



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la
Recherche Scientifique
Université d'Abou Bakr Belkaïd – Tlemcen
Faculté des Sciences
Département d'Informatique



MÉMOIRE DE PROJET DE FIN D'ÉTUDES

En vue de l'obtention du diplôme de master en informatique

Spécialité : Modèle intelligent et de décision (M.I.D)

Thème : La détection des maladies des arbres par l'intelligence
artificielle

Présenté par : BENDIMERAD Youcef & BOUIZEM

Mohammed Rayane

Soutenu publiquement le 23 Juin 2024 devant le jury :

Dr. ABDELDJELIL Hanane	Présidente
Dr. BENMAHDI Meriem Bouchra	Examinatrice
Dr. FEKAR Riyadh	Expert
Dr. HADJILA Fethallah	Encadrant
Dr. DERRAZ Foued	Co-Encadrant

Année Universitaire : 2023 / 2024

Remerciements

Nous saisissons cette occasion pour exprimer notre profonde gratitude et nos sincères remerciements à nos encadrants de l'université de Tlemcen, Monsieur HADJILA Feth-Allah et Monsieur DERRAZ Foued, pour leurs précieux aides, soutiens et conseils ainsi que la confiance qu'ils nous ont accordée et qui nous a permis de multiplier nos efforts pour être à la hauteur et mener à bien la réalisation de ce projet.

Aussi, nous tenons à remercier vivement les membres du Jury de l'université de Tlemcen, Madame ABDELJELIL, Madame BENMAHDI et Monsieur FEKAR, qui ont accepté de juger ce travail par leurs précieuses critiques, remarques et expertises.

Des remerciements particuliers sont adressés aux membres du laboratoire de Télécommunications LTT pour leur contribution : Messieurs MERIAH S.M. (Directeur), BENDIMERAD F.T., BOUSAHLA M., ABDELLAOUI G., MEGNAFI H. et Madame BENDAHMANE Z. (Ingénieur du LTT), ainsi qu'à Monsieur BOUIZEM M. de l'université de Tlemcen.

Dédicaces

Je tiens à exprimer ma gratitude la plus profonde et la plus émotive à mes parents, dont le soutien indéfectible et l'amour inconditionnel ont été les fondements de mon succès. Un merci tout particulier à mon père, dont les encouragements constants, les sages conseils et les sacrifices m'ont permis d'avancer, ainsi qu'à ma mère, dont la tendresse, la patience et le dévouement ont été une source de force inépuisable. Leur foi en moi et leur présence rassurante m'ont aidé à surmonter les moments difficiles et à persévérer dans mes efforts.

Merci également à mes deux petits frères, sources de joie et de motivation. Leur enthousiasme et leur énergie m'ont souvent rappelé l'importance de rester déterminé et optimiste.

Je dédie également ce travail à mon oncle, Monsieur ZAOUI Abdelkader, et à sa famille. Je leur exprime ma reconnaissance la plus sincère pour l'aide précieuse et le soutien inestimable qu'ils m'ont offerts. Leur bienveillance, leur générosité et leur amour ont été une véritable source d'inspiration et de force.

Mon oncle Abdelkader, par sa perspective unique et ses réflexions profondes, a changé ma manière de voir les choses, m'apportant ainsi une nouvelle vision et une approche renouvelée face aux défis. Sa présence bienveillante et ses encouragements constants m'ont profondément touché et motivé.

Que cette dédicace soit le témoignage de ma profonde reconnaissance envers tous ceux qui ont cru en moi et m'ont soutenu dans cette aventure.

Merci de tout cœur.

Mohammed Rayane B.

Dédicaces

A la mémoire de mes grands-parents paternels et maternels. Ces quelques lignes sont peu de choses pour remercier chaleureusement ma famille et tout particulièrement mes parents pour leurs nombreux sacrifices et pour m'avoir montré l'exemple. Merci à mon frère, à ma sœur et à son époux pour leurs encouragements et leur soutien.

J'adresse aussi ma gratitude à ma grande famille (oncles, tantes, cousins et cousines) pour leur affection et leur présence à mes côtés.

Enfin, je remercie mes amis et camarades pour tout ce que nous avons partagé ensemble, aussi pour leurs soutien et présence.

Youcef B.

Table des matières

Résumé	13
Abstract	14
المخلص	15
1 INTRODUCTION GENERALE	16
1.1 Contexte	16
1.2 Problématique	16
1.2.1 Diagnostique des maladies des arbres	17
1.2.2 Détection des arbres	18
1.2.3 Localisation des feuilles au niveau des arbres	18
1.2.4 Classification des maladies des arbres	18
1.3 Contribution	19
1.3.1 Partie logicielle	19
1.3.2 Partie matérielle	21
1.4 Plan de mémoire	22
2 Deep Learning	23
2.1 Introduction	23
2.2 Réseaux de neurones artificiels	23
2.2.1 Réseaux de neurones FeedForward (FNN)	24
2.2.2 Réseaux de neurones Récurrent (RNN) :	26
2.2.3 Réseaux neuronaux convolutifs (CNN)	27
2.2.4 Architecture de CNN	28
2.3 Principe de fonctionnement de CNN	28
2.4 Définition du modèle YOLO	31
2.4.1 L'avantage d'utilisation de YOLOv5	31

2.4.2	Principe de fonctionnement de YOLO	31
2.4.3	Architecture de YOLO	32
2.4.4	Importance de YOLO	33
2.4.5	Limitation de YOLO	34
2.5	Conclusion	34
3	Conception et réalisation du drone	35
3.1	Intoductuion	35
3.2	Matériel utilisé	35
3.2.1	Châssis	35
3.2.2	Moteurs Brushless	36
3.2.3	Contrôleurs de vitesse électroniques (ESC)	36
3.2.4	Hélices	37
3.2.5	Batterie	38
3.2.6	Distributeur d'alimentation	39
3.2.7	Émetteur radio pour système de transmission	39
3.2.8	Émetteur radio FPV	40
3.2.9	Contrôleur De Vol (Pixhawk)	40
3.2.10	Camera Stéréo	41
3.2.11	Module GPS	42
3.2.12	Kit de développement Jetson Nano	42
3.3	L'assemblage de drone	43
3.4	Calibration De Drone	44
3.4.1	Connexion de Mission Planner avec Pixhawk	44
3.4.2	Configuration de classe et de type de trame	44
3.4.3	Accelerometer Calibration	45
3.4.4	Compass Calibration	46
3.4.5	Télécommande radio Calibration	46
3.5	Conclusion	47
4	L'implémentation et Les résultats obtenus	48
4.1	Introduction	48
4.2	L'implémentation des composantes de notre système	48
4.2.1	Détection des arbres et des feuilles dans notre système	49

