provenant de Chine, couvrant diverses catégories de ravageurs et maladies telles que le curling des feuilles, la moisissure des feuilles, la brûlure tardive, la tache bactérienne, la tache septoïa, la tache cible, les acariens, la tache grise, le virus mosaïque ainsi que des plants sains, comprenant chacune 640 images.

Par la suite, le modèle VGG16 a été utilisé pour extraire les caractéristiques distinctives des images brutes. Ces caractéristiques ont ensuite été combinées avec un algorithme de classification SVM pour identifier les maladies. Cependant, il est important de noter que la performance globale du système dépend significativement de la qualité relativement élevée des images utilisées.

Dans [27], Les auteurs ont proposé d'utiliser des réseaux neuronaux profonds pour détecter les maladies et les ravageurs à partir d'images capturées sur les champs de tomate. Ils ont exploré trois principales familles de détecteurs (Faster R-CNN, R-FCN et SSD) ainsi que deux extracteurs de caractéristiques profondes (VGG net et ResNet). Une méthode d'annotation de classe, ainsi que des techniques d'augmentation des données pour agrandir la taille du Dataset ont été développées pour améliorer la précision et réduire les faux positifs.

Leur méthode a été testée sur un ensemble de données comprenant des images de feuilles de tomate infectées par neuf types de maladies et de ravageurs, montrant une capacité à détecter efficacement ces affections même dans des scénarios complexes (Images non claires à 100%).

Dans [28], Les auteurs proposent une nouvelle approche pour faciliter la reconnaissance des maladies, visant à surmonter les défis liés au bruit dans les images résultant des interférences environnementales. Ils ont recours à une méthode de transformation en ondelettes binaires combinée avec la méthode Retinex (BWT + R) pour réduire le bruit et améliorer la qualité des images. Cette technique permet d'éliminer les taches de bruit et les contours indésirables tout en préservant les informations texturales essentielles. Ensuite, afin d'isoler efficacement les feuilles de tomate du fond de l'image, les chercheurs utilisent une approche d'optimisation basée sur un essaim d'abeilles artificielles (ABCK).

Enfin, pour l'identification précise des maladies, les auteurs ont utilisé le modèle Both-channelAttention Residual Network (B-ARNet). Ce modèle permet de capturer efficacement les caractéristiques importantes des maladies des feuilles de tomate. Les

résultats de l'application de cette méthode sur un ensemble de 8616 images montrent une précision globale de détection d'environ 89%.

Dans [29], les chercheurs ont proposé l'utilisation de la transformation d'ondelettes de Gabor pour extraire des caractéristiques essentielles à partir des images de feuilles de tomate, qu'ils ont ensuite associées à des Machines à Vecteurs de Support (SVM) afin de détecter les maladies. Après avoir collecté des échantillons de feuilles malades et les avoir isolées, ils ont appliqué une technique basée sur les caractéristiques d'ondelettes pour sélectionner les plus pertinentes. En utilisant un classifieur SVM avec différentes fonctions de noyau, ils ont réussi à identifier des maladies telles que l'oïdium ou la brûlure précoce. Les résultats des tests sur un ensemble de données comprenant 100 images pour chaque type de maladie ont démontré une précision moyenne de 99,5%.

Dans [30], La solution proposée par les auteurs utilise un modèle de CNN comprenant 3 couches de convolution et 3 couches de regroupement maximum, suivies de 2 couches entièrement connectées, pour détecter et classifier les maladies. Les couches de convolution extraient progressivement des caractéristiques des images de feuilles de tomate, permettant au modèle de reconnaître les signes de maladies spécifiques. Les couches de regroupement maximum réduisent la dimensionnalité des caractéristiques extraites tout en préservant les informations importantes. Enfin, les couches entièrement connectées classifient les caractéristiques extraites, permettant d'identifier précisément les maladies des feuilles de tomate avec une précision allant jusqu'à 91,2%.

Les résultats de cette méthode ont montré une efficacité significative par rapport aux modèles pré-entraînés tels que VGG16 et InceptionV3. La précision de classification obtenue varie de 76% à 100% selon les classes de maladies.

Dans [31], Les auteurs proposent une solution de détection automatique des maladies courantes des feuilles de tomates dans le sud de la Chine, en utilisant une approche basée sur FC-SNDPN (Fully Convolutional – Switchable Normalization Dual Path Networks). Cette méthode intègre un réseau de convolution complète basé sur le modèle VGG-16 pour segmenter l'image de la culture cible, suivi d'un modèle DPN amélioré pour extraire les caractéristiques. En combinant les couches DenseNet et ResNet, cette approche optimise les paramètres du réseau de neurones, améliorant ainsi sa polyvalence pour différents types de maladies et de ravageurs, ainsi que sa vitesse d'apprentissage. Les résultats obtenus démontrent une précision d'identification de 97,59%.

Dans [32], Les auteurs proposent une solution basée sur l'utilisation de CNNs pré-entraînés, notamment AlexNet, GoogLeNet et ResNet-50, pour extraire les caractéristiques. Ensuite, ils ont proposé un modèle qui combine les caractéristiques profondes extraites de ces 3 modèles. Ces caractéristiques ont été utilisées pour entraîner un classificateur de machine à vecteurs de support (SVM). Le modèle proposé a été utilisé pour classifier des images de feuilles de tomate atteintes de maladies et de ravageurs, qui constituent un sous-ensemble du Dataset PlantVillage qui est en accès libre, composé au total de 18835 images appartenant à 10 classes, dont une d'images de plantes saines. Les mesures de performance telles que l'exactitude, la précision, la sensibilité et le score f ont été utilisées avec la méthode de validation hold-out pour déterminer les performances du modèle.

Les résultats expérimentaux montrent que la détection efficace est possible en utilisant les caractéristiques profondes concaténées avec un taux de précision global de 96,99 %.

Dans [33], La méthode proposée repose sur une approche utilisant le traitement d'images pour détecter automatiquement les maladies. Tout d'abord, les images sont acquises et collectées à partir de différents champs de tomates. Ensuite, un prétraitement est effectué pour améliorer la qualité des images, impliquant le recadrage des images pour éliminer les parties non utiles pour la détection, le redimensionnement des images à une taille standard et l'amélioration de la qualité de l'image pour rendre les informations plus visibles. Ensuite, les images sont segmentées en utilisant la technique de segmentation nommée Otsu, qui est une méthode de segmentation d'image qui vise à simplifier la représentation d'une image en la divisant en plusieurs segments ou régions, généralement en fonction des variations de luminosité ou de couleur. Cette technique est basée sur la méthode dite de "seuillage", où un seuil est défini pour séparer les pixels de l'image en deux classes distinctes : les pixels d'avant-plan et les pixels d'arrière-plan.

Après la segmentation, l'extraction des caractéristiques est effectuée pour représenter l'image sous forme de vecteur de caractéristiques fixes, en utilisant des techniques de texture statistique basées sur GLCM (Gray Level Co-Occurrence Matrix). Enfin, la classification des images est réalisée à l'aide d'une machine à vecteurs de support (SVM), qui utilise les valeurs des caractéristiques extraites pour déterminer la présence de maladies et leurs types.

Dans [34], les auteurs ont mis au point une méthode nouvelle et originale utilisant

des réseaux neuronaux profonds (DNN), baptisée PCA DeepNet. Cette méthode combine deux techniques : l'Analyse en Composantes Principales (PCA) et un réseau neuronal profond personnalisé. De plus, elle intègre un Réseau Générateur Adversaire (GAN) pour enrichir les jeux de données. Pour détecter les maladies, ils ont utilisé un type particulier de réseau de convolution appelé F-RCNN, qui permet d'atteindre une précision de classification élevée de 99,60 %. La PCA DeepNet optimisée assure un traitement soigné des données, depuis leur prétraitement jusqu'à leur classification. Les données sont d'abord prétraitées et augmentées grâce au GAN, puis elles subissent une extraction de caractéristiques à l'aide de la méthode PCA.

Dans [35], Les auteurs ont comparé des solutions qui reposent sur l'utilisation de la vision par ordinateur pour une détection intelligente des maladies liées aux feuilles de la tomate. Plus précisément, ils ont comparé les performances de différents modèles d'apprentissage en profondeur, tels que DenseNet169, ResNet50V2 et ViT. Ils ont utilisé un ensemble de données comprenant à la fois des échantillons de tomates malades et saines pour entraîner et tester les modèles.

D'après les résultats de l'étude, le modèle DenseNet121 semble offrir les meilleures performances en termes de précision, avec une précision de 99%. Cependant, il convient de noter que les modèles ResNet50V2 et ViT ont également montré des performances élevées, bien que légèrement inférieures à celle de DenseNet121. Ainsi, le choix de la meilleure solution dépendra des besoins spécifiques de l'application et des contraintes de ressources de l'ordinateur utilisé (DenseNet169 est plus gourmand que ResNet50V2 par exemple, et ViT est le plus gourmand).

Dans [36], les chercheurs ont développé une méthode combinant deux modèles déjà entraînés, EfficientNetB3 et MobileNet, pour créer un nouveau modèle appelé EffiMob-Net, qui repère les maladies des feuilles de tomates. Pour permettre au modèle de mieux détecter sur des données différentes de celles vues dans le Dataset d'entraînement, ils ont utilisé différentes techniques comme la régularisation, le dropout et la normalisation par lots.

Ce modèle hybride, EffiMob-Net, a été testé sur un ensemble de données contenant des images de feuilles de tomates, et il a réussi à détecter les maladies avec une précision de 99,92 %.

Dans [37], les auteurs ont développé une méthode de détection en combinant différentes techniques. Ils ont utilisé l'ensemble de données PlantVillage pour annoter

les images, puis ont entraîné un modèle CornerNet avec une architecture personnalisée. En plus de cela, ils ont intégré le réseau DenseNet-77 pour extraire les caractéristiques des images. DenseNet-77 est un réseau de neurones convolutionnels (CNN) qui se caractérise par une architecture dense où chaque couche reçoit en entrée les sorties de toutes les couches précédentes. Cette connexion dense permet un flux d'informations riche à travers le réseau, favorisant ainsi une meilleure représentation des caractéristiques des images.

Dans cette méthode, le DenseNet-77 est utilisé comme base pour extraire des caractéristiques pertinentes des images de feuilles de tomate affectées par les maladies. Ces caractéristiques sont ensuite fournies à un modèle CornerNet personnalisé pour la localisation et la classification automatiques des régions affectées. La solution a été évaluée sur l'ensemble de données complexe PlantVillage, obtenant une précision moyenne de 99,98 %.

Dans l'article [38], les auteurs ont proposé une méthode de détection de la mineuse de la tomate en utilisant des réseaux neuronaux profonds (DNN). Ils redimensionnent d'abord les images des feuilles de tomate à une taille uniforme de 300 par 300 pixels, puis segmentent la région de la feuille infectée par la mineuse pour créer des masques binaires indiquant les zones affectées par la maladie. Ensuite, un DNN basé sur l'apprentissage par transfert, utilisant ResNet152 pré-entraîné sur le jeu de données ImageNet, est employé pour classifier les images en feuilles normales et infectées. Parallèlement, un autre DNN appelé DMRCNN est utilisé pour la segmentation des objets, en se basant sur les paires d'images redimensionnées et les masques binaires correspondants.

Le tableau suivant synthétise les différentes méthodes de détection des maladies des feuilles de tomate présentées dans les articles précédents, en mettant en évidence les modèles utilisés, les datasets exploités, ainsi que les taux de précision obtenus pour chaque approche.

Article	Modèle	Dataset	Taux de précision
[15]	-Réseau neuronal profond (DNN) (AlexNet et SqueezeNet)	-PlantVillage	-AlexNet : 95,6 % -SqueezeNet : 94,3 %

[16]	-Les réseaux de neurones convolutionnels (modèle Inception de Google)	-Un grand ensemble d'images de feuilles de tomate, totalisant 2 100 images provenant d'Internet. -500 images de fermes locales.	99 %
[17]	-PLPNet	-PlantVillage	94,5 %
[18]	-Modèle TomFormer.	-KUTomaDATA. -PlantDoc. -PlantVillage	-87 % sur l'ensemble de données KUTomaDATA. -81 % sur l'ensemble de données PlantDoc. -83 % sur l'ensemble de données PlantVillage.
[19]	-Algorithme de segmentation par seuillage itératif -Algorithme de fuzzy C-means clustering.	-Ensemble d'images capturées à l'aide d'une caméra portable.	
[20]	-EfficientNetV2B2	-Dataset de kaggle.	99 %
[21]	-CNN	-PlantVillage.org.	99,01 %
[22]	-Faster RCNN -SSD MobileNet	-Images capturées à l'aide d'un appareil photo numérique.	99,99 %
[23]	-CNN	-31 397 photographies	98,9 %
[24]	-CNN (LeNet, AlexNet et VGG-16)	-Dataset de kaggle.	-LeNet-5 : 13,5 % -AlexNet : 88,25 % -VGG-16 : 61,03 %
[25]	-CNN (GoogleNet et VGG16)	PlantVillage.	99 %
[26]	-VGG-16	-7040 images provenant de Chine.	89 %

[27]	-Faster R-CNN, R-FCN et SSD. -VGG net et ResNet.	-Images collectées à partir des exploitations agricoles de tomates en Corée.	83 %
[28]	-Both-channel Attention Residual Network (B-ARNet).	- Plant Village	89 %
[29]	- SVM (machines à vecteurs de support).	-200 images capturées à l'aide d'un appareil photo dans la ville de Bani Seef.	99,5 %
[30]	-CNN (VGG-16 et Inception V3)	-Plant Village.	91,2 %
[31]	-VGG-16 -DPN	- Base de données contient des images capturées dans un environnement de terrain. -PlantVillage.	97,59 %
[32]	-AlexNet -GoogleNet -ResNet-50	-PlantVillage.	96,99 %
[33]	- SVM (machines à vecteurs de support).	-Ensemble d'images du format JPEG capturées à l'aide d'une caméra mobile à Dir, au Pakistan.	-99 % pour les feuilles saines. -95 % pour la brûlure précoce. -90 % pour la tache septorienne des feuilles. -85 % pour la brûlure tardive.
[34]	-F-RCNN	-PlantVillage.	99,60 %
[35]	-DenseNet169, ResNet50V2 et ViT (Vision Transformer).	-Dataset de Kaggle	99 %
[36]	-EffiMob-Net	-PlantVillage.	99,92 %

[37]	-CNN (DenseNet-77) -CornerNet	-PlantVillage.	99,98 %
[38]	-DNN (Re- sNet152, DMRCNN)	-ImageNet.	97,75 %

TABLE

2.2.1 – Tableau récapitulatif

2.3 Critique et discussion

Les méthodes de détection évoquées dans cet état de l'art présentent diverses limitations, notamment en termes de connectivité, de contraintes matérielles, de flexibilité et de capacité à effectuer des analyses en temps réel. Par exemple, certaines méthodes nécessitent une connexion à des services cloud ou à des serveurs distants pour le traitement des images, ce qui peut entraîner des retards et des dépendances vis-à-vis de la disponibilité du réseau. Par exemple, dans [24], l'utilisation des services Microsoft Azure implique une dépendance à une connexion Internet pour l'envoi des images au service de classification d'images hébergé dans Azure.