4.2.2	Datasets	49
4.3	Conception	50
4.3.1	Connexion entre jetson nano et le drone	50
4.3.2	Implémentation des modèles d'IA sur Jetson Nano	51
4.3.3	Serveur Django pour Interaction Utilisateur et Données du Drone	52
4.3.4	Modèles d'apprentissage profond	53
4.4	Procédure d'entraînement	56
4.4.1	Détection des arbres	56
4.4.2	Détection des feuilles	57
4.4.3	Classification des maladies des arbres	57
4.5	Mesures de performance	57
4.6	Résultat et discussion	59
4.6.1	Performances	59
4.7	Conclusion	68
5	Business Model Canvas	69
5.1	Introduction	69
5.2	Proposition de valeur	69
5.2.1	Quels problèmes résolvons-nous pour nos clients?	69
5.2.2	Quels besoins de nos clients satisfont nos produits ou services?	70
5.2.3	En quoi notre offre est-elle différente de celle de nos concurrents?	70
5.2.4	Quelle est notre proposition unique de valeur?	70
5.3	Segments de clients	71
5.3.1	Quels sont nos clients principaux?	71
5.3.2	Quels sont les différents segments de clients que nous visons?	71
5.3.3	Quels sont les besoins spécifiques de chaque segment de clients?	71
5.3.4	Comment pouvons-nous catégoriser nos clients en groupes distincts?	71
5.4	Relation avec les clients	72
5.4.1	Quel type de relation chaque segment de clients attend-il de nous?	72
5.4.2	Comment entretenons-nous actuellement les relations avec nos clients?	72
5.4.3	Comment pouvons-nous améliorer ou personnaliser nos interactions avec nos clients?	73
5.5	Canaux de distribution	73
5.5.1	Par quels canaux nos clients veulent-ils être atteints?	73

5.5.2	Quels canaux sont les plus efficaces pour atteindre chaque segment de clients?	73
5.5.3	Comment pouvons-nous intégrer différents canaux pour améliorer l'expérience client?	74
5.6	Partenaires clés	75
5.6.1	Qui sont nos partenaires clés?	75
5.6.2	Quels sont les partenariats qui nous aident à réduire les coûts, à accéder à de nouvelles ressources ou à améliorer notre proposition de valeur?	75
5.6.3	Comment pouvons-nous aligner nos intérêts avec ceux de nos partenaires?	76
5.7	Activités clés	76
5.7.1	Quelles sont les actions principales que nous devons entreprendre pour livrer notre proposition de valeur?	76
5.7.2	Quelles sont les opérations essentielles pour notre entreprise?	77
5.7.3	Quelles sont les activités qui créent le plus de valeur pour nos clients?	77
5.8	Ressources clés	78
5.8.1	Quels sont nos actifs matériels, immatériels et humains essentiels?	78
5.8.2	Quels sont les outils, les technologies ou les partenariats dont nous avons besoin pour réussir?	79
5.8.3	Quels sont les principaux avantages concurrentiels de nos ressources?	79
5.9	Charges et coûts	80
5.9.1	Quels sont les coûts fixes et variables associés à notre modèle économique?	80
5.9.2	Quels sont les coûts les plus importants pour notre entreprise?	80
5.9.3	Comment pouvons-nous réduire les coûts ou améliorer l'efficacité de nos opérations?	81
5.10	Revenus	81
5.10.1	Quels produits ou services nos clients sont-ils prêts à payer?	81
5.10.2	Quels sont les différents moyens par lesquels nous pouvons générer des revenus?	82
5.10.3	Quel est notre modèle de tarification?	82
5.11	Conclusion	82

Table des figures

2.1	Arborescence des Types de Réseaux de Neurones Profonds (DNNs).	24
2.2	Le processus d'opération de convolution [1].	29
2.3	Le processus d'opération de pooling [1].	30
2.4	La couche dense [2].	30
2.5	Architecture de YOLO [3].	33
3.1	Châssis [4].	36
3.2	Moteurs Brushless [5].	36
3.3	Contrôleurs de vitesse électroniques (ESC) [6].	37
3.4	RC Propellers CW 5x5 [7].	38
3.5	11.1V 3S 5200MAH/35C LIPO BATTERY [8].	39
3.6	Dual BEC 5V/12V PDB [9].	39
3.7	Émetteur radio pour système de transmission [10].	40
3.8	Émetteur radio FPV[10].	40
3.9	Contrôleur De Vol (Pixhawk) [11].	41
3.10	imx219 83 camera [12].	41
3.11	GPS Module [13].	42
3.12	Jetson Nano [14].	43
3.13	Schéma L'assemblage de drone [15].	43
3.14	Connexion de Mission Planner avec Pixhawk .	44
3.15	Etat connecté .	44
3.16	Choix du type [16].	45
3.17	Accelerometer Calibration.	45
3.18	Compass calibration [17].	46
3.19	Télécommande radio Calibration .	47
4.1	Schema de deroulement des tâches.	52

4.2	interface de connexion entre drone et serveur.	53
4.3	Exemple de détection d'arbres avec YOLOv5s	54
4.4	Exemple de détection de feuilles avec YOLOv5s.	55
4.5	Structure du model CNN proposé.	56
4.6	Courbes loss d'entraînement et de validation pour yolov5 detction d'arbre.	61
4.7	Courbes metrics n pour yolov5 detection d'arbre.	62
4.8	matrice de confusion pour yolov5 detction d'arbre.	63
4.9	Courbes loss d'entraînement et de validation pour yolov5 detction des feuilles.	64
4.10	Courbes metrics pour yolov5 detction des feuilles.	65
4.11	Matrice de confusion pour yolov5 detction des feuilles.	66
4.12	Courbes d'accuracy/loss d'entraînement et de validation pour CNN modèle.	66
4.13	matrice de confusion pour le modèle CNN.	67
5.1	Business Model Canvas	83

Liste des tableaux

4.1	Paramètres utilisés dans la phase d'entraînement pour la détection des arbres.	57
4.2	Paramètres utilisés dans la phase d'entraînement pour la détection des feuilles.	57
4.3	Paramètres utilisés dans la phase d'entraînement pour la classification des maladies. . .	57
4.4	Table des Résultats des Modèles de Détection et de Classification des Maladies des Plantes.	59

Liste d'abréviation

Intelligence Artificielle (IA)
Réseau de neurones convolutionnel (CNN)
You Only Look Once (YOLO)
Véhicule aérien sans pilote (UAV)
Deep learning (DL)
Réseau de neurone profond (DNN)
Réseau de neurone artificiel (ANN)
Réseau de neurone feedforward (FNN)
Réseau de neurone récurrent
Autoencodeurs Variationnels (VAE)
Gated Recurrent Units (GRU)
Long Short-Term Memory (LSTM)
Bidirectional LSTM (BLSTM)
Backpropagation Through Time (BPTT)
Deep Belief Networks (DBN)
Restricted Boltzmann Machines (RBM)
Réseau entièrement convolutif (FCN)
Réseau de neurone régional (R-CNN)
Rectified Linear Unit (ReLU)

Résumé

Ces dernières années, l'intelligence artificielle a émergé comme une révolution technologique dans divers domaines, y compris l'agriculture. L'utilisation de drones équipés de capteurs avancés et de techniques d'apprentissage automatique permet une surveillance précise des cultures, facilitant la détection précoce et le diagnostic des maladies des plantes.

Ce mémoire de master vise à améliorer la précision et l'efficacité de la détection des maladies des arbres en utilisant des réseaux neuronaux profonds, en exploitant spécifiquement des images capturées par des drones. Pour ce faire, nous avons utilisé des techniques d'apprentissage profond et avons examiné plusieurs modèles de réseaux neuronaux convolutionnels, notamment YOLO et CNN. Les résultats expérimentaux ont systématiquement démontré que les modèles YOLO ont réussi à accomplir les deux tâches de détection des arbres puis des feuilles avec une performance élevée.

D'autre part, le modèle CNN a montré une précision prometteuse de 90,64 %. Ces résultats font des modèles des choix fiables pour le suivi et la gestion des maladies des arbres à l'aide de drones.

Abstract

Récemment, l'intelligence artificielle a émergé comme une révolution technologique dans divers domaines, y compris l'agriculture. L'utilisation de drones équipés de capteurs avancés et de techniques d'apprentissage automatique permet une surveillance précise des cultures, facilitant la détection précoce et le diagnostic des maladies des plantes.

Ce mémoire de master vise à améliorer la précision et l'efficacité de la détection des maladies des arbres en utilisant des réseaux neuronaux profonds, en exploitant spécifiquement des images capturées par des drones. Pour ce faire, nous avons utilisé des techniques d'apprentissage profond et avons examiné plusieurs modèles de réseaux neuronaux convolutionnels, notamment YOLO et CNN. Les résultats expérimentaux ont systématiquement démontré que les modèles YOLO ont réussi à accomplir les deux tâches de détection des arbres puis des feuilles avec une performance élevée. Le modèle CNN a montré une précision prometteuse de 90,64

Ces résultats font de ces modèles des choix fiables pour le suivi et la gestion des maladies des arbres à l'aide de drones.

الملخص

في السنوات الأخيرة، ظهر الذكاء الاصطناعي كثورة تكنولوجية في مجالات مختلفة، بما في ذلك الزراعة. استخدام طائرات بدون طيار مزودة بأجهزة استشعار متقدمة وتقنيات التعلم الآلي تسمح برصد المحاصيل بدقة، وتسهيل الكشف المبكر عن الأمراض النباتية وتشخيصها. تهدف أطروحة الماجستير هذه إلى تحسين دقة وكفاءة مرض الأشجار الكشف باستخدام الشبكات العصبية العميقة، وتحديد الاستفادة من الصور التي تم التقاطها طائرات بدون طيار. لتحقيق ذلك، استخدمنا تقنيات التعلم العميق وفحصنا العديد من نماذج الشبكة العصبية التلافيفية، ولا سيما بو و ث نجحت بإنجاز المهام المزدوجة للكشف عن بوو أظهرت النتائج التجريبية باستمرار أن نماذج الأشجار والأوراق بدقة عالية.

من ناحية أخرى أظهر نموذج دقة واحدة بنسبة ٦٤.٩٠%. هذه تجعل النتائج هذه النماذج خيارات موثوقة لرصد وإدارة الأشجار الأمراض باستخدام الطائرات بدون طيار.

Chapitre 1

INTRODUCTION GENERALE

1.1 Contexte

Actuellement, le machine learning et même le deep learning sont largement étendus avec l'avènement de l'informatique embarquée et de l'internet des objets. En particulier, de nombreux problèmes peuvent être résolus en implémentant des concepts d'intelligence artificielle tels que la reconnaissance d'objets, la localisation d'objets, la détection d'objets et le suivi d'objets à l'aide de systèmes embarqués à faible coût et faible consommation de ressources de calcul.

Il est important de noter que ces programmes intelligents (intelligence ambiante) doivent satisfaire aux contraintes de la pénurie des ressources de calcul des objets embarqués. De plus, ces programmes doivent également respecter les contraintes de temps réel imposées et assurer un niveau acceptable de précision. Dans ce qui suit, nous montrons une application de l'intelligence ambiante dans le secteur de l'agriculture.

1.2 Problématique

L'utilisation de l'intelligence artificielle (IA) et des drones offre de nouvelles possibilités pour améliorer efficacement et économiquement la détection des maladies des arbres. En combinant des algorithmes avancés d'apprentissage automatique avec des technologies de capture d'images aériennes, il devient possible de surveiller les cultures à grande échelle et d'identifier rapidement les signes de maladies. Cela permet aux agriculteurs de prendre des mesures rapides et ciblées pour protéger leurs cultures.

De plus, l'utilisation de drones permet une collecte d'images plus rapide et plus précise par rapport aux méthodes traditionnelles, facilitant ainsi une détection précoce des problèmes de santé des arbres

et une intervention plus efficace. L'IA peut également analyser les images collectées pour fournir des informations détaillées sur l'état de santé des arbres. Cela permet aux agriculteurs de prendre des décisions éclairées pour gérer leurs cultures de manière plus durable.

Dans la prochaine étape, nous aborderons la manière d'observer et d'identifier les maladies des arbres, ainsi que les méthodes pour établir un diagnostic précis sur ces arbres [18].

1.2.1 Diagnostique des maladies des arbres

Les pommiers sont sujets à plusieurs maladies qui peuvent avoir un impact significatif sur leur santé et leur rendement, parmi les maladies les plus courantes, on trouve l'oïdium (powdery mildew) et la rouille (rust), qui sont des maladies fongiques particulièrement préoccupantes pour les cultivateurs de pommiers et c'est les plus répandues et les plus nuisibles [18].

Principaux types de maladies affectant les pommiers :

- L'oïdium : Cette maladie fongique se manifeste par un revêtement poudreux blanc sur les feuilles, les tiges et les fruits des pommiers. Elle peut entraîner la déformation des feuilles, la chute prématurée des fruits et une diminution du rendement [19].
- La rouille : La rouille est une autre maladie fongique courante qui affecte les pommiers. Elle se caractérise par l'apparition de taches rouges ou orangées sur les feuilles, causées par des spores de champignons. La rouille peut affaiblir l'arbre et réduire sa capacité à produire des fruits de qualité [19].

Ces maladies peuvent avoir un impact dévastateur sur la santé et le rendement des arbres, ainsi que sur la production agricole globale. Ces maladies peuvent entraîner une réduction significative du rendement en affectant la taille, la qualité et la quantité des fruits produits. Les fruits infectés peuvent devenir déformés, tachetés ou pourris, ce qui diminue leur valeur marchande et leur attrait pour les consommateurs. Il est donc crucial pour les agriculteurs de mettre en place des stratégies efficaces de détection, de prévention et de gestion des maladies des pommiers pour protéger la santé et le rendement de leurs cultures. Cela peut inclure l'utilisation de méthodes de surveillance avancées, telles que l'IA et les drones, pour détecter les maladies à un stade précoce et prendre des mesures appropriées pour les contrôler. De plus, en utilisant ces technologies l'automatisation du diagnostic peut permettre une surveillance continue et à grande échelle des cultures, offrant aux agriculteurs des informations précieuses pour prendre des décisions éclairées sur la gestion de leurs cultures. Enfin, en réduisant le besoin d'interventions manuelles coûteuses et potentiellement invasives, l'automatisation du diagnostic peut contribuer à une agriculture plus durable et respectueuse de l'environnement.

1.2.2 Détection des arbres

Pour effectuer la tâche de détection des arbres dans un verger à l'aide de YOLO, il est nécessaire d'entraîner un modèle YOLO à reconnaître les caractéristiques visuelles des arbres.

Le modèle est alimenté avec un grand nombre d'images annotées où les arbres sont clairement identifiés. YOLO divise chaque image en une grille et prédit les boîtes englobantes et les classes d'objets pour chaque cellule de la grille en une seule passe du réseau.