En ce qui concerne le coût matériel, plusieurs méthodes requièrent l'utilisation de dispositifs spécifiques tels que des drones ou des caméras spéciales. Ces dispositifs peuvent être coûteux à acquérir et à maintenir, ce qui peut constituer un obstacle pour leur déploiement à grande échelle. Par exemple, dans [17], l'utilisation de drones pour détecter les maladies peut être coûteuse en termes d'équipement et de maintenance. En termes de portabilité et de détection en temps réel, certaines méthodes peuvent être limitées par la puissance de traitement des dispositifs embarqués ou par la complexité des modèles utilisés. Par exemple, dans [20], bien que l'application Android permette une évaluation en temps réel du degré de maladie, la puissance de traitement des Smartphones peut être insuffisante pour des tâches de détection plus complexes ou pour des volumes élevés d'images.

Conclusion

L'examen approfondi de l'état de l'art des techniques de détection des maladies des feuilles de tomate a permis de mettre en lumière la diversité des approches utilisées et

les progrès réalisés dans ce domaine. Ces recherches démontrent l'évolution vers des solutions automatisées et efficaces, mais elles révèlent également des défis à surmonter. En nous appuyant sur cette analyse critique, nous sommes désormais mieux armés pour développer une solution innovante et performante, qui répondra aux besoins spécifiques des agriculteurs et contribuera à la protection des cultures de tomate contre les maladies. Nous allons présenter cette solution dans le prochain chapitre.

Chapitre 3

Solution proposée

Introduction

Dans ce troisième chapitre, nous allons explorer les éléments clés de notre solution pour la détection des maladies des feuilles de tomates. Nous allons discuter de la motivation derrière le choix de notre solution, en présentant les outils utilisés tels que le Raspberry Pi et Edge Impulse, expliquant ainsi leur fonctionnement, leurs avantages et pourquoi ils ont été sélectionnés pour notre solution. Ensuite, nous allons présenter le fonctionnement de notre solution.

3.1 Motivation

Après avoir passé en revue les principaux travaux liés à la détection de maladies, nous avons été motivés sur plusieurs points pour la proposition de notre solution. Tout d'abord, notre solution fonctionne sans connexion Internet, ce qui garantit une disponibilité constante même dans des environnements isolés. De plus, elle réduit les coûts, ce qui la rend économique et accessible aux agriculteurs sans nécessiter d'équipement coûteux. La facilité d'utilisation de Raspberry Pi en fait également un choix pratique, car elle ne nécessite pas de compétences techniques avancées pour être mise en œuvre. En combinant la puissance de calcul de Raspberry Pi avec les fonctionnalités avancées d'Edge Impulse, nous pouvons obtenir une solution robuste et efficace pour notre projet.

3.2 Qu'est-ce que la vision par ordinateur ?

Computer Vision ou la vision par ordinateur, est une branche de l'Intelligence Artificielle, elle vise à permettre aux ordinateurs d'analyser et d'interpréter des données visuelles telles que des photos, des vidéos et d'autres entrées visuelles, prises par un système d'acquisition, pour en extraire des informations. Si l'intelligence artificielle permet aux ordinateurs de «penser», la vision par ordinateur leur permet de «voir», d'observer et de comprendre. Elle comprend divers domaines, dont les deux principaux sont la reconnaissance d'image et la Machine Vision. Ces domaines reposent sur des algorithmes d'apprentissage supervisé, qui sont formés à partir d'exemples d'images labellisées. [39].

3.2.1 Principe de fonctionnement

La vision par ordinateur s'appuie sur des algorithmes mathématiques et statistiques pour extraire des informations à partir d'images et de vidéos, et les interpréter de manière significative. Ces algorithmes utilisent majoritairement des réseaux de neurones, et notamment les CNN.

Les algorithmes de vision par ordinateur s'inspirent du fonctionnement de cerveau humain. Les scientifiques ont étudié le fonctionnement du cortex visuel, la partie du cerveau qui traite les informations visuelles, afin de concevoir des algorithmes capables de reproduire certains aspects de la perception humaine. [40].

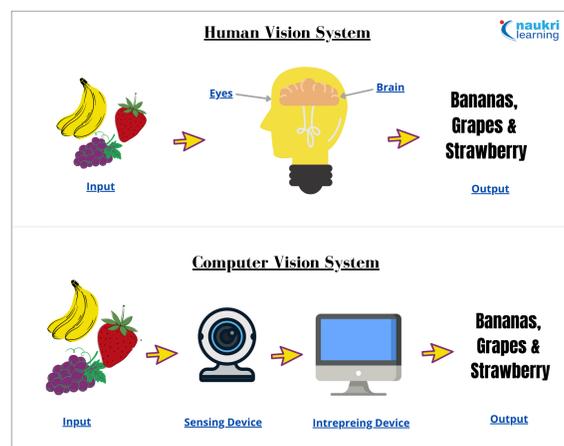


FIGURE 3.1 – Système de vision humaine VS Système de vision par ordinateur.

3.2.2 Les étapes de fonctionnement

La vision par ordinateur comprend les étapes suivantes :

1. **Acquisition d'images** : capture d'images ou de vidéos numériques à l'aide de caméras ou de capteurs.
2. **Prétraitement** : les données brutes des images sont prétraitées, ce qui comprend des tâches telles que la réduction du bruit, l'amélioration de l'image et la normalisation.
3. **Extraction de caractéristiques** : l'algorithme extrait les caractéristiques importantes de l'image, telles que les contours, les coins et les textures, pour aider à identifier et à classer les objets dans l'image.

4. **Reconnaissance et suivi des objets** : l'algorithme utilise les caractéristiques extraites pour identifier et suivre les objets dans l'image, et peut également suivre leurs mouvements.
5. **Interprétation et prise de décision** : l'algorithme analyse les objets identifiés et leur mouvement pour extraire des informations utiles et prendre des décisions ou des prédictions basées sur ces informations.[41]

3.2.3 Applications de la vision par ordinateur

- **Classification d'objets** : entraînement de modèles pour identifier et classer de nouveaux objets dans des catégories spécifiques, permettant ainsi une reconnaissance automatique et précise.
- **Analyse du mouvement vidéo** : calcul de la vitesse des objets en mouvement ou suivi précis de leur trajectoire dans une vidéo pour détecter des événements significatifs tels que les collisions ou les mouvements suspects.
- **Analyse et reconstruction 3D** : création de modèles tridimensionnels à partir d'images, de photographies ou de plans en deux dimensions, ce qui facilite la visualisation et la manipulation d'objets en trois dimensions.
- **Détection et identification d'objets** : reconnaissance précise et suivi d'objets dans une image, quelle que soit leur position ou leur orientation, offrant ainsi des solutions efficaces pour la sécurité, la surveillance et la navigation.
- **Analyse en temps réel** : utilisation de la vision par ordinateur en temps réel pour des applications telles que la surveillance de la circulation, la navigation autonome et la réalité virtuelle, offrant ainsi des solutions rapides et adaptatives aux défis en constante évolution .[42]

3.3 Le traitement d'image

Le traitement d'images désigne une discipline de l'informatique et des mathématiques appliquées qui étudie les images numériques et leurs transformations, dans le but d'améliorer leur qualité ou d'en extraire de l'information. [43]. On utilise le traitement d'image pour modifier une image brute et la préparer pour d'autres tâches telles que la vision par ordinateur.

Input : Image brute

Output : Image modifiée



FIGURE 3.2 – Exemple d’une image avant et après le traitement

Différentes techniques du traitement d’images

— Amélioration d’images

L’amélioration d’images est le processus qui consiste à faire ressortir et mettre en évidence certaines caractéristiques d’intérêt dans une image en modifiant des paramètres tels que la luminosité ou le contraste.

— Traitement des Images en couleur

Le traitement des images en couleur inclut diverses techniques de modélisation des couleurs dans un domaine numérique. Cette étape a gagné en importance en raison de l’utilisation significative d’images numériques sur Internet.

— Traitement d’Ondelettes et Multi-résolution

Les ondelettes sont utilisées pour représenter les images à différents degrés de résolution. Les images sont subdivisées en ondelettes ou en régions plus petites pour la réduction des données.

— Compression

La compression est un processus utilisé pour réduire le stockage nécessaire pour sauvegarder une image ou la bande passante nécessaire pour la transmettre. Cela est fait notamment lorsque l’image est destinée à être utilisée sur Internet.

— **Traitement Morphologique**

Le traitement morphologique est un ensemble d'opérations de traitement pour transformer les images en fonction de leurs formes.

— **Segmentation**

La segmentation est l'une des techniques les plus importantes du traitement d'images. Elle consiste à partitionner une image en parties distinctes pour permettre une analyse plus précise.

— **Représentation et Description**

Après qu'une image a été segmentée en régions dans le processus de segmentation, chaque région est représentée et décrite sous une forme adaptée au traitement informatique. La représentation traite les caractéristiques de l'image et les propriétés régionales. La description traite de l'extraction d'informations qui aident à différencier une classe d'objets de l'autre. [44].

3.4 Tiny machine learning

L'intelligence artificielle (IA) et le machine learning (ML) transforment notre quotidien, redéfinissant notre interaction avec le monde numérique. Cependant, une nouvelle tendance émerge au sein de ces domaines en plein essor, promettant des bouleversements majeurs : le Tiny Machine Learning.

Cette approche s'inspire des principes fondamentaux de l'IA et du ML, mais elle se distingue par sa capacité à s'exécuter sur des appareils à faible puissance, comme des microcontrôleurs ou des capteurs embarqués. Cette caractéristique ouvre un champ d'applications inédit, permettant d'intégrer l'IA et le ML dans des objets du quotidien, comme des smartphones, des wearables ou des appareils connectés.

Qu'est-ce que le TinyML ?

Le TinyML, ou apprentissage automatique embarqué, se distingue comme un sous-domaine prometteur de l'apprentissage automatique. Il s'intéresse à l'implantation de modèles d'apprentissage automatique sur des appareils à faible puissance, tels que les microcontrôleurs, caractérisés par des contraintes énergétiques, de latence et de bande passante strictes.

En comparaison avec les processeurs standard, qui consomment généralement entre 65 et 85 watts, les microcontrôleurs opèrent à des niveaux de consommation d'énergie extrêmement faibles, mesurés en milliwatts voire en microwatts. Cette efficacité énergétique remarquable permet aux appareils TinyML de fonctionner pendant des périodes prolongées, allant de plusieurs semaines à plusieurs années dans certains cas, sans nécessiter d'alimentation externe. Cet atout majeur s'avère utile à cause de la hausse des coûts énergétiques.[45]

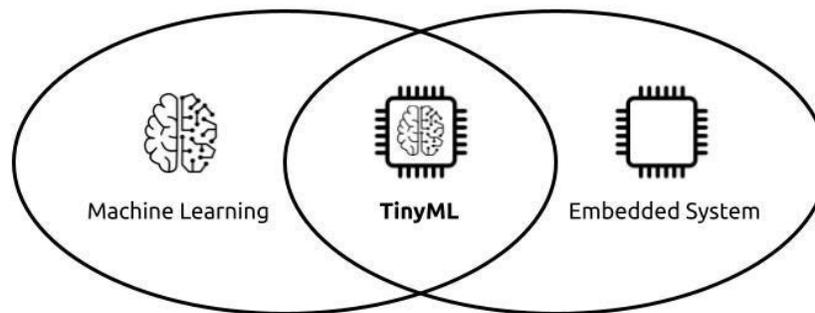


FIGURE 3.3 – Schéma d'un système TinyML.

Les avantages de TinyML

Dans le cadre de notre projet, nous avons choisi d'explorer la détection des maladies des feuilles de tomates en temps réel, en utilisant la technologie TinyML. Cette approche consiste à intégrer l'apprentissage automatique sur des dispositifs de faible puissance tels que la Raspberry Pi, afin de fournir une solution efficace et peu coûteuse pour les agriculteurs.

Dans cette section, nous allons présenter les avantages qui ont motivé le choix de TinyML pour notre solution.

1. **Faible latence** : En déployant le modèle TinyML sur des appareils proches les uns des autres, les données n'ont plus besoin d'être envoyées à un serveur distant, réduisant ainsi considérablement le temps de latence. Cela permet une analyse et une prise de décision rapides.
2. **Faible consommation d'énergie** : Les microcontrôleurs utilisés dans TinyML consomment peu d'énergie, permettant un fonctionnement autonome sur

de longues périodes sans recharge fréquente. De plus, l'élimination de l'infrastructure serveur pour le transfert de données réduit encore la consommation d'énergie, entraînant des coûts d'exploitation plus bas.

3. **Bande passante réduite** : Les applications TinyML nécessitent moins de bande passante car les données ne sont pas constamment envoyées vers un serveur. Cela est particulièrement avantageux dans les zones rurales où la connectivité Internet peut être limitée ou coûteuse.
4. **Confidentialité des données** : L'exécution locale du modèle sur l'appareil améliore la confidentialité des données car elles ne sont pas stockées sur des serveurs distants. Cela minimise les risques de piratage et les fuites de données sensibles. [45].

Principaux Cas d'Utilisation de TinyML

Grâce aux avancées du machine learning, TinyML s'est rapidement intégré dans divers secteurs, notamment ceux liés à l'Internet des objets (IoT). Voici quelques cas d'utilisation principaux :

1. **Agriculture** : TinyML permet la collecte et l'analyse en temps réel des données agricoles. Par exemple, la startup suédoise Imagimob a créé une plateforme de développement utilisée par cinquante-cinq organisations dans l'Union européenne pour améliorer la gestion des cultures et du bétail grâce au machine learning portable.
2. **Santé** : le projet Solar Scare Mosquito utilise TinyML pour limiter la propagation de maladies telles que la dengue, le paludisme, le virus Zika et le chikungunya. En détectant les conditions de reproduction des moustiques, ce système pulvérise de l'eau pour empêcher leur reproduction. Ce projet est à la fois économe en énergie grâce à TinyML et alimenté par l'énergie solaire.
3. **Expérience Client** : la personnalisation est essentielle pour le marketing des marques. Les entreprises qui comprennent et ciblent efficacement leurs clients avec des annonces et des messages pertinents gagnent des parts de marché. Les applications Edge TinyML aident à mieux comprendre le comportement des prospects et à adapter leur expérience en ligne à leurs besoins.

4. **Industrie** : les machines industrielles sont souvent sujettes aux pannes. En utilisant TinyML sur des appareils à faible consommation, il est possible de surveiller la chaîne de production et de prédire les problèmes techniques à l'avance. Cette maintenance prédictive permet de réaliser des économies considérables et d'améliorer la sécurité dans les usines. [46]

3.5 Les éléments de notre solution

Notre approche pour détecter les maladies des feuilles de tomate repose sur 02 éléments clés :

1. **Carte Raspberry Pi** : agit comme un ordinateur miniature pour collecter des données, exécuter des modèles et communiquer avec la plateforme Edge Impulse.
2. **Plateforme Edge Impulse** : offre un environnement de développement pour créer, entraîner et déployer des modèles d'apprentissage automatique sur la Raspberry Pi.

Fonctionnement de base des éléments :

- **Collecte de données** : la Raspberry Pi capture des images des feuilles de tomate.
- **Entraînement du modèle** : Edge Impulse est utilisé pour entraîner un modèle allégé d'apprentissage automatique à identifier les maladies à partir des images.
- **Déploiement du modèle** : le modèle entraîné est déployé sur la Raspberry Pi pour une classification en temps réel des nouvelles images.

3.5.1 Raspberry pi

Après la découverte du premier transistor en électronique, la réduction significative de la taille des machines et l'amélioration de leurs performances ont été rendues possibles, donnant naissance à des avancées telles que l'ordinateur. Cette évolution a conduit à l'apparition de micro-ordinateurs et même de nano-ordinateurs, comme la Raspberry Pi, qui offrent des performances impressionnantes malgré leur taille réduite.

Qu'est ce qu'un Raspberry Pi ?

Le Raspberry Pi est un nano-ordinateur à une seule carte ou monocarte, il a été créé par des enseignants du département d'informatique de l'Université de Cambridge dans le cadre de la Fondation Raspberry Pi. Ce petit ordinateur, de la taille d'une carte de crédit, offre une plateforme abordable et polyvalente pour les projets informatiques. Il est compatible avec divers systèmes d'exploitation, y compris Debian GNU/Linux et Windows 10 IoT Core, ce qui permet aux utilisateurs d'explorer différentes technologies logicielles. Son format compact et son accessibilité en font un outil précieux pour les étudiants et les amateurs de technologie cherchant à développer leurs compétences en informatique.[47].

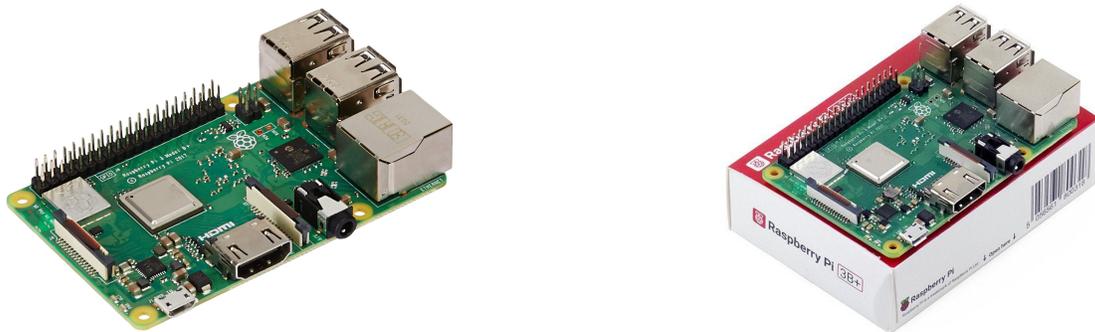


FIGURE 3.4 – Le Raspberry pi 3B+

Historique

L'origine de cette carte remonte à 2006, au sein du département d'informatique de l'Université de Cambridge. Le Professeur Eben Upton, constatant un manque de compréhension et de maîtrise de l'électronique chez les informaticiens, a cherché une solution pour pallier ce problème. Il a conclu à la nécessité de concevoir des ordinateurs modifiables intégrant des composants électroniques pas chers. Ainsi, l'idée de la Raspberry Pi est née. Après plusieurs tentatives, la première carte a finalement été lancée en 2012. Elle se distinguait par sa taille très réduite, son prix abordable et sa puissance suffisante pour exécuter de nombreuses applications. Cette innovation a rapidement rencontré un vif succès, notamment auprès des étudiants, des enseignants

et des amateurs de bricolage informatique et électronique.

La Raspberry Pi a depuis connu plusieurs évolutions, avec l'introduction de nouveaux modèles plus puissants et polyvalents. Elle est aujourd'hui utilisée dans une multitude d'applications, allant de l'éducation à la domotique en passant par le développement de jeux vidéo et l'intelligence artificielle. Le succès de la Raspberry Pi est dû à plusieurs facteurs, dont son prix abordable, sa communauté active et sa grande polyvalence. Elle est devenue un outil incontournable pour tous ceux qui souhaitent apprendre l'informatique, développer des projets électroniques ou simplement s'amuser avec la technologie.[48].

Les modèles de Raspberry pi

Le Raspberry Pi 1

Le Raspberry Pi 1, premier modèle de la série Raspberry Pi, a vu le jour le 29 février 2012. Cet ordinateur monocarte économique s'articule autour d'un système sur puce (SoC) Broadcom BCM2835. Ce dernier intègre un processeur ARM1176JZF-S cadencé à 700 MHz, un processeur graphique Videocore 4 et 512 Mo de mémoire vive (RAM).

Deux modèles principaux composent la gamme Raspberry Pi 1 :

- **Le modèle A**, lancé initialement, dispose d'un port USB 2.0 et d'un connecteur GPIO (General Purpose Input/Output) pour l'interfaçage avec des composants électroniques externes.
- **Le modèle B**, introduit ultérieurement, enrichit le modèle A d'un port Ethernet 10/100 et de deux ports USB 2.0 supplémentaires.[49].

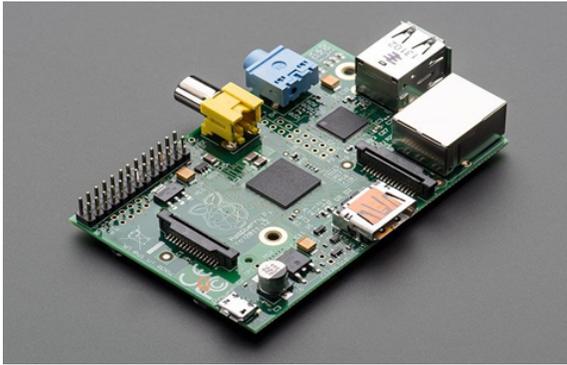


FIGURE 3.5 – Le Raspberry pi 1 modèle B



FIGURE 3.6 – Le Raspberry pi 1 modèle A

Deux versions dérivées ont également été commercialisées :

- **Le modèle B+**, successeur du modèle B, améliore les performances et la gestion de l'énergie tout en conservant la même connectique.
- **Le modèle A+**, version économique du modèle A, réduit les coûts en supprimant le port Ethernet et en simplifiant l'alimentation.

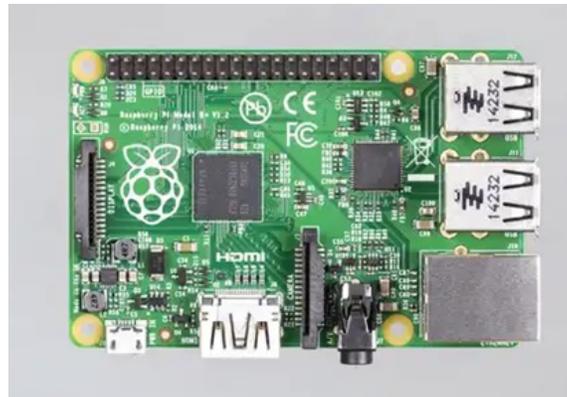


FIGURE 3.7 – Le Raspberry pi 1 modèle B+



FIGURE 3.8 – Le Raspberry pi 1 modèle A+

Le Raspberry Pi 2

Le Raspberry Pi 2, lancé en février 2015, constitue la deuxième génération de la célèbre série Raspberry Pi. Il se distingue par ses performances accrues et ses fonctionnalités améliorées, le positionnant comme un choix incontournable pour les amateurs d'informatique et d'électronique.

Comparé à son prédécesseur, le Raspberry Pi 2 Modèle B offre des avancées majeures :

- **Un processeur plus puissant** : Il troque le processeur ARM1176JZF-S monocœur du Raspberry Pi 1 pour un processeur ARM Cortex-A7 quadricœur cadencé à 900 MHz. Cette évolution se traduit par une multiplication par six des performances CPU, permettant une exécution plus fluide des applications et des tâches gourmandes en ressources.
- **Une mémoire vive doublée** : La capacité de la mémoire vive (RAM) passe de 512 Mo à 1 Go, offrant ainsi une meilleure gestion du multitâche et une prise en charge plus efficace des applications plus lourdes.[50]

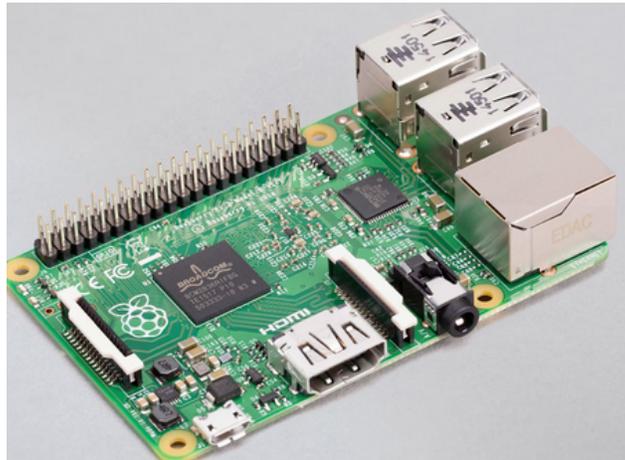


FIGURE 3.9 – Le Raspberry Pi 2 modèle B

Le Raspberry Pi Zero

Le Raspberry Pi Zero, lancé le 30 novembre 2015, repousse les limites de la miniaturisation en offrant une puissance informatique remarquable dans un format ultra-compact, deux fois plus petit que le Raspberry Pi A+. Il s'avère être une solution économique et polyvalente, adaptée à une large gamme de projets.

Doté d'un processeur Broadcom BCM2835 monocœur cadencé à 1 GHz et de 512 Mo de RAM, le Raspberry Pi Zero offre des performances suffisantes pour exécuter de nombreuses applications courantes, telles que la navigation web, le traitement de texte, le visionnage de vidéos et le développement de jeux simples.

Sa connectivité complète comprend :

- Un port mini HDMI pour la sortie vidéo
- Un port micro USB pour l'alimentation et les données
- Un emplacement pour carte microSD pour le stockage

Disponible en deux variantes principales :

- Le modèle Zero W intègre le Wi-Fi et le Bluetooth, permettant une connectivité sans fil pour des projets domotiques, l'IoT (Internet des Objets) et le streaming multimédia.
- Le modèle Zero WH ajoute à la connectivité du modèle W un connecteur pour écran LCD, idéal pour la création de mini-ordinateurs, de consoles de jeux rétro

et d'interfaces homme-machine.[50, 51]



FIGURE 3.10 – Le Raspberry pi Zero W



FIGURE 3.11 – Raspberry pi Zero WH

Le Raspberry Pi 3

Le Raspberry Pi 3, décliné en deux principaux modèles, B+ et A+, représente la troisième génération de cette série d'ordinateurs monocartes. Introduits respectivement en mars et novembre 2018, ces modèles se distinguent par leurs performances accrues, leur connectivité améliorée et leur polyvalence renforcée.

Le Raspberry Pi 3 Modèle B+ se caractérise par :

- **Un processeur Broadcom BCM2837B0 quad-core 64 bits cadencé à 1,4 GHz**, offrant une puissance de traitement nettement supérieure à ses prédécesseurs, permettant une exécution fluide des applications gourmandes en ressources et un multitâche efficace.
- **Une connectivité sans fil double bande 802.11 ac et Bluetooth 4.2/BLE**, garantissant des transferts de données plus rapides et une connectivité stable pour les périphériques et les réseaux sans fil.
- **Un port Gigabit Ethernet**, pour un accès réseau filaire ultra-rapide et une communication fiable avec les périphériques réseau.
- **La prise en charge du Power-over-Ethernet (PoE)**, permettant d'alimenter le Raspberry Pi directement via un câble Ethernet, éliminant le besoin d'un adaptateur secteur séparé.

Le Raspberry Pi 3 Modèle A+, quant à lui, offre :

- **Le même processeur quad-core 64 bits cadencé à 1,4 GHz** que le modèle B+, garantissant des performances puissantes pour une large gamme d'applications.
- **Une connectivité sans fil double bande 802.11 ac et Bluetooth 4.2/BLE**, pour une connectivité sans fil rapide et fiable.
- **Un format ultra-compact**, identique au Raspberry Pi 1 Modèle A+, idéal pour les projets embarqués et les espaces restreints.
- **Un prix abordable**, le rendant accessible à un large public d'utilisateurs.



FIGURE 3.12 – Le Raspberry pi 3 modèle A+

Le Raspberry Pi 4

Le Raspberry Pi 4, lancé le 24 juin 2019, marque une avancée majeure en termes de vitesse et de performances. Ce petit ordinateur monocarte offre une expérience de bureau complète, rivalisant avec les ordinateurs personnels traditionnels, tout en conservant son format compact et sa faible consommation d'énergie.

Doté d'un processeur Broadcom BCM2711 quad-core 64 bits cadencé à 1,5 GHz et de deux options de mémoire vive (1 Go, 2 Go ou 4 Go), le Raspberry Pi 4 surpasse largement ses prédécesseurs en termes de puissance de traitement. Cette performance accrue permet une exécution fluide d'applications gourmandes en ressources, telles que le montage vidéo, les jeux vidéo et le développement de logiciels.