En utilisant des techniques avancées de Deep Learning, le modèle YOLO apprend à extraire des caractéristiques discriminantes des arbres, comme leur forme, leur texture et leur couleur, pour les distinguer des autres éléments de l'image.

Une fois entraîné, le modèle YOLO peut être utilisé pour détecter automatiquement les arbres dans de nouvelles images, offrant ainsi une méthode précise et efficace pour surveiller les vergers et détecter les maladies ou les problèmes de croissance.

1.2.3 Localisation des feuilles au niveau des arbres

La localisation des feuilles sur les arbres d'un verger nécessite l'entraînement d'un modèle YOLO pour détecter précisément les feuilles dans une image. Ce processus implique de fournir au modèle un grand nombre d'images annotées où les feuilles sont clairement identifiées.

YOLO divise chaque image en une grille et prédit les boîtes englobantes ainsi que les classes d'objets pour chaque cellule de la grille en une seule passe du réseau.

En utilisant des techniques avancées de Deep Learning, le modèle YOLO apprend à extraire des caractéristiques spécifiques des feuilles, telles que leur forme, leur texture et leur couleur, pour les distinguer des autres éléments de l'image. Une fois entraîné, le modèle YOLO peut être déployé pour localiser automatiquement les feuilles dans de nouvelles images, offrant ainsi une méthode précise et efficace pour l'analyse des arbres et la gestion des cultures.

1.2.4 Classification des maladies des arbres

La classification des maladies des arbres visibles dans les feuilles d'un verger à l'aide d'un réseau de neurones convolutionnel (CNN) implique d'entraîner un modèle à identifier précisément les maladies à partir des caractéristiques visuelles des feuilles.

Pour ce faire, on alimente le modèle avec un ensemble de données étiquetées contenant des images de feuilles présentant différentes maladies, parmi lesquelles les plus connues sont l'oïdium et la rouille.

Le CNN apprend à reconnaître les caractéristiques distinctives des feuilles malades, telles que les taches, les décolorations et les motifs, en utilisant des couches de convolution et de pooling pour

extraire des informations significatives. Une fois entraîné, le modèle peut classifier automatiquement les maladies des arbres visibles dans les feuilles sur de nouvelles images, offrant ainsi une méthode précise et efficace pour diagnostiquer les problèmes de santé des arbres et prendre des mesures appropriées pour les traiter.

1.3 Contribution

Dans cette partie, nous allons explorer deux aspects essentiels étroitement liés qui nous permettent d'approfondir la partie logicielle et matérielle de notre projet.

1.3.1 Partie logicielle

Dans le cadre de ce projet, nous proposons une approche combinant deux modèles de Deep Learning pour résoudre la problématique de détection des maladies des arbres dans les vergers.

Nous utilisons le modèle YOLO pour détecter les arbres et les feuilles dans les images, ce qui permet une localisation précise des zones affectées.

Ensuite, nous employons un réseau de neurones convolutionnel (CNN) pour classifier les maladies identifiées, en se basant sur les caractéristiques visuelles des feuilles.

À chaque étape, nous décrirons les modèles de Deep Learning utilisés pour répondre à notre problématique.

1. Modèle pour la détection des arbres : Nous avons utilisé le modèle pré-entraîné YOLOv5 pour détecter les arbres à partir d'images capturées par un drone. YOLOv5 est un réseau de neurones convolutionnel conçu pour la détection d'objets en temps réel, offrant un bon compromis entre vitesse et précision.

Nous avons opté pour le modèle YOLOv5s en raison de sa légèreté et de sa rapidité, le rendant adapté à l'utilisation sur des systèmes embarqués comme le NVIDIA Jetson utilisé dans notre projet.

En utilisant YOLOv5s pré-entraîné sur le jeu de données Tree-Detection Dataset, nous avons pu détecter efficacement les arbres dans les images drone capturées. Cette détection des arbres constitue une étape cruciale de notre système, permettant d'identifier les zones de plantation potentiellement affectées par des maladies, nécessitant ensuite la détection des feuilles des arbres dans la prochaine étape.

L'utilisation du modèle YOLOv5s pré-entraîné nous a permis de bénéficier d'une solution de détection d'arbres rapide et précise, renforçant ainsi l'efficacité et la fiabilité de notre système

de détection des maladies des arbres par drone.

2. Modèle pour la détection des feuilles : Après avoir détecté les arbres dans notre projet, nous allons procéder à la détection des feuilles dans les arbres détectés.

Pour cela, nous utiliserons la même procédure en passant les images détectées par le premier modèle pour les traiter et extraire les feuilles. Ensuite, nous aurons une liste d'images de feuilles prêtes à être classifiées selon les maladies existantes.

L'utilisation du modèle YOLOv5 pré-entraîné sur le jeu de données PlantDoc dataset a permis une détection efficace des feuilles dans les images capturées par le drone.

Cette capacité de détection est cruciale pour identifier les zones des arbres potentiellement affectées par des maladies, facilitant ainsi la surveillance et la gestion de la santé des arbres.

3. Modèle pour la classification des maladies des arbres : Pour la classification des maladies des feuilles, nous avons développé un modèle CNN à partir de zéro afin de répondre aux besoins spécifiques de notre projet.

Ce modèle a été conçu pour classifier les feuilles en différentes catégories en fonction de leurs caractéristiques morphologiques et texturales, notamment pour déterminer si elles sont malades ou non, et si elles le sont, les classifier comme étant affectées par la rouille ou l'oïdium [19].

Notre modèle CNN est structuré en plusieurs couches, comprenant des couches de convolution pour extraire les caractéristiques des images de feuilles, des couches de pooling pour réduire la dimensionnalité en effectuant un sous-échantillonnage de l'image tout en conservant les informations essentielles, et des couches entièrement connectées pour la classification finale.

Nous avons également utilisé des techniques de régularisation telles que le dropout pour prévenir le sur-apprentissage.

Pour l'entraînement du modèle, nous avons utilisé un ensemble de données annotées de feuilles provenant du jeu de données Apple Leaf Disease sur Kaggle [20], qui contient environ 1710 images.

Cet ensemble de données a été divisé en ensembles d'entraînement, de validation et de test. Nous avons entraîné le modèle sur l'ensemble d'entraînement, ajusté les hyperparamètres en fonction des performances sur l'ensemble de validation, puis évalué les performances finales sur l'ensemble de test.

Notre modèle CNN a montré des performances prometteuses dans la classification des feuilles, avec une précision de 90 % sur l'ensemble de test.

Ces résultats démontrent l'efficacité de notre approche de classification des feuilles basée sur le CNN.

1.3.2 Partie matérielle

Parmi les composants utilisés dans ce projet nous pouvons citer trois composants qui sont cruciaux pour la conception de notre projet :

1. Drone : Le drone, également connu sous le nom de véhicule aérien sans pilote (UAV), est un aéronef télécommandé qui peut être contrôlé à distance à l'aide d'un dispositif de télécommande ou d'un ordinateur.

Les drones sont équipés de divers capteurs et technologies, tels que des caméras, des capteurs infrarouges et des systèmes GPS, qui leur permettent de collecter des données et d'accomplir diverses tâches telles que la surveillance, la cartographie et la photographie aérienne.

Dans le cadre de ce projet, les drones seront utilisés pour capturer des images des arbres, qui seront ensuite analysées à l'aide de l'intelligence artificielle pour détecter les maladies et évaluer la santé des arbres.