Le Raspberry Pi 4 se distingue également par sa haute connectivité, avec notamment :

- **Deux ports HDMI**, permettant de connecter deux moniteurs simultanément pour une expérience multi-écrans optimale.
- **Deux ports USB 3.0**, offrant des transferts de données ultra-rapides pour les périphériques externes.
- **Un port Gigabit Ethernet**, garantissant un accès réseau filaire fiable et performant.
- **La connectivité sans fil Wi-Fi 802.11ac et Bluetooth 5.0**, pour une connectivité sans fil stable et rapide.
- **Un connecteur GPIO 40 broches**, permettant l'interfaçage avec divers composants électroniques et capteurs pour des projets de domotique, d'IoT et de prototypage électronique.[50]



FIGURE 3.13 – Le Raspberry pi 4

Raspberry Pi Pico

Le Raspberry Pi Pico est une carte microcontrôleur économique mais performante, dotée d'interfaces numériques flexibles. Ses principales caractéristiques, en plus de sa taille très réduite, sont les suivantes :

- **264 Ko de SRAM et 2 Mo de mémoire flash intégrée**, permettant de stocker des programmes et des données directement sur la carte.
- **26 broches GPIO multifonctions**, programmables pour piloter divers périphériques électroniques, tels que des capteurs, des LED, des moteurs et des écrans.
- **Horloge et minuteur précis intégrés**, pour une gestion précise du temps dans les applications embarquées.[52]



FIGURE 3.14 – Raspberry Pi Pico

Le Raspberry Pi 5

Le Raspberry Pi 5 est le dernier modèle commercialisé, sorti en 2023, il représente une avancée significative par rapport à ses prédécesseurs, offrant une vitesse de traitement deux à trois fois supérieure au modèle 4 grâce à son processeur quadricœur Arm Cortex A76 Broadcom BCM2712 cadencé à 2,4 GHz. Avec une capacité de RAM pouvant atteindre 8 Go.[49]

Le système d'exploitation Raspbian OS

Raspbian OS, anciennement connu sous le nom de Raspbian, est un système d'exploitation gratuit basé sur Debian, conçu sur mesure pour les ordinateurs monocartes Raspberry Pi. Il est le choix par défaut pour une utilisation standard sur ces appareils.

Points forts de Raspbian OS :

- **Facilité d'installation** : Avec plus de 35 000 paquets logiciels préconfigurés et prêts à fonctionner directement, l'installation sur le Raspberry Pi est simple et rapide.
- **Optimisation continue** : Les développeurs de cet OS accordent beaucoup d'importance à l'amélioration constante de la stabilité et des performances, en optimisant la compatibilité maximale avec le matériel Raspberry Pi.
- **Environnement bureautique intuitif** : Le bureau PIXEL, basé sur LXDE, offre une interface conviviale et intuitive, facilitant la prise en main de l'appareil.
- **Polyvalence** : L'OS convient aussi bien à l'apprentissage, au développement, au multimédia ou à la domotique.
- **Communauté active** : Une communauté vaste et très active permet de toujours résoudre les problèmes et bugs de manière rapide.[47]

Pourquoi choisir le Raspberry pi ?

L'utilisation de la carte Raspberry Pi dans le domaine de l'agriculture présente un grand intérêt, notamment pour la détection des maladies des feuilles de tomates. Cette technologie offre des avantages considérables en termes de puissance de traitement, de connectivité, d'accessibilité et de portabilité, faisant d'elle un choix idéal pour les applications agricoles.

Avantages du Raspberry Pi

- **Puissance de traitement élevée** : La Raspberry Pi offre une puissance de calcul suffisante pour exécuter des algorithmes de traitement d'image complexes nécessaires à la détection des maladies des feuilles de tomates.
- **Connectivité étendue** : La carte dispose de diverses interfaces de connexion, permettant de relier divers capteurs, caméras et autres périphériques, favorisant ainsi la collecte et l'analyse des données.
- **Accessibilité** : Le prix abordable de la Raspberry Pi comparé aux ordinateurs la rend accessible à un large public d'utilisateurs, y compris les agriculteurs et les chercheurs.

- **Portabilité** : La taille compacte et la faible consommation d'énergie de la Raspberry Pi la rendent facilement transportable et installable dans différents environnements agricoles.
- **Détection en temps réel** : La combinaison de la puissance de traitement et de la connectivité de la Raspberry Pi permet une analyse rapide des images des feuilles de tomates, permettant une détection des maladies en temps réel.
- **Surveillance continue** : La Raspberry Pi peut fonctionner en continu, permettant aux agriculteurs de capturer et analyser des images des feuilles à intervalles réguliers.
- **Flexibilité** : La portabilité de la Raspberry Pi permet de déployer le système de détection dans divers environnements agricoles, tels que les champs ouverts, les serres et les pépinières.[53]

3.5.2 Edge impulse

Edge Impulse est une plateforme en ligne qui simplifie grandement le développement et le déploiement d'applications d'apprentissage automatique sur des appareils embarqués. Elle offre une solution complète qui permet aux utilisateurs de :

- **Collecter des données** à partir de divers capteurs et sources, tels que les microphones, les accéléromètres, les gyroscopes, les caméras, etc.
- **Entraîner des modèles d'apprentissage automatique** puissants et précis à l'aide de techniques d'apprentissage optimisées pour les appareils embarqués tel que Raspberry Pi.
- **Déployer des modèles** sur une large gamme de périphériques embarqués, notamment les microcontrôleurs et les ordinateurs monocarte, en utilisant des formats de code optimisés tels que C, C++ et TensorFlow Lite (Python).

Edge Impulse propose une interface graphique web intuitive et une API puissante qui permettent aux utilisateurs de gérer l'ensemble du processus de développement, de la collecte de données au déploiement du modèle. La plateforme offre également des fonctionnalités supplémentaires telles que la visualisation des données à travers des graphes et la collaboration en équipe.[54]



FIGURE 3.16 – Logo d'Edge impulse

Pourquoi choisir Edge Impulse ?

1. Accessibilité à l'apprentissage automatique embarqué :

- Edge Impulse démocratise l'apprentissage automatique (ML) embarqué en le rendant accessible aux développeurs avec des connaissances ML limitées.
- Son objectif principal est de créer des solutions Tiny ML adaptées aux appareils à ressources limitées, élargissant l'applicabilité du ML embarqué.

2. Flux de travail complet et intégré :

- Edge Impulse offre une plateforme complète pour gérer l'ensemble du processus de développement ML de bout en bout.
- Les utilisateurs peuvent collecter des données, entraîner et optimiser des modèles, évaluer leurs performances et déployer des modèles sur des appareils embarqués.
- Cela simplifie le flux de travail et accélère le processus.

3. Approche centrée sur les données :

- Edge Impulse met l'accent sur la collecte et l'analyse des données, éléments essentiels pour les projets ML.
- Il permet l'importation de données à partir de diverses sources, y compris les capteurs embarqués et les Datasets.

4. Aucun besoin d'expertise avancée en codage :

- Edge Impulse offre une interface qui ne requiert pas de compétences en programmation avancées.
- Il propose une variété de blocs de prétraitement et d'apprentissage optimisés, des architectures de réseaux neuronaux et des modèles pré-entraînés, simplifiant ainsi le processus de développement.

5. Support d'une large gamme de capteurs :

- Edge Impulse prend en charge une large gamme de capteurs, des accéléromètres et microphones aux caméras, ce qui le rend adaptable à une grande variété de projets et d'applications.

6. Communauté et ressources dynamiques :

- Edge Impulse bénéficie d'une communauté active et d'une documentation complète pour soutenir les utilisateurs dans leurs efforts de développement ML embarqué.
- Cette communauté dispose d'un forum pour l'échange de connaissances, la collaboration et l'assistance.[55]

3.6 Fonctionnement de la solution

Après avoir identifié les éléments clés de notre solution de détection des maladies des feuilles de tomate, nous aborderons maintenant brièvement son fonctionnement. Ce processus comprend plusieurs étapes clés :

1. Collecte des données :

- Acquisition d'un ensemble de données d'images de feuilles de tomate saines et malades provenant de la plateforme Kaggle.
- Ces images serviront de base à l'entraînement du modèle de détection des maladies.

2. Prétraitement des données :

- Les images brutes subissent un prétraitement pour les adapter au format requis par le modèle d'apprentissage automatique.
- Cela peut inclure le redimensionnement, la normalisation et la conversion en un format compatible.

3. Entraînement du modèle :

- Utilisation de la plateforme Edge Impulse pour entraîner un modèle de détection des maladies des feuilles de tomate sur les images prétraitées.
- Le modèle apprend à distinguer les caractéristiques des feuilles saines et malades à partir d'exemples étiquetés (labellisés).

4. Évaluation et ajustement :

- Mesure de la précision et de l'efficacité du modèle.

- Ajustement potentiel du modèle en fonction des résultats de l'évaluation, en ajoutant des données d'entraînement ou en optimisant les paramètres.

5. Déploiement du modèle :

- Transfert du modèle entraîné sur la Raspberry Pi via Edge Impulse.
- Le modèle déployé permet une détection des maladies en temps réel directement sur le terrain, sans connexion internet.

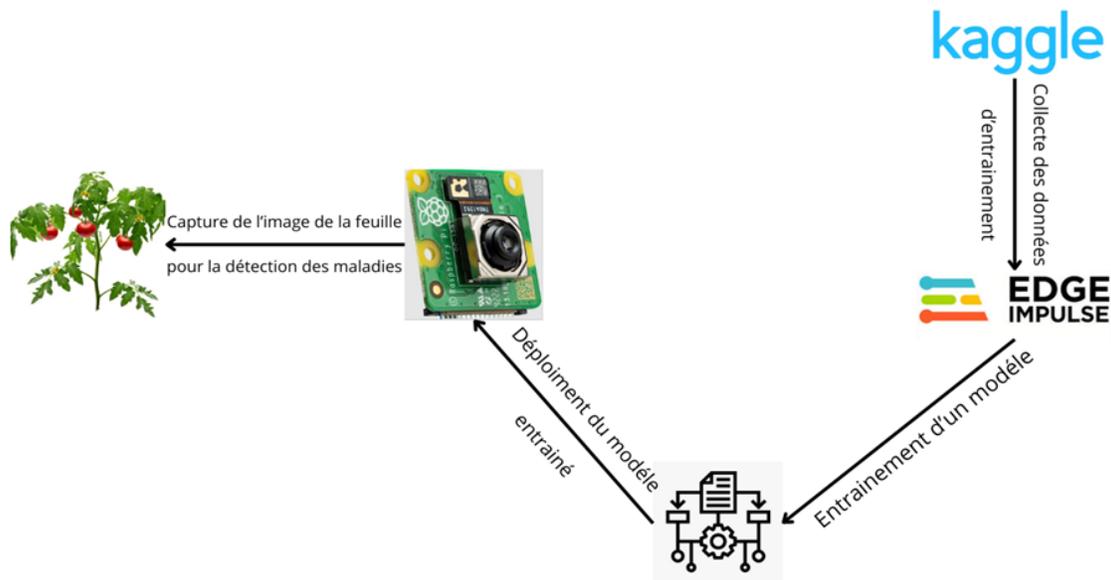


FIGURE 3.17 – Schéma de fonctionnement de la solution.

Conclusion

Ce chapitre a permis de mettre en évidence les choix des technologies de notre solution pour la détection des maladies des feuilles de tomates. En explorant le Tiny Machine Learning, la Raspberry Pi et Edge Impulse, nous avons exploré l'importance de chaque élément dans la conception et la mise en œuvre de notre solution. Ces technologies ont été sélectionnées pour leurs avantages spécifiques, offrant une combinaison puissante de traitement des données et de facilité de développement. Avec ces éléments, nous allons poursuivre vers la mise en œuvre pratique de notre

Solution proposée

solution dans le chapitre suivant, où nous détaillerons son fonctionnement concret et ses performances.

Chapitre 4

Mise en oeuvre et réalisation

Introduction

Dans ce chapitre, nous allons explorer le processus d'utilisation d'un modèle d'apprentissage automatique pour la classification des maladies des feuilles de tomate en utilisant la plateforme Edge Impulse. Cette démarche inclut la création et l'entraînement d'un modèle de réseau de neurones, ainsi que le déploiement du modèle sur une carte Raspberry Pi. Nous détaillerons chaque étape afin de mettre en lumière la manière dont Edge Impulse simplifie le processus de développement de solutions d'intelligence artificielle embarquée.

4.1 Création d'un Compte Edge Impulse et Démarrage d'un Nouveau Projet

Pour commencer le développement d'un modèle d'apprentissage automatique avec Edge Impulse, il est nécessaire de créer un compte sur la plateforme. Une fois inscrit, la première étape consiste à démarrer un nouveau projet. La figure ci-dessous illustre l'interface de travail de la plateforme.

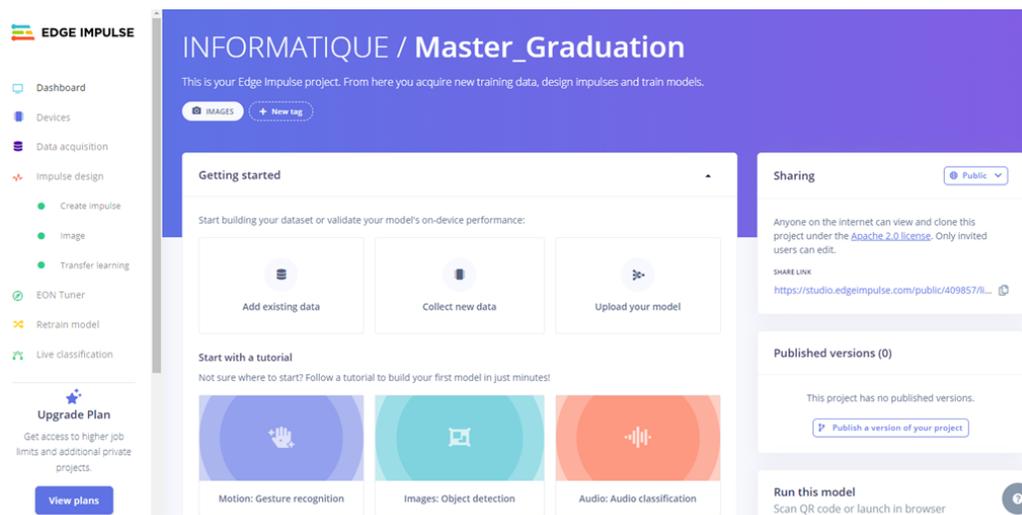
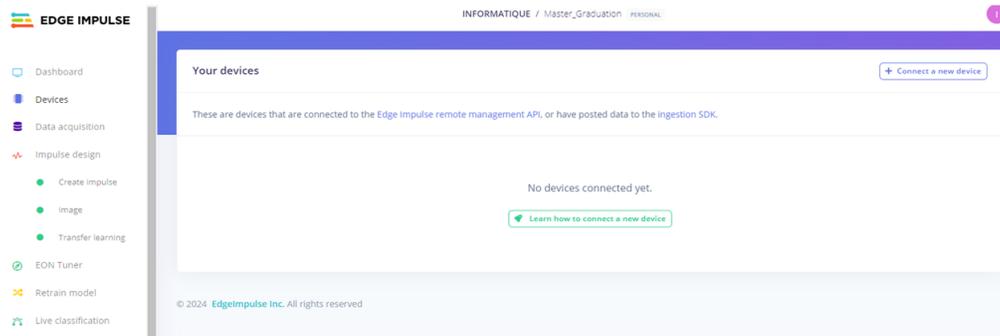


FIGURE 4.1 – Vue de l'interface utilisateur de la plateforme Edge Impulse.