2. Carte NVIDIA Jetson : NVIDIA Jetson [14] est une plate-forme informatique embarquée conçue pour les applications d'intelligence artificielle et de traitement des données en temps réel.

Elle est équipée d'un processeur GPU NVIDIA de haute performance, de capacités de calcul parallèle avancées et de logiciels optimisés pour l'IA, ce qui en fait un choix idéal pour les applications nécessitant des performances élevées et une faible latence.

Dans le contexte de ce projet, NVIDIA Jetson sera utilisé pour analyser les images capturées par les drones afin de détecter les maladies des arbres et d'évaluer leur santé.

3. Caméra stéréo-depth : Une caméra de profondeur stéréo est un type de caméra qui utilise deux objectifs séparés pour capturer des images en trois dimensions.

En comparant les images capturées par chaque objectif, la caméra peut calculer la distance entre la caméra et les objets dans la scène, créant ainsi une carte de profondeur de la scène. Cette carte de profondeur peut être utilisée pour des applications telles que la vision par ordinateur, la réalité augmentée et la navigation autonome, où une perception précise de la profondeur est essentielle.

Dans le cadre de ce projet, une caméra de profondeur stéréo peut être utilisée pour aider à la détection des maladies des arbres en fournissant des informations tridimensionnelles sur la structure des arbres et les symptômes des maladies.

1.4 Plan de mémoire

Ce mémoire est organisé en quatre chapitres :

- Le premier chapitre « Introduction générale » décrit le contexte de notre projet et nous donne l'importance de fusion de l'IA et les systèmes embarqués afin de détecter les maladies des arbres d'une façon plus fiable.
- Le deuxième chapitre approfondit la partie DL utilisée dans notre projet, où nous discuterons des modèles utilisés pour assurer la détection et la classification des maladies des arbres.
- Le troisième chapitre abordera l'Internet des objets et l'importance des matériels utilisés pour le traitement des images capturées.
- le dernier chapitre fournira plus d'informations sur la conception de notre système intelligent et présentera les résultats obtenus, suivis de leur discussion.

Chapitre 2

Deep Learning

2.1 Introduction

Le deep learning (DL) est une branche de l'apprentissage automatique [21] et qui est principalement utilisé pour la classification d'images, détection d'objets [22] et traitement du langage naturel .

DL s'appuie sur l'utilisation de réseaux neuronaux artificiels profonds pour extraire des caractéristiques complexes et abstraites des images, permettant ainsi une détection précise des symptômes de la maladie [1].

En utilisant les techniques de l'apprentissage profond, ce projet vise à améliorer la précision et l'efficacité de la détection des maladies des arbres, ce qui peut contribuer à réduire les pertes de récoltes et à améliorer la gestion des cultures. DL est une branche de l'IA basé sur les réseaux de neurones artificiels qui sélectionnent automatiquement les fonctionnalités des données [1], pour cela dans ce chapitre nous explorerons en détail les réseaux de neurones artificiels et leur application dans la résolution de problèmes complexes.

2.2 Réseaux de neurones artificiels

Les réseaux de neurones profonds (DNN) sont une classe de réseaux de neurones artificiels (ANN) comprenant plusieurs couches entre les couches d'entrée et de sortie [23].

Conçus pour reconnaître des modèles dans des données complexes, ces réseaux ont révolutionné de nombreux domaines de l'IA, notamment la reconnaissance d'images et de la parole [24].

Les DNN peuvent être divisés en deux principaux types : les réseaux de neurones feedforward (FNN) et les réseaux de neurones récurrents (RNN). Chacun de ces types peut être classé selon les

paradigmes d'apprentissage qu'ils utilisent, tels que l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

Nous présentons ci-dessous ces catégories et leurs types de réseaux dans la figure 2.1.

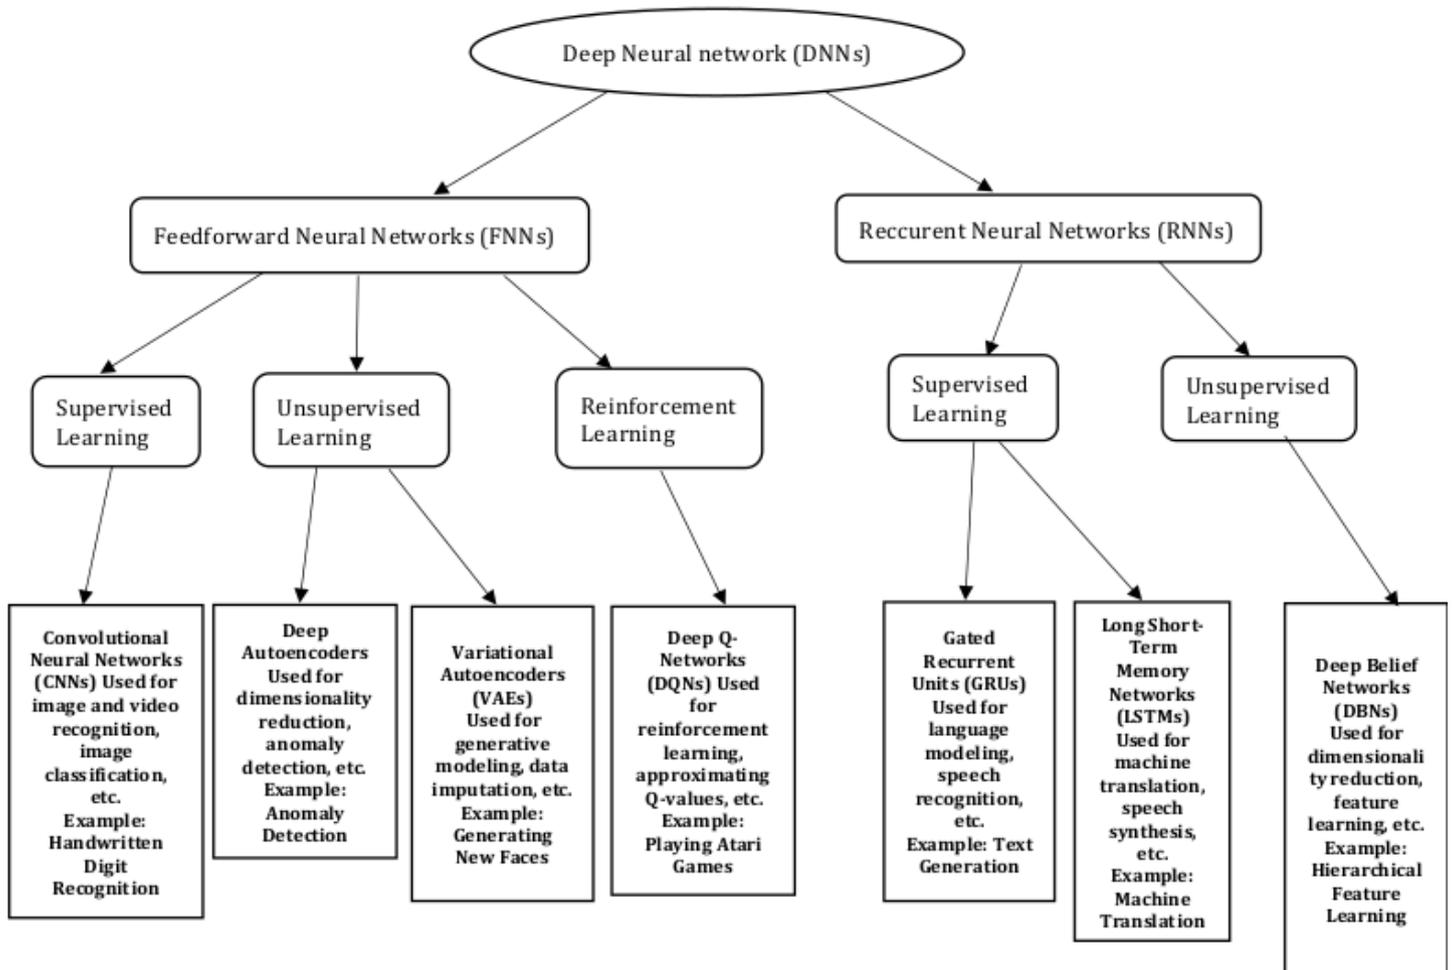


FIGURE 2.1 – Arborescence des Types de Réseaux de Neurons Profonds (DNNs).

2.2.1 Réseaux de neurones FeedForward (FNN)

Les réseaux de neurones feedforward (FNN) sont les réseaux de neurones artificiels les plus simples où les connexions entre les nœuds ne forment pas de cycles.

Dans les FNN, les données circulent dans une seule direction de la couche d'entrée à la couche de sortie en passant par les couches cachées [25].

Les FNN sont fréquemment utilisés pour résoudre des problèmes de classification et de régression. Ils sont formés en utilisant des algorithmes de rétropropagation basés sur le gradient afin de minimiser la fonction de perte [26].

Ce processus de rétropropagation permet d'ajuster les poids et les biais du réseau après chaque passage des données à travers celui-ci [26].

Les FNN sont divisés en fonction des paradigmes d'apprentissage suivants :

- Apprentissage supervisé : L'apprentissage supervisé est une méthode d'apprentissage automatique qui utilise des données étiquetées pour former des modèles. Dans ce type d'apprentissage, chaque échantillon de l'ensemble de données de formation est composé d'une entrée et de la sortie correspondante désirée, ce qui permet au modèle d'apprendre à faire des prédictions à partir de nouvelles données [27].

Les CNN (Convolutional Neural Networks) sont particulièrement efficaces pour le traitement des données structurées en grille, telles que les images [1]. Transformers :

Les transformers ont révolutionné le domaine du traitement du langage naturel en introduisant une architecture sans récurrence, ce qui les rend plus parallélisables et plus efficaces pour traiter de longues séquences de données [28]. Ils ont notamment introduit le concept d'attention, qui permet au modèle de donner plus ou moins d'importance à différentes parties de l'entrée lors de la génération de la sortie. Cette capacité d'attention est essentielle pour des tâches telles que la traduction automatique, où le modèle doit considérer l'ensemble du texte source lors de la génération de la traduction [28].

Les transformers ont révolutionné le domaine du traitement du langage naturel en introduisant une architecture sans récurrence, ce qui les rend plus parallélisables et plus efficaces pour traiter de longues séquences de données [28]. Ils introduisent le concept d'attention, permettant au modèle de donner plus ou moins d'importance à différentes parties de l'entrée lors de la génération de la sortie. Cette capacité d'attention est essentielle pour des tâches telles que la traduction automatique, où le modèle doit considérer l'ensemble du texte source [28].

- Apprentissage non supervisé : Les techniques d'apprentissage non supervisé permettent un apprentissage sans données étiquetées, en se concentrant sur la découverte de structures dans les données d'entrée. Les maillages génératifs, la réduction de dimensionnalité et le clustering sont des méthodes courantes dans cette classe.

Les modèles d'apprentissage profond comme les machines Boltzmann contraintes, les auto-encodeurs, les GAN et les RNN (y compris les GRU et les LSTM) sont utilisés dans les tâches d'apprentissage non supervisé [29].

Les autoencodeurs profonds sont des réseaux de neurones artificiels utilisés pour l'apprentissage non supervisé de représentations efficaces des données.

Ils se composent d'un réseau encodeur qui mappe les données d'entrée dans une représentation de l'espace latent et d'un réseau décodeur qui reconstruit les données d'entrée à partir de cette représentation latente.

Les autoencodeurs variationnels (VAE) étendent cette architecture pour générer de nouvelles

données à partir de l'espace latent [30][31].

- Apprentissage par renforcement : L'apprentissage par renforcement fonctionne en interagissant avec l'environnement, contrairement à l'apprentissage supervisé qui utilise des données étiquetées. Cette technique a été développée en 2013 avec Google DeepMind [32].

L'apprentissage par renforcement est un type d'algorithme d'apprentissage automatique qui apprend à résoudre des problèmes par essais et erreurs à travers l'interaction avec un environnement réel. L'agent (la machine) est entraîné à prendre des décisions en fonction des récompenses ou des punitions reçues pour ses actions. Son objectif est de maximiser la récompense totale. Le renforcement profond vise à imiter le fonctionnement du cerveau humain en utilisant plusieurs couches de réseaux de neurones artificiels dans son architecture [33].

Q-Learning est un algorithme d'apprentissage par renforcement qui vise à trouver la politique optimale pour maximiser les récompenses cumulées à long terme. Il utilise une table de Q-valeurs $Q(s,a)$ pour estimer l'espérance de la récompense pour chaque paire état-action [33].

Une fois que l'agent a appris la fonction Q , il recherche la meilleure action possible dans un état donné (s) qui produit la plus grande valeur de Q . Avec la fonction Q optimale (Q^*), on peut déterminer la politique optimale en appliquant un algorithme d'apprentissage par renforcement pour maximiser la valeur de chaque état [33].

2.2.2 Réseaux de neurones Récurrent (RNN) :

Les réseaux de neurones récurrents (RNN) sont un type de réseau de neurones largement utilisé dans le domaine du DL [34].

Les RNN utilisent les sorties précédentes comme entrées supplémentaires, ce qui les rend parfaitement adaptés au traitement de données séquentielles [35].

Les RNN sont appelés "récurrents" car ils utilisent les sorties précédentes comme entrées, créant une mémoire de la séquence de données. Bien qu'ils puissent théoriquement gérer des séquences de longueur arbitraire, en pratique, ils ne voient que quelques étapes en arrière. Ils capturent les dépendances temporelles en utilisant les prédictions passées comme entrées via les états cachés [35].

Les RNN sont divisés en fonction de paradigmes d'apprentissage suivant :

- Apprentissage supervisé :

Les Gated Recurrent Units (GRU) ont été introduits par Cho et al. [36] en 2014 pour résoudre le problème de perte de gradient des réseaux récurrents classiques, tout en proposant une architecture avec moins de paramètres d'entraînement par rapport aux LSTM [35]. Similaires aux LSTM, les GRU constituent un élément central de l'architecture GRU. Ils comportent

deux principales portes :

La porte de mise à jour (update gate) qui contrôle la quantité d'information passée à conserver dans l'état caché [37]. La porte de réinitialisation (reset gate) qui contrôle la quantité d'information passée à oublier [37]. Ces portes permettent aux GRU de mieux gérer la mémoire à court et à long terme, sans avoir besoin d'un état de cellule séparé comme dans les LSTM [35]. Les GRU sont une architecture de réseaux de neurones récurrents plus simple que les LSTM, tout en offrant des performances comparables sur de nombreuses applications [37].