Les données peuvent être collectées en connectant un appareil mobile, une carte Raspberry Pi ou toute autre machine à notre compte Edge Impulse, simplement en cliquant sur "Devices" puis « Connect a new device ».

4.2 Collecte de Données (Data acquisition)

Dans cette étape, nous avons collecté les données d'entraînement et de test nécessaires à l'entraînement et à la validation du modèle.

Pour ce faire, nous avons utilisé un dataset provenant de Kaggle, qui contient des échantillons de feuilles saines et malades, répartis en quatre classes : trois correspondant à des maladies différentes et une à des feuilles saines.

Le dataset original comprenait 1000 images par classe pour les données d'entraînement et 100 images par classe pour les données de test. Nous avons modifié ce dataset en réduisant le nombre d'images d'entraînement à 500 par classe pour garantir un équilibre avec les données de test. Pour maintenir une répartition de 80 % pour l'entraînement et 20 % pour la validation, nous avons utilisé 500 images par classe pour l'entraînement et 100 images par classe pour la validation, afin qu'on puisse avoir une bonne classification.

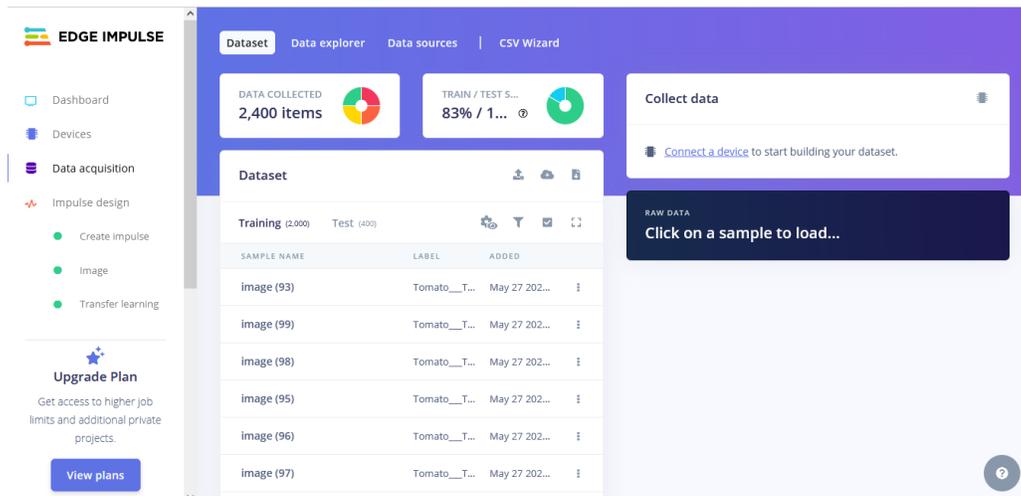


FIGURE 4.2 – Collecte des données d’entraînement et de test

4.3 Choix d’un modèle d’entraînement

Dans cette étape, nous avons commencé à choisir un bloc de traitement et un modèle d’entraînement. Pour démarrer, dans la section "Create Impulse" nous avons cliqué sur "Ajouter un bloc de traitement". Ensuite, en appuyant sur le bouton "Ajouter" à côté du bloc "Image", nous avons ajouté un bloc pour traiter les images. Ce bloc améliorera la qualité des couleurs ainsi que le contraste et la luminosité. Nous avons choisi une taille de 96x96 pixels pour les images utilisées, cette dimension étant suffisante pour un modèle d’entraînement de classification d’images d’après ce que nous avons trouvé dans la littérature. Ensuite, nous avons choisi le bloc "Transfer Learning" pour obtenir un modèle déjà prêt à reconnaître des images. Nous avons utilisé ce modèle afin d’effectuer un apprentissage par transfert pour l’adapter à notre tâche de reconnaissance des feuilles de tomate. Enfin, nous avons sauvegardé tout notre travail en cliquant sur "Save Impulse".

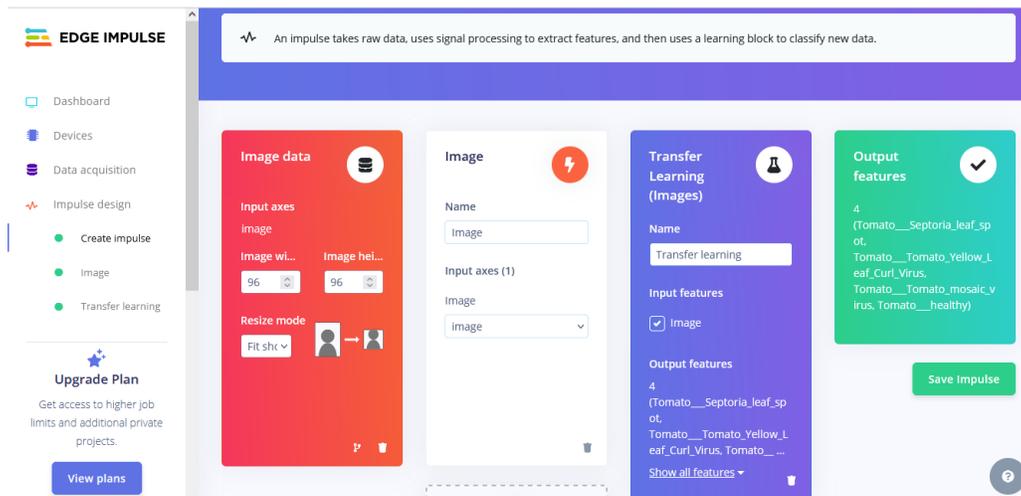


FIGURE 4.3 – Pré-entraînement du modèle

4.4 Extraction des caractéristiques

Une caractéristique est une propriété ou un aspect spécifique d’une image qui peut être utilisé pour identifier, analyser ou classifier le contenu de l’image. Les caractéristiques sont des représentations essentielles des données brutes, permettant aux modèles d’IA de comprendre et de traiter les informations pour pouvoir différencier les images entre elles.

Le graphe généré représente les caractéristiques extraites à partir des données d’entraînement. Chaque échantillon d’image est représenté par un ensemble de caractéristiques qui le distinguent des autres échantillons. Cependant, nous observons également des zones de chevauchement entre les différentes classes d’échantillons, où certaines caractéristiques se ressemblent. Ce chevauchement indique que certaines propriétés visuelles peuvent être communes à plusieurs types d’échantillons. Par exemple, certaines caractéristiques associées à des feuilles saines peuvent également être présentes dans les échantillons affectés par des maladies.

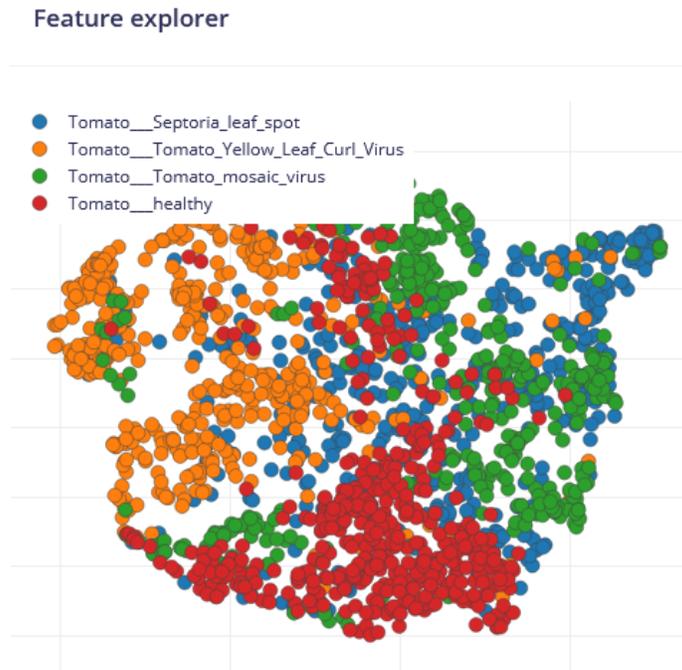


FIGURE 4.4 – Graphe représentant l’Exploration des Caractéristiques.

Grâce à ce graphe nous avons pu visualiser les différences entre les objets classés. Il offre une visualisation de la distribution des caractéristiques pour quatre échantillons d’images distincts, où chaque couleur correspond à un type spécifique d’échantillon.

4.5 Entraînement des modèles

Après l’importation et le traitement des données, nous allons commencer à entraîner le réseau de neurones pour reconnaître les motifs dans les données. Pour entraîner le réseau de neurones pour l’apprentissage par transfert, nous avons utilisé ces paramètres :

- **Nombre de cycles de formation** : : 30, indique que le modèle passe 30 fois à travers les données d’entraînement pour ajuster le modèle. Plus ce nombre est élevé, plus le modèle a de chances d’apprendre des données d’entraînement, mais cela peut conduire à un surapprentissage.
- **Taux d’apprentissage** : 0,0005.

- **Augmentation des données** : désactivée, ce qui signifie que nous n'utilisons pas de techniques pour augmenter artificiellement la taille du dataset d'entraînement.

Notre modèle a une couche d'entrée (input layer) de 27648 neurones, correspondant aux caractéristiques extraites de chaque image de 96x96 pixels avec 3 canaux de couleur (RGB) ($96 \times 96 \times 3 = 27648$), et une couche de sortie (output layer) de 4 neurones, représentant les quatre classes de feuilles de tomates : feuilles saines, et celles affectées par trois différentes maladies.

- **Modèles du réseau de neurones utilisé** :
 - MobileNetV2 96x96 0.35.
 - MobileNetV1 96 x 96 0.2.
 - MobileNetV1 96 x 96 0.25.

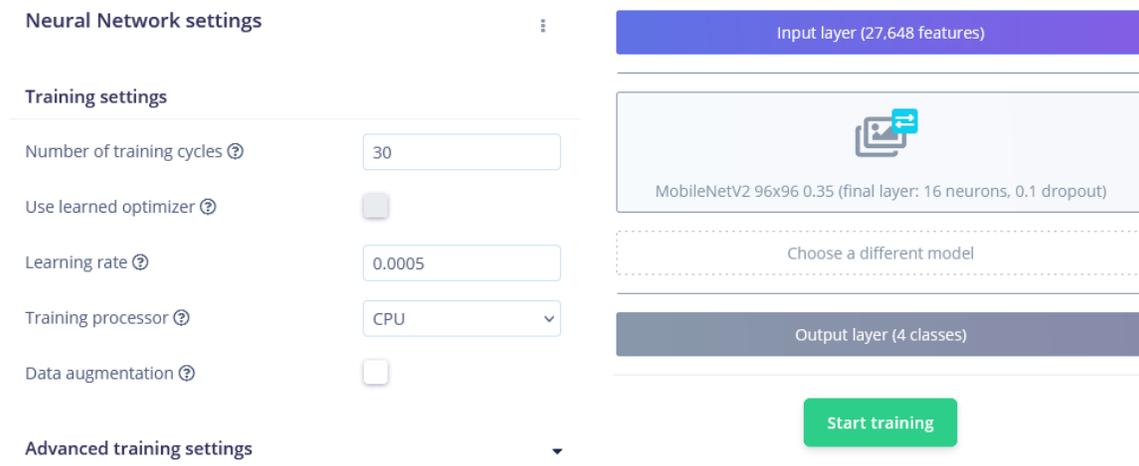


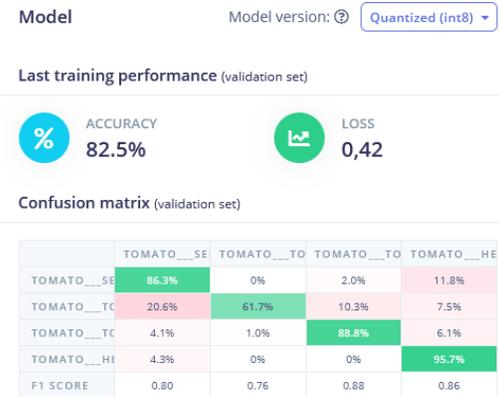
FIGURE 4.5 – Configuration du Réseau de Neurones.

En lançant l'entraînement avec le bouton « Start training », le réseau de neurones commencera à traiter toutes les images pour générer le modèle d'apprentissage automatique.

MobileNetV2 96*96 0.35



MobileNetV1 96*96 0.25



MobileNetV1 0.2

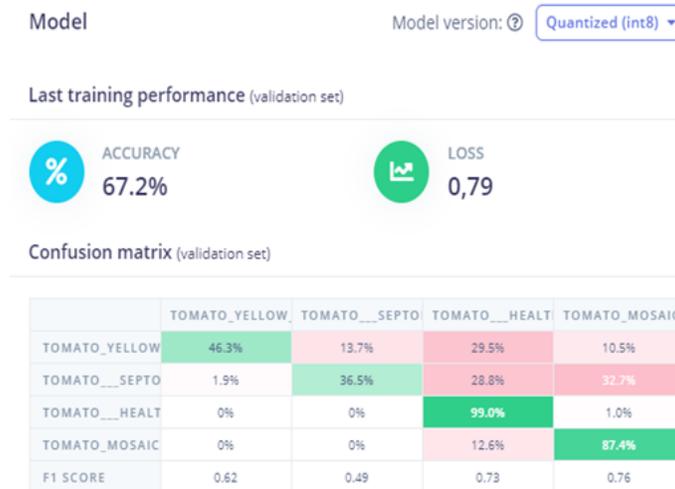


FIGURE 4.6 – Matrices de confusion

Une fois l'entraînement achevé, nous constatons une précision de 96.0%, accompagnée d'une perte de 0,11 avec le modèle MobileNetV2 96x96 0.35, et une précision de 82.5% et une perte de 0.42 avec le modèle MobileNetV1 96x96 0.25 Tandis que MobileNetV1 96x96 0.2 a atteint une précision de 67.2% et une perte de 0.79.