Pour surmonter le problème de disparition du gradient, S. Hochreiter et al. [38] ont proposé les LSTM, qui ont ensuite été améliorés par F. Gers et al. Schmidhuber [39]. Les LSTM sont une architecture de RNN conçue pour gérer efficacement les dépendances à long terme dans les données séquentielles [40].

Les LSTM possèdent une cellule mémoire composée de plusieurs portes, telles qu'une porte d'entrée, une porte de sortie et une porte d'oubli, qui permettent de contrôler les informations à retenir et à oublier sur de longues séquences de données [41]. Ces réseaux sont appris à l'aide de l'algorithme de rétro-propagation à travers le temps (BPTT) et peuvent être bidirectionnels (BLSTM) pour capturer les dépendances passées et futures dans les données séquentielles [40].

- Apprentissage non supervisé : Les Deep Belief Networks (DBN) sont des réseaux de neurones profonds qui combinent des principes d'apprentissage non supervisé et des réseaux de neurones [42]. Les DBNs sont des modèles de réseau de neurones composés de plusieurs couches de variables latentes (ou unités cachées) interconnectées. Chaque couche est formée par des Restricted Boltzmann Machines (RBMs) ou des structures similaires. Les RBMs sont des modèles d'énergie basés sur les probabilités qui peuvent reconstruire les entrées d'origine. Les couches des DBNs sont entraînées de manière indépendante, puis assemblées pour former un réseau global [42][48][49]. Les DBNs ont une architecture dirigée acyclique (DAG), ce qui signifie que les couches sont connectées entre elles, mais pas entre les unités dans chaque couche. Cela permet aux DBNs de fonctionner de manière générative et discriminative, ce qui signifie qu'ils peuvent reconstruire les entrées et classer les données [42][48][49].

2.2.3 Réseaux neuronaux convolutifs (CNN)

Les CNN sont largement utilisés pour la classification des maladies des feuilles des plantes.

Comme autres réseaux DL tels que les réseaux entièrement convolutifs (FCN) et les réseaux déconvolutifs sont utilisés pour la segmentation d'images [43] ou diagnostique médicale [44].

Un CNN se compose généralement de couches convolutives, regroupées et entièrement connectées.

La couche de convolution utilise la corrélation locale des données d'image pour extraire les caractéristiques.

2.2.4 Architecture de CNN

Le réseau neuronal convolutif se compose de plusieurs couches telles que la couche d'entrée, la couche convolutive, la couche de pooling et les couches entièrement connectées [45]. Une couche convolutive applique des filtres à l'image d'entrée pour extraire les caractéristiques, une couche de Pooling échantillonne l'image pour réduire les calculs et une couche entièrement connectée effectue la prédiction finale. Le réseau apprend les filtres optimaux par rétro-propagation et descente de gradient [45]. Voici des principales architectures de CNNs les plus connues : AlexNet : développé par Alex Krizhevsky et al., a remporté la compétition ImageNet en 2012 et a popularisé l'utilisation des CNN pour la classification d'images [46][47].

1. VGG : proposé par Karen Simonyan et Andrew Zisserman, utilise une architecture simple de convolutions 3x3 empilées, avec une profondeur allant jusqu'à 19 couches [46][47].
2. GoogLeNet : développé par Christian Szegedy et al., introduit le module Inception qui combine des convolutions de différentes tailles en parallèle [46][47]. GoogLeNet a une architecture plus profonde que AlexNet et VGG, avec 22 couches, tout en ayant moins de paramètres [46][47].
3. ResNet : proposé par Kaiming He et al., vise à entraîner des réseaux très profonds (jusqu'à 1000 couches) [46][47]. ResNet introduit les connexions résiduelles ("shortcut connections") pour faciliter l'entraînement des réseaux très profonds en évitant le problème de dégradation de la performance [46][47].
4. MobileNets : proposé par Andrew G. Howard et al., sont des CNN légers et efficaces conçus pour le déploiement sur des appareils mobiles et embarqués [48]. MobileNets utilisent des convolutions dépliées (depthwise separable convolutions) pour réduire drastiquement le nombre de paramètres [48].

2.3 Principe de fonctionnement de CNN

Les réseaux de neurones convolutifs (CNN) sont un type de réseau de neurones profonds spécialement conçu pour traiter des données structurées telles que des images. Leur principe de fonctionnement repose sur plusieurs concepts de base :

1. Couche de convolution :

Le processus de l'opération de convolution est illustré à la figure 2.2, Le noyau est placé dans le coin supérieur gauche de la figure[1]. Les valeurs de pixels kernelisées sont multipliées par les valeurs de noyau correspondantes, puis les produits sont additionnés et un biais est ajouté à la fin [1]. Le noyau est déplacé d'un pixel et le processus est répété jusqu'à ce que tous les emplacements possibles dans l'image soient filters [1], comme le montre la figure 2. Il applique un ensemble de filtres apprenables appelés noyaux aux images d'entrée [49]. Les Filtres sont des matrices plus petites et il leurs glisse sur les données de l'image d'entrée et calcule le produit scalaire entre la masse du noyau et l'emplacement de l'image d'entrée correspondant [1].

La sortie de cette couche est appelée cartes de caractéristiques (Feature Map)[45].

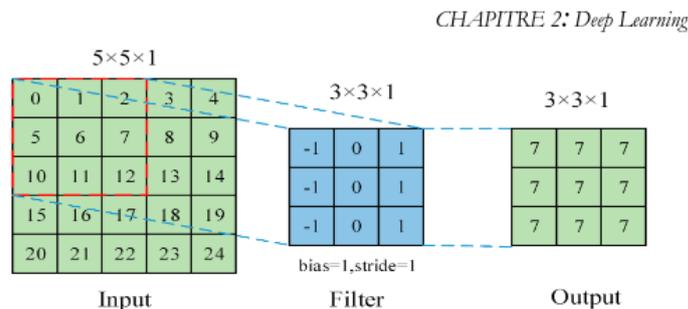


Figure 2. Le processus d'opération de convolution [71].

FIGURE 2.2 – Le processus d'opération de convolution [1].

2. Couche Pooling :

Le processus de la fonction de Pooling est illustré à la figure 2.3. Le Pooling maximale consiste à diviser l'image d'entrée en plusieurs régions rectangulaires en fonction de la taille du filtre et à imprimer la valeur maximale de chaque region [50]. Pour le Pooling moyenne, le résultat est la moyenne de chaque intervalle [50]. Les couches convolutives et convolutives apparaissent souvent de manière interchangeable dans les applications. Chaque neurone d'une couche entièrement connectée est connecté à un neurone supérieur, et les caractéristiques multidimensionnelles sont intégrées et transformées en caractéristiques unidimensionnelles pour des tâches de classification ou de reconnaissance [51]. La couche de pooling est une opération de sous-échantillonnage appliquée généralement entre deux couches de convolution dans un CNN [48]. Son objectif est de réduire la dimension spatiale des représentations en entrée, tout en préservant les caractéristiques importantes [50].