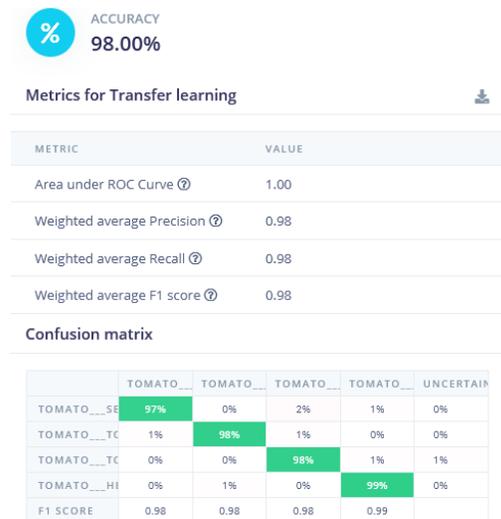
Ces matrices de confusion indiquent le pourcentage de précision offert par les modèles de réseau de neurones MobileNetV2 96x96 0.35, MobileNetV1 96x96 0.2 et MobileNetV1 96x96 0.25. Les pourcentages obtenus reflètent la performance de ces modèles sur les données d'entraînement, avec une validation croisée intégrée.

La validation croisée est une technique où le dataset d'entraînement est divisé en plusieurs sous-ensembles. Le modèle est ensuite formé et validé plusieurs fois, chaque sous-ensemble étant utilisé une fois comme ensemble de validation, permettant ainsi d'estimer plus précisément la performance du modèle sur des données qu'il n'a pas vues pendant l'entraînement direct.

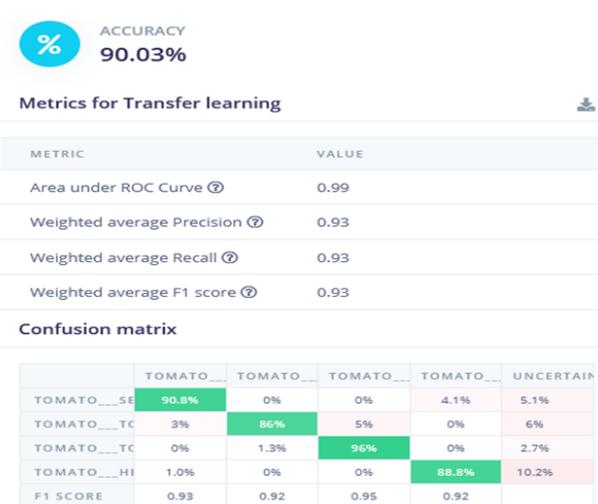
4.6 Test des modèles

Pour évaluer les performances des modèles, nous avons réservé 20% des données pour les tests lors de l'acquisition des données. Ces données de test, distinctes des données d'entraînement, permettent de vérifier la capacité des modèles à généraliser sur des données nouvelles et non vues précédemment. En utilisant cette partition de test, nous avons pu mesurer la précision réelle des modèles.

MobileNetV2 96*96 0.35



MobileNetV1 96*96 0.25



MobileNetV1 96*96 0.2

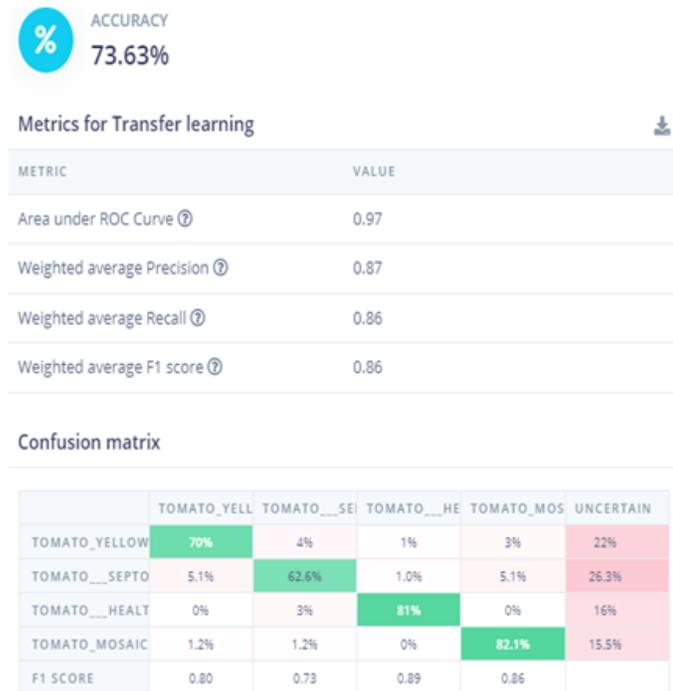


FIGURE 4.7 – Résultat de test des modèles

Lors de cette étape, le modèle MobileNetV2 0.35 a atteint une précision de 98.00%, tandis que le modèle MobileNetV1 0.25 n'a obtenu que 90.03%. De plus, nous avons également évalué le modèle MobileNetV1 96x96 0.2, qui a enregistré une précision de 73.63%. Cette différence significative de précision entre ces trois modèles pourrait justifier le choix du modèle MobileNetV2 0.35, qui offre une meilleure exactitude et réduit les erreurs de classification par rapport aux autres modèles évalués, confirmant ainsi que le MobileNetV2 0.35 est la meilleure option en termes de performances et de capacité d'adaptation aux nouvelles données.

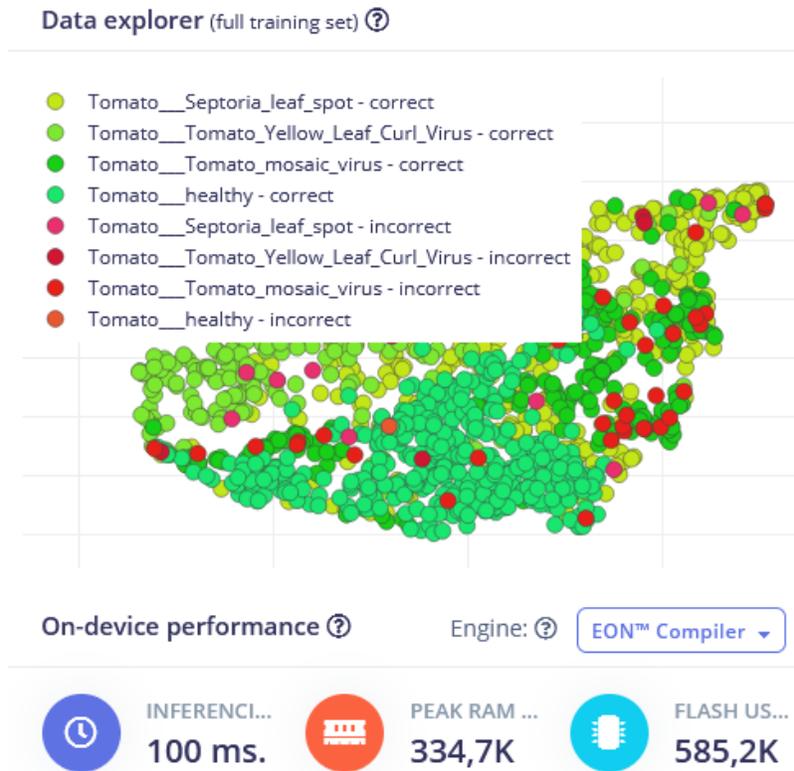


FIGURE 4.8 – Explorateur de caractéristiques du MobileNetV2 0.35.

Les résultats montrent que notre modèle choisit, avec un réseau de 16 couches, a effectué le traitement des données en 100 ms. Ce processus a été réalisé avec une consommation de mémoire vive (RAM) atteignant 334,7 Ko et une utilisation de la mémoire flash évaluée à 585,2 Ko.

Fonctions principales du modèle MobileNetV2

Les fonctions principales du code source du modèle de classification d'images MobileNetV2 sont les suivantes :

- **MobileNetV2()** : Cette fonction principale est responsable de la création de l'architecture complète du modèle MobileNetV2. Elle prend en compte divers arguments tels que l'adaptation à la taille d'entrée des images en pixels, le facteur d'échelle (alpha) qui contrôle la largeur du réseau de neurones, et d'autres

options de configuration du modèle.

- **Preprocess_input(x, kwargs)** : Cette fonction est responsable du prétraitement des données d'entrée. Elle normalise les valeurs des pixels et redimensionne les images pour les adapter à l'entrée du modèle. Cela garantit que les données sont dans un format approprié pour être utilisées par le réseau de neurones.
- **_make_divisible(v, divisor, min_value=None)** : Cette fonction est utilisée pour s'assurer que le nombre de canaux dans chaque couche du modèle est divisible par 8. Cela est nécessaire pour maintenir la compatibilité avec l'architecture spécifique de MobileNetV2. MobileNetV2 est spécifiquement conçu avec cette contrainte de diviseur de 8 pour assurer une exécution efficace sur une variété de plateformes matérielles (comme TensorFlow et Edge Impulse). En respectant cette contrainte, la fonction `_make_divisible` garantit que le modèle final résultant sera pleinement compatible avec l'architecture MobileNetV2.
- **_inverted_res_block**, cette fonction construit l'architecture du réseau en empilant plusieurs blocs. Chaque bloc réalise des convolutions (pour filtrer les informations) et des projections (pour changer la dimension des données). Cela permet d'adapter les données pour le traitement et de rendre le réseau plus dense (contenant plus d'informations utiles et moins d'informations inutiles) tout en restant efficace en termes de calcul (traitant les données rapidement avec moins de puissance informatique).

4.7 Live classification

Dans cette étape, nous utilisons une nouvelle image capturée à l'aide de la caméra de Raspberry Pi pour une classification en direct. L'objectif de cette étape est donc de montrer au modèle une image qu'il n'a jamais vu auparavant et de voir s'il pourra la classer. Notre modèle a pu classer l'image avec succès en tant que feuille infectée par le `Tomato_Yellow_Leaf_Curl_Virus`.

CATEGORY	COUNT
Tomato__Septoria_leaf_spot	0
Tomato__Tomato_Yellow_Leaf_Curl_Virus	1
Tomato__Tomato_mosaic_virus	0
Tomato__healthy	0
uncertain	0

Detailed result Show only unknowns

TOMATO__SE...	TOMATO__TOMA...	TOMATO__TOMA...	TOMATO__HE...
0	1.00	0	0

FIGURE 4.9 – Taux de précision

4.8 Déploiement du modèle sur Raspberry Pi

Après avoir validé l'efficacité de notre modèle avec un taux de précision de 98% sur des images non vues, nous avons déployé ce modèle sur une carte Raspberry Pi. Cette étape nous permet de tester notre système en conditions réelles, en utilisant la Raspberry Pi pour capturer et classer des images de feuilles de tomate en temps réel.

Étapes de déploiement du modèle

Pour déployer le modèle de classification sur une carte Raspberry Pi pour des classifications en temps réel, il est important de suivre certaines étapes pour s'assurer que tout fonctionne correctement :

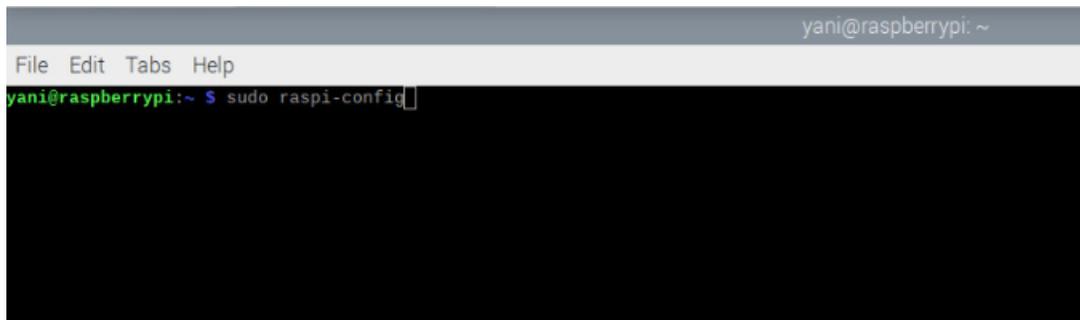
1. Préparation de la Raspberry Pi :

- Installation d'un système d'exploitation sur notre carte SD et l'insérer dans la Raspberry Pi.
- Connexion de la Raspberry Pi à un moniteur, un clavier, et une souris.
- Alimentation de la Raspberry Pi et la connecter à internet (via Ethernet ou Wi-Fi).

2. Configuration de la caméra :

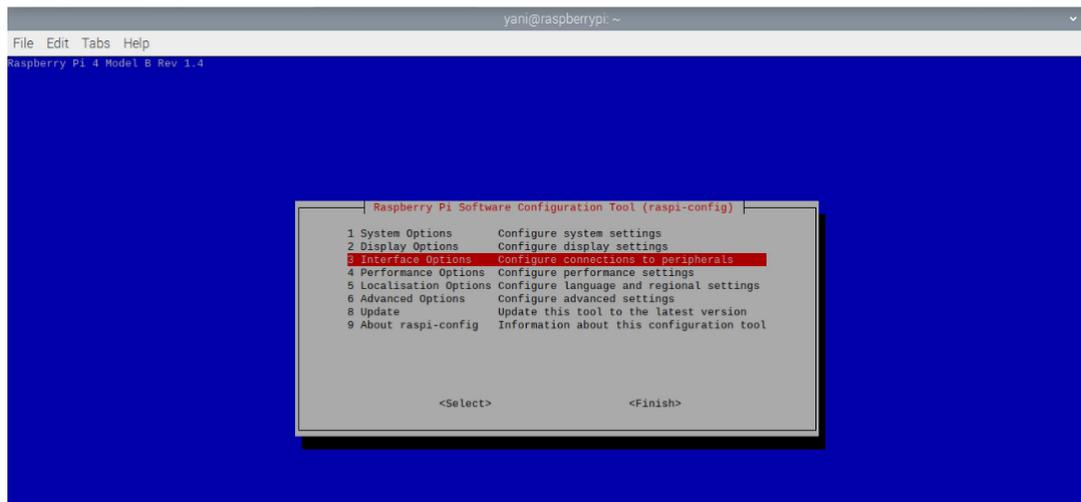
- Connexion de la caméra au port CSI (Camera Serial Interface) de la Raspberry Pi.
- Activation de la caméra en exécutant la commande suivante dans le terminal :

sudo raspi-config

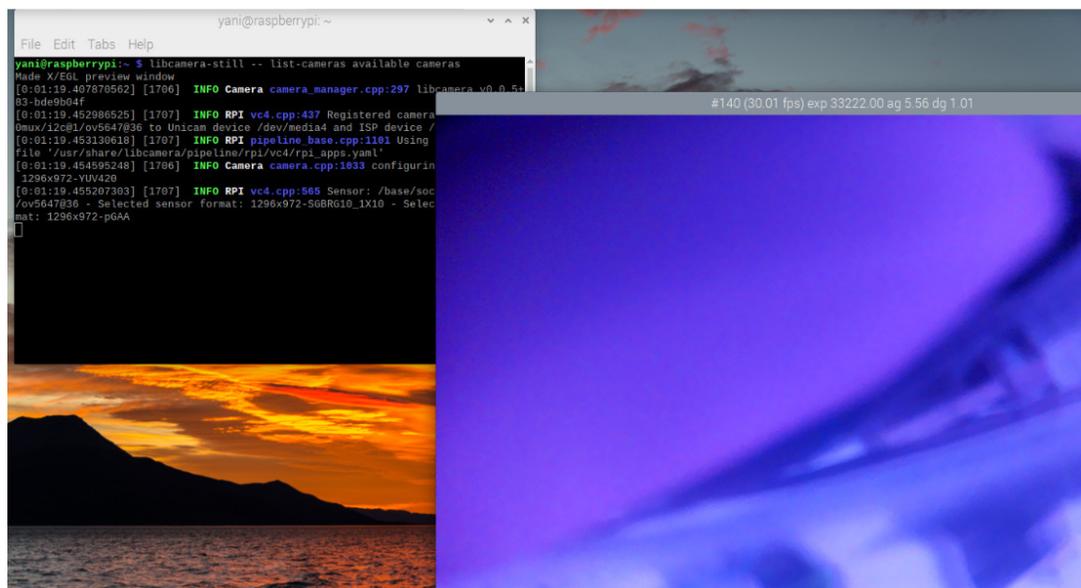


```
yani@raspberrypi: ~
File Edit Tabs Help
yani@raspberrypi:~ $ sudo raspi-config
```

Dans le menu qui s'affiche, sélection de "Interface Options", puis "Camera", et activation de celle-ci. Redémarrage de la Raspberry Pi si nécessaire.



Ensuite, test de la caméra pour s'assurer de son bon fonctionnement en utilisant la commande suivante : **libcamera-still --list-cameras available cameras**. Cette commande permet de lister toutes les caméras disponibles. Une fois exécutée, une fenêtre s'ouvrira, affichant ce que la caméra capture. Si l'image apparaît, cela indique que la caméra fonctionne correctement.



3. Installation d'Edge Impulse CLI sur la Raspberry Pi :

Avant de commencer l'installation des paquets Node.js et npm, il est important de mettre à jour la liste des paquets disponibles sur la Raspberry Pi pour s'assurer d'avoir les dernières versions disponibles. Pour ce faire :

— Ouvrir un terminal et exécuter la commande :

sudo apt update

Cette commande télécharge les informations les plus récentes sur les paquets à partir des bases de données en ligne, mettant ainsi à jour la base de données locale. Cela garantit que le système connaît les versions les plus récentes des logiciels disponibles.

— Installation de Node.js 16.x

curl -sL https://deb.nodesource.com/setup_16.x | sudo bash -

Cette commande télécharge et exécute le script d'installation de NodeSource pour configurer le dossier pour Node.js 16.x. Cela permet d'ajouter le dossier NodeSource et de configurer notre système pour installer Node.js 16.x.

— Installation des paquets nécessaires :

sudo apt install -y gcc g++ make build-essential nodejs sox gstreamer1.0-tools gstreamer1.0-plugins-good gstreamer1.0-plugins-base gstreamer1.0-plugins-base-apps

Cette commande installe plusieurs paquets nécessaires pour compiler et exécuter des modèles d'apprentissage automatique sur la Raspberry Pi.

- Configuration et Installation de l'Edge Impulse CLI :

```
npm config set user root && sudo npm install edge-impulse-linux -g  
--unsafe-perm
```

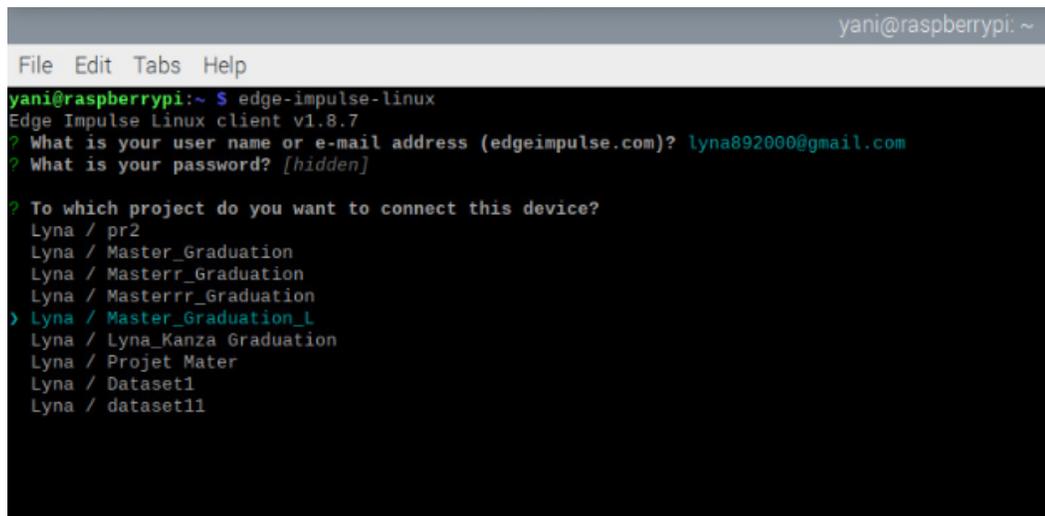
Cette commande configure npm pour éviter les problèmes de permissions lors de l'installation de paquets Edge Impulse, puis installe l'Edge Impulse CLI avec les permissions nécessaires.

4. Connexion de la Raspberry Pi à Edge Impulse :

- Connexion à un compte Edge Impulse depuis le navigateur.
- Exécution de la commande suivante dans le terminal pour lier l'appareil à Edge Impulse :

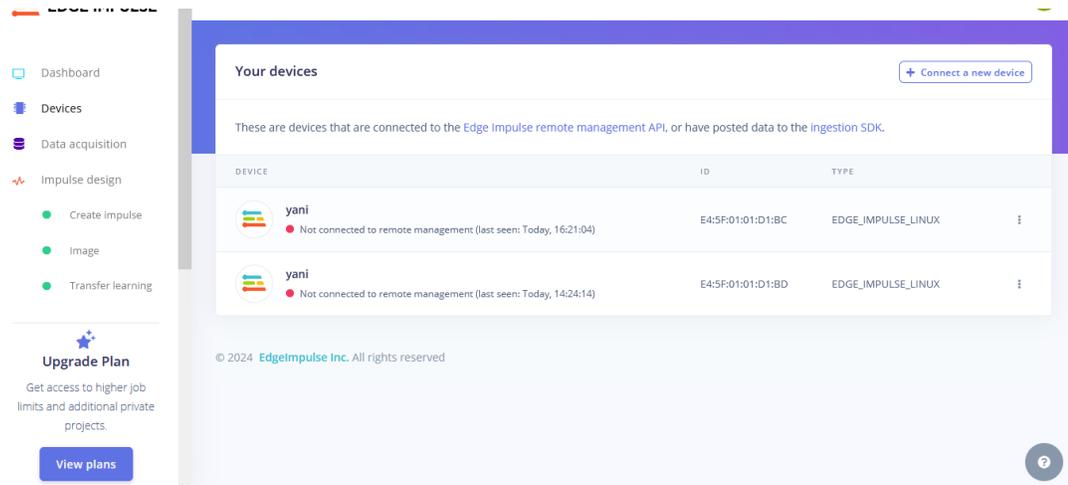
```
edge-impulse-linux
```

- Suivi des instructions à l'écran pour connecter la Raspberry Pi à un projet Edge Impulse.



```
yani@raspberrypi: ~  
File Edit Tabs Help  
yani@raspberrypi:~ $ edge-impulse-linux  
Edge Impulse Linux client v1.8.7  
? What is your user name or e-mail address (edgeimpulse.com)? lyna892000@gmail.com  
? What is your password? [hidden]  
  
? To which project do you want to connect this device?  
Lyna / pr2  
Lyna / Master_Graduation  
Lyna / Masterr_Graduation  
Lyna / Masterrr_Graduation  
? Lyna / Master_Graduation_L  
Lyna / Lyna_Kanza Graduation  
Lyna / Projet Mater  
Lyna / Dataset1  
Lyna / dataset11
```

Après avoir finalisé ces instructions, notre Raspberry Pi s'est affichée dans la section "Devices" (périphériques) d'Edge Impulse, confirmant sa connexion réussie.



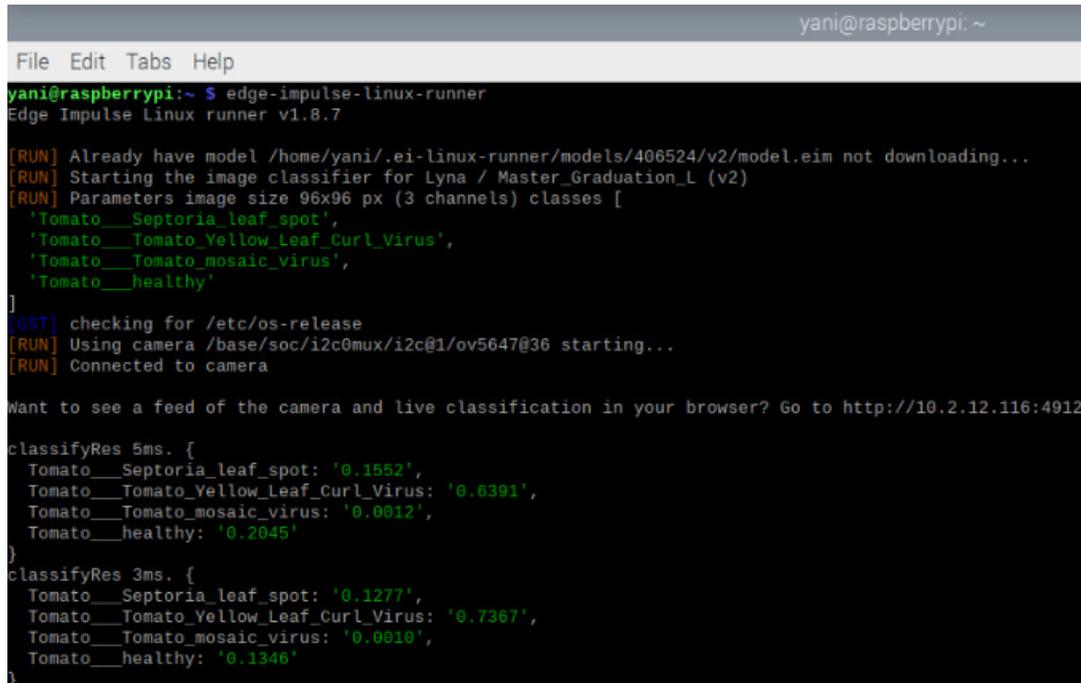
— Lancement de l'agent Edge Impulse avec le microphone désactivé :

```
yani@raspberrypi: ~  
File Edit Tabs Help  
yani@raspberrypi:~$ edge-impulse-linux --disable-microphone  
Edge Impulse Linux client v1.8.7  
[GST] checking for /etc/os-release  
[SER] Using camera /base/soc/i2c0mux/i2c@1/ov5647@36 starting...  
[SER] Connected to camera  
[WS ] Connecting to wss://remote-mgmt.edgeimpulse.com  
[WS ] Connected to wss://remote-mgmt.edgeimpulse.com  
[WS ] Device "yani" is now connected to project "Master_graduation_L". To connect to another project, run "edge-impulse-linux --clean".  
[WS ] Go to https://studio.edgeimpulse.com/studio/406524/acquisition/training to build your machine learning model!
```

Lors de lancement de cette commande, l'agent Edge Impulse détectera les capteurs disponibles (à l'exception du microphone). Dans notre cas, nous avons un seul capteur, qui est la caméra, donc il va détecter et initialiser automatiquement la caméra pour capturer des données visuelles.

5. Exécution du modèle sur la raspberry Pi

- Exécution de la commande "**edge-impulse-linux-runner**" pour exécuter le modèle de classification directement sur la carte Raspberry Pi.



```
yani@raspberrypi: ~
File Edit Tabs Help
yani@raspberrypi:~ $ edge-impulse-linux-runner
Edge Impulse Linux runner v1.8.7

[ RUN ] Already have model /home/yani/.ei-linux-runner/models/406524/v2/model.eim not downloading...
[ RUN ] Starting the image classifier for Lyna / Master_Graduation_L (v2)
[ RUN ] Parameters image size 96x96 px (3 channels) classes [
    'Tomato__Septoria_leaf_spot',
    'Tomato__Tomato_Yellow_Leaf_Curl_Virus',
    'Tomato__Tomato_mosaic_virus',
    'Tomato__healthy'
]
[ GST ] checking for /etc/os-release
[ RUN ] Using camera /base/soc/i2c0mux/i2c@1/ov5647@36 starting...
[ RUN ] Connected to camera

Want to see a feed of the camera and live classification in your browser? Go to http://10.2.12.116:4912

classifyRes 5ms. {
  Tomato__Septoria_leaf_spot: '0.1552',
  Tomato__Tomato_Yellow_Leaf_Curl_Virus: '0.6391',
  Tomato__Tomato_mosaic_virus: '0.0012',
  Tomato__healthy: '0.2045'
}
classifyRes 3ms. {
  Tomato__Septoria_leaf_spot: '0.1277',
  Tomato__Tomato_Yellow_Leaf_Curl_Virus: '0.7367',
  Tomato__Tomato_mosaic_virus: '0.0010',
  Tomato__healthy: '0.1346'
}
```

Conclusion

Ce chapitre a détaillé le processus complet d'entraînement et de déploiement de notre modèle de Classification. En utilisant les données d'entraînement provenant de Kaggle et en adoptant l'architecture MobileNetV2, nous avons obtenu une précision élevée de 98% sur les données de test. Le déploiement réussi de ce modèle sur une carte Raspberry Pi pour des classifications en temps réel montre non seulement la robustesse du modèle, mais aussi son potentiel pour des applications pratiques et embarquées.

Conclusion générale

Ce projet de fin de cycle a été une exploration enrichissante du domaine de l'intelligence artificielle embarquée, axée sur la résolution d'un problème vital dans l'agriculture. En se concentrant sur la classification des maladies des feuilles de tomate, nous avons exploité les avancées technologiques récentes pour développer une solution combinant Edge Impulse et Raspberry Pi.

À travers les différentes étapes de ce projet, de la collecte des données à l'entraînement du modèle et en passant par son déploiement sur la Raspberry pi, nous avons parcouru les étapes de collecte de données, d'entraînement du modèle et de déploiement sur la Raspberry Pi. Utiliser un dataset de Kaggle et l'architecture MobileNetV2 a été, nous le pensons, un choix judicieux, renforçant la performance de notre modèle.

Les résultats obtenus lors des tests ont été prometteurs, avec une précision de classification élevée de 98% lors de l'évaluation. De plus, le déploiement réussi du modèle sur une carte Raspberry Pi a ouvert la voie à des applications concrètes sur le terrain, offrant ainsi aux agriculteurs un outil pratique pour diagnostiquer et traiter les maladies des feuilles de tomate de manière efficace et proactive. Cette solution améliore non seulement la rapidité de la détection, mais réduit également les coûts et la dépendance aux experts des méthodes traditionnelles.

L'intégration de technologies avancées comme l'IA et l'apprentissage automatique dans l'agriculture offre des perspectives prometteuses pour la gestion des maladies des plantes, parmi elles nous citons : Augmentation de la diversité du dataset avec plus de maladies, développement d'une application mobile pour notre solution et enfin test sur le terrain avec un grand nombre de plantes différentes (la tomate et autres).

Bibliographie

- [1] SEDDIKI, D. Hamida aya ellah TIET, (2021). Valorisation des sous-produits de tomates (Doctoral dissertation), Université Mohamed El Bachir El Ibrahimi B.B.A.
- [2] Tomate industrielle : croissance de la production de 17% en 2021 ». (A.P.S. mardi 16 novembre 2021.17h27) consulté le 2 decembre 2023, <https://www.aps.dz/economie/130791-tomate-industrielle-croissance-de-la-production-de-17-en-2021>.
- [3] Soubre, Alain. 2022. Tomates : techniques de culture, choix des variétés, conseils d'entretien, cuisine et conservation. Broché – Illustré, 2 mars 2022. Éditions Eugen Ulmer. ISBN : 978-2800122569.
- [4] Ait Issad, H. (2020). Déploiement intelligent de drones pour une agriculture du futur (Doctoral dissertation, Université Mouloud Mammeri).
- [5] Hamza, A. A. (2010). Taxonomie et diagnostic des espèces de Xanthomonas associées à la gale bactérienne de la tomate et des Capsicum spp. : situation dans les Îles du Sud Ouest de l'océan Indien (Doctoral dissertation, Université de la Réunion).
- [6] Davis, R. Michael, Ken Pernezny, and Janet C. Broome. 2017. Tomato Health Management. 2nd Edition. APS PRESS (October 16, 2013). ISBN : 978-0890545010.
- [7] N'guettia Marie, Y., Amako Pauline, N., Marie Hélène, K.A., Senan, S., Drissa, K., & Boni Clovis, K.N. (2022). Controle Des Maladies De La Tomate (Solanum Lycopersicum L.) En Culture Avec Trois Extraits De Plantes A Daloa (Cote

- D'ivoire). European Scientific Journal, ESJ.
- [8] Dominique Blancard. June 2018. Tomato Diseases : Identification, Biology and Control : A Colour Handbook. 2nd Edition. CRC Press. ISBN : 978-1138034259.
- [9] NOUAR, R. (2020) Une approche d'apprentissage automatique pour la détection des maladies dans les fermes intelligentes, (Memoire master), Université Mohamed Khider – BISKRA
- [10] Tiendrebeogo, A., Bonzi, S., Dabiré, G. T., Son, D., Sanou, A., Kambire, H. S., ... & Legrève, A. (2023). Identification de mycètes cultivables associés aux maladies de la tomate au Burkina Faso. BASE.
- [11] Haiech, J. (2020). Parcourir l'histoire de l'intelligence artificielle, pour mieux la définir et la comprendre. médecine/sciences, 36(10), 919-923
- [12] Bouchelaghem, S. (2022). Télédétection aérienne des déchets de plastiques utilisant les images hyper-spectrales et l'apprentissage automatique, (Memoire mater), Université 8Mai 1945 – GUELMA.
- [13] YASSINE, M., FAROUK, R., Mansouria, S. E. K. K. A. L., & Eddine, B. C. (2023). PLANT DOCTOR Développement d'un système intelligent pour le diagnostic des maladies des plantes (Doctoral dissertation).
- [14] Abdellatif MOUSSAID, (2023) Intelligence Artificielle et Traitement D'images Satellites pour la Prédiction du Rendement et le Suivi des Cultures Arboricoles : Cas d'un Verger D'agrumes, Université Mohammed V de Rabat.
- [15] Durmus, H., Günes, E.O., & Kirci, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. 2017 6th International Conference on Agro-Geoinformatics, 1-5.
- [16] Hasan, M., Tanawala, B.A., & Patel, K.J. (2019). Deep Learning Precision Farming : Tomato Leaf Disease Detection by Transfer Learning. Computational Materials Science eJournal.

- [17] Tang, Z., He, X., Zhou, G., Chen, A., Wang, Y., Li, L., & Hu, Y. (2023). A Precise Image-Based Tomato Leaf Disease Detection Approach Using PLPNet. *Plant Phenomics*, 5.
- [18] Khan, A., Nawaz, U., Lochan, K., Seneviratne, L.D., & Hussain, I. (2023). Early and Accurate Detection of Tomato Leaf Diseases Using TomFormer. *2023 21st International Conference on Advanced Robotics (ICAR)*, 645-651.
- [19] Tian, Y., Zheng, P., & Shi, R. (2016). The Detection System for Greenhouse Tomato Disease Degree Based on Android Platform. *2016 3rd International Conference on Information Science and Control Engineering (ICISCE)*, 706-710.
- [20] Debnath, A., Hasan, M.M., Raihan, M., Samrat, N., Alsulami, M.M., Masud, M., & Bairagi, A.K. (2023). A Smartphone-Based Detection System for Tomato Leaf Disease Using EfficientNetV2B2 and Its Explainability with Artificial Intelligence (AI). *Sensors (Basel, Switzerland)*, 23.
- [21] Emebo, O., Fori, B., Victor, G., & Zannu, T. (2019). Development of Tomato Septoria Leaf Spot and Tomato Mosaic Diseases Detection Device Using Raspberry Pi and Deep Convolutional Neural Networks. *Journal of Physics : Conference Series*, 1299.
- [22] Aftab, S., Lal, C., Beejal, S.K., & Fatima, A. (2022). Raspberry Pi (Python AI) for Plant Disease Detection. *International Journal of Current Research and Review*.
- [23] Nagaraju, T., & Malleswari, B. (2021). Real-Time Agriculture Plant Leaf Monitoring and Disease Identification System using Raspberry Pi. *Mathematical Statistician and Engineering Applications*, 70(2), 382-399.
- [24] Al-Mashhadani, Z., & Chandrasekaran, B. (2021). ROS-based Robotic System for Tomato Disease and Ripeness Classification using Convolutional Neural Networks. *2021 IEEE 12th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, 0420-0427.
- [25] Sampoorna, C.K. (2020). Tomato Leaf Disease Detection using K-Means, SVM Classifier & Neural Networks. *International Journal of Recent Technology and*

Engineering.

- [26] Jia, S., Peiyi, J., Hu, S., & Haibo, S. (2017). Automatic detection of tomato diseases and pests based on leaf images. 2017 Chinese Automation Congress (CAC), 2537-2510.
- [27] Fuentes, A., Yoon, S., Kim, S.C., & Park, D.S. (2017). A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. Sensors (Basel, Switzerland), 17.
- [28] Chen, X., Zhou, G., Chen, A., Yi, J., Zhang, W., & Hu, Y. (2020). Identification of tomato leaf diseases based on combination of ABCK-BWTR and B-ARNet. Comput. Electron. Agric., 178, 105730.
- [29] Mokhtar, U., Ali, M.A., Hassenian, A.E., & Hefny, H.A. (2015). Tomato leaves diseases detection approach based on Support Vector Machines. 2015 11th International Computer Engineering Conference (ICENCO), 246-250.
- [30] Agarwal, M., Singh, A., Arjaria, S.K., Sinha, A., & Gupta, S.K. (2020). ToLeD : Tomato Leaf Disease Detection using Convolution Neural Network. Procedia Computer Science.
- [31] Huang, X., Chen, A., Zhou, G., Zhang, X., Wang, J., Peng, N., Yan, N., & Jiang, C. (2022). Tomato Leaf Disease Detection System Based on FC-SNDPN. Multimedia Tools and Applications, 82, 2121-2144.
- [32] Altuntas, Y., & Kocamaz, F. (2021). Deep Feature Extraction for Detection of Tomato Plant Diseases and Pests based on Leaf Images. Celal Bayar Universitesi Fen Bilimleri Dergisi.
- [33] Rahman, S.U., Alam, F., Ahmad, N., & Arshad, S. (2022). Image processing based system for the detection, identification and treatment of tomato leaf diseases. Multimedia Tools and Applications, 82, 9431-9445.
- [34] Roy, K., Chaudhuri, S.S., Frnda, J., Bandopadhyay, S., Ray, I.J., Banerjee, S., & Nedoma, J. (2023). Detection of Tomato Leaf Diseases for Agro-Based

- Industries Using Novel PCA DeepNet. *IEEE Access*, 11, 14983-15001.
- [35] Alzahrani, M.S., & Alsaade, F.W. (2023). Transform and Deep Learning Algorithms for the Early Detection and Recognition of Tomato Leaf Disease. *Agronomy*.
- [36] Ullah, Z., Alsubaie, N.M., Jamjoom, M.M., Alajmani, S.H., & Saleem, F. (2023). EffiMob-Net : A Deep Learning-Based Hybrid Model for Detection and Identification of Tomato Diseases Using Leaf Images. *Agriculture*.
- [37] Albahli, S., & Nawaz, M. (2022). DCNet : DenseNet-77-based CornerNet model for the tomato plant leaf disease detection and classification. *Frontiers in Plant Science*, 13.
- [38] Jeong, S., Jeong, S., & Bong, J.H. (2022). Detection of Tomato Leaf Miner Using Deep Neural Network. *Sensors (Basel, Switzerland)*, 22.
- [39] Eldrogi, N., Larroque, B., Bolliet, V., & Luthon, F. (2019, May). Computer vision for automatic detection and tracking of glass-eels. In *17e journées ORASIS*.
- [40] Manitsaris, S. (2022). Vision par ordinateur pour la reconnaissance des gestes musicaux des doigts. *Revue Francophone Informatique et Musique*.
- [41] Malciu, M. (2001). *Approches orientées modèle pour la capture des mouvements du visage en vision par ordinateur*.
- [42] Richard Szeliski(2023) *Computer Vision : Algorithms and Applications*, 2nd ed. 2022 édition (Cham : Springer Nature Switzerland AG, 2023).
- [43] Rahman, Mansib. 2017. *Beginning Microsoft Kinect for Windows SDK 2.0 : Motion and Depth Sensing for Natural User Interfaces*. Apress. ISBN : 978-1-4842-2315-4.
- [44] Gonzalez, Rafael C., and Richard E. Woods. 2017. *Digital Image Processing*. 4th Edition. Pearson. ISBN : 978-0133356724.

- [45] Iodice, Gian Marco. 2022. TinyML Cookbook : Combine artificial intelligence and ultra-low-power embedded devices to make the world smarter. Packt Publishing. ISBN : 978-1801814973.
- [46] Warden, Pete, and Daniel Situnayake. *TinyML : Machine Learning with TensorFlow on Arduino, and Ultra-Low Power Micro-Controllers*. Broché – 1 janvier 2020.
- [47] Jepson, Brian. 2023. The Official Raspberry Pi Beginner’s Guide, 5th Edition. Raspberry Pi Press. ISBN : 978-1912047727
- [48] Upton, Eben, Gareth Halfacree. 2016. Raspberry Pi User Guide, 4th Edition. Wiley. ISBN : 978-1-119-26866-3.
- [49] Tsiferana rabetokotany, « Un Raspberry pi 1 modèle B ou supérieur? », Raspberry Pi France (blog), 22 novembre 2022, <https://www.raspberrypi-france.fr/un-raspberry-pi-1-modele-b-ou-superieur/>.
- [50] Raspberry Pi Ltd, « Buy a Raspberry Pi », Raspberry Pi, consulté le 30 avril 2024, <https://www.raspberrypi.com/products/>.
- [51] GO TRONIC,« Carte Raspberry Pi Zero WH », GO TRONIC, consulté le 28 avril 2024, <https://www.gotronic.fr/art-carte-raspberry-pi-zero-wh-27670.htm>.
- [52] « Raspberry Pi Pico and Pico W-Raspberry Pi Documentation », consulté le 14 avril 2024, <https://www.raspberrypi.com/documentation/microcontrollers/raspberry-pi-pico.html>.
- [53] Jolles, J. W. (2021). Broad-scale applications of the Raspberry Pi : A review and guide for biologists. *Methods in Ecology and Evolution*, 12(9), 1562-1579.
- [54] Hymel, S., Banbury, C., Situnayake, D., Ellum, A., Ward, C., Kelcey, M., ... & Reddi, V. J. (2022). Edge impulse : An mlops platform for tiny machine learning. arXiv preprint arXiv :2212.03332.

- [55] « Getting Started | Edge Impulse Documentation », 21 mars 2024, <https://edge-impulse.gitbook.io/docs/>.

Résumé

De nos jours, la sécurité alimentaire joue un rôle clé dans l'avenir du pays, et garantir de bonnes productions agricoles devient nécessaire. Notre projet de fin d'études s'inscrit dans le domaine en plein essor de la classification d'images, un domaine crucial pour de nombreuses applications sensibles telles que les diagnostics médicaux, la surveillance et l'agriculture. Ce projet a exploré un domaine d'apprentissage automatique nommé « Tiny ML », qui est une forme de machine learning adaptée aux systèmes embarqués permettant l'exécution de modèle d'apprentissage automatique sur des appareils à faible puissance tel que la Raspberry Pi, nous l'avons utilisé dans notre projet afin de classer les maladies des feuilles de la tomate. Avec le choix d'Edge Impulse comme plateforme pour entraîner notre modèle de classification d'images. En combinant la puissance de Tiny ML et la facilité d'utilisation d'Edge Impulse, nous avons simplifié et optimisé le processus de développement de notre solution de surveillance agricole.

Mots clés : Intelligence Artificielle, Raspberry Pi, Détection de maladies, Traitement d'image. Internet des Objets.

Abstract

Nowadays, food security plays a key role in the country's future, and guaranteeing good agricultural production is becoming a necessity. Our project is part of the fast-growing field of image classification, a crucial area for many sensitive applications such as medical diagnostics, surveillance and agriculture. This project explored a field of machine learning called "Tiny ML", which is a form of machine learning adapted to embedded systems, enabling the execution of machine learning models on low-power devices such as the Raspberry Pi. We used it in our project to classify tomato leaf diseases. We chose Edge Impulse as the platform for training our image classification model. By combining the power of Tiny ML with the ease of use of Edge Impulse, we have simplified and optimized the development process of our agricultural monitoring solution.

Keywords : Artificial Intelligence, Raspberry Pi, Disease detection, Image processing. Internet of Things.