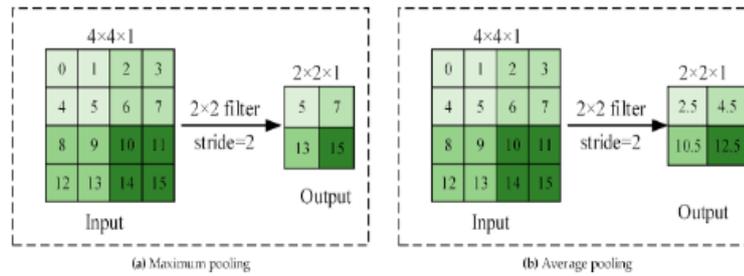


FIGURE 2.3 – Le processus d’opération de pooling [1].

3. Couche dense :

Une couche dense, également appelée couche entièrement connectée, est un composant de base d’un réseau neuronal dans lequel chaque neurone de la couche est connecté à chaque neurone de la couche précédente [52]. Dans ce type de couche, la sortie de chaque neurone est déterminée par une somme pondérée des entrées de la couche précédente, suivie de l’application d’une fonction d’activation [52]. Cette couche prend les entrées du niveau précédent et calcule la tâche finale de classification ou de regression [50]. La dernière couche contient généralement le même nombre de nœuds de sortie que le nombre de classes dans les tâches de classification, Des fonctions non linéaires telles que ReLU sont utilisées après chaque couche dense pour ajouter de la non-linéarité au Réseau [53].

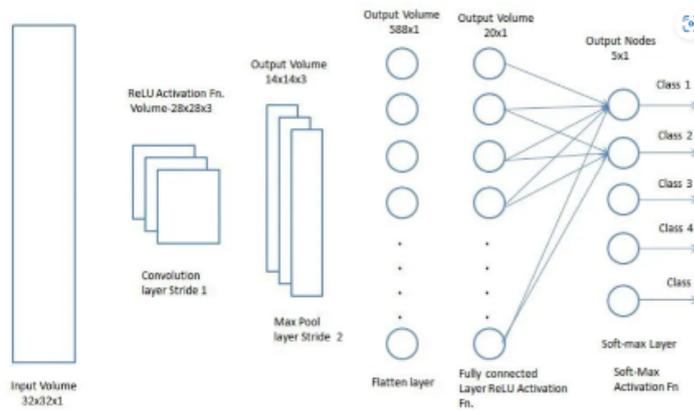


FIGURE 2.4 – La couche dense [2].

4. Couche dropout :

La couche Dropout est une technique de régularisation utilisée dans les réseaux de neurones pour prévenir le sur-apprentissage [29]. Pendant l’entraînement, des neurones sélectionnés au hasard sont temporairement Ignorés d’une manière aléatoire, ce qui force le réseau à ne pas

trop s'appuyer sur un seul neurone et à apprendre à utiliser toutes les informations disponibles [26].

2.4 Définition du modèle YOLO

L'apprentissage automatique et le traitement d'images peuvent détecter et identifier automatiquement les maladies des plantes, jouant ainsi un rôle important dans le diagnostic automatique des maladies des plantes [54].

Les algorithmes en une étape ont bien fonctionné par rapport à d'autres modèles d'apprentissage profond [55], comme la série YOLO (You Only Look Once). YOLO est un algorithme viral et largement utilisé [56], célèbre pour ses capacités de détection d'objets. En 2015, Redmon et al. ont introduit la première version de YOLO [57].

YOLO est un algorithme de détection d'objets qui utilise un réseau de neurones pour identifier les objets dans des images. Il est basé sur l'approche de la classification d'images et de la localisation d'objets, combinées pour produire des résultats de détection d'objets en temps réel [58].

Ces dernières années, les chercheurs ont publié plusieurs versions ultérieures de YOLO, décrites comme YOLOv2, YOLOv3, YOLOv4 et YOLOv5 [59].

2.4.1 L'avantage d'utilisation de YOLOv5

YOLO est une famille de modèles de détection d'objets en temps réel basés sur des réseaux de neurones convolutifs. YOLOv5 est une version spécifique de l'algorithme YOLO, qui se distingue par sa simplicité, sa rapidité et sa précision [60][61].

Contrairement aux approches traditionnelles de détection d'objets qui effectuent plusieurs prédictions sur différentes parties de l'image, YOLO divise l'image en une grille et prédit les boîtes englobantes et les classes d'objets pour chaque cellule de la grille en une seule passe du réseau [60][61].

Cela permet à YOLO d'être très rapide, ce qui le rend idéal pour les applications nécessitant une détection d'objets en temps réel, telles que la surveillance vidéo et la conduite autonome [60][61].

2.4.2 Principe de fonctionnement de YOLO

YOLO est un algorithme de détection d'objets en temps réel qui traite une image en un seul passage via un réseau neuronal.

Contrairement aux algorithmes de détection d'objets traditionnels impliquant plusieurs étapes de traitement, YOLO effectue la reconnaissance d'objets et la régression du cadre de délimitation en une seule étape [55].

Cela le rend rapide et efficace, avec la capacité de traiter jusqu'à 60 images par seconde [55].

YOLO fonctionne en divisant une image en une grille de cellules et en prédisant des cadres de délimitation pour chaque cellule [62]. Pour chaque cadre englobant, YOLO prédit la probabilité de classe (c'est-à-dire la probabilité que le cadre englobant contienne un objet particulier) et le score de confiance (c'est-à-dire la probabilité que le cadre englobant contienne un objet) [54].

YOLO prédit également les coordonnées du cadre de délimitation par rapport à la cellule [62].

Le modèle YOLO traite les images à plus de 45 images par seconde. En raison de la mise à jour de l'algorithme, la vitesse augmente, permettant désormais la détection en temps réel [63].

2.4.3 Architecture de YOLO

L'architecture de YOLO est similaire à celle de GoogleNet. Elle comporte un total de 24 couches convolutives, quatre couches de connexion maximum et deux couches entièrement connectées [64].

L'architecture de YOLO fonctionne comme suit :

1. Division de l'image en grille : YOLO divise l'image d'entrée en une grille de cellules. Chaque cellule de la grille est responsable de prédire un certain nombre de boîtes englobantes (bounding boxes) et les probabilités de classe associées [54][61].
2. Pour chaque boîte englobante prédite par une cellule, YOLO prédit
 - Les coordonnées (x, y, largeur, hauteur) de la boîte par rapport à la cellule [61].
 - Un score de confiance qui représente la probabilité qu'une boîte contienne un objet et la précision de la boîte [54][61].
3. Prédiction des probabilités de classe : En plus des boîtes englobantes, chaque cellule prédit également les probabilités conditionnelles de classe pour chaque objet.

Ces probabilités représentent la probabilité qu'un objet appartienne à chaque classe possible, conditionnellement à la présence d'un objet dans la boîte [54][61].

Comme illustré dans la figure 2.5, l'architecture du modèle CNN constitue la base du modèle YOLO [54]. L'algorithme YOLO prend une image en entrée, puis utilise un simple CNN pour détecter les objets dans l'image [61].

L'architecture de YOLO est basée sur un CNN qui utilise des couches de convolution et de pooling pour extraire des caractéristiques de l'image [54]. Les couches de convolution sont suivies de couches de pooling pour réduire la taille de l'image et améliorer la robustesse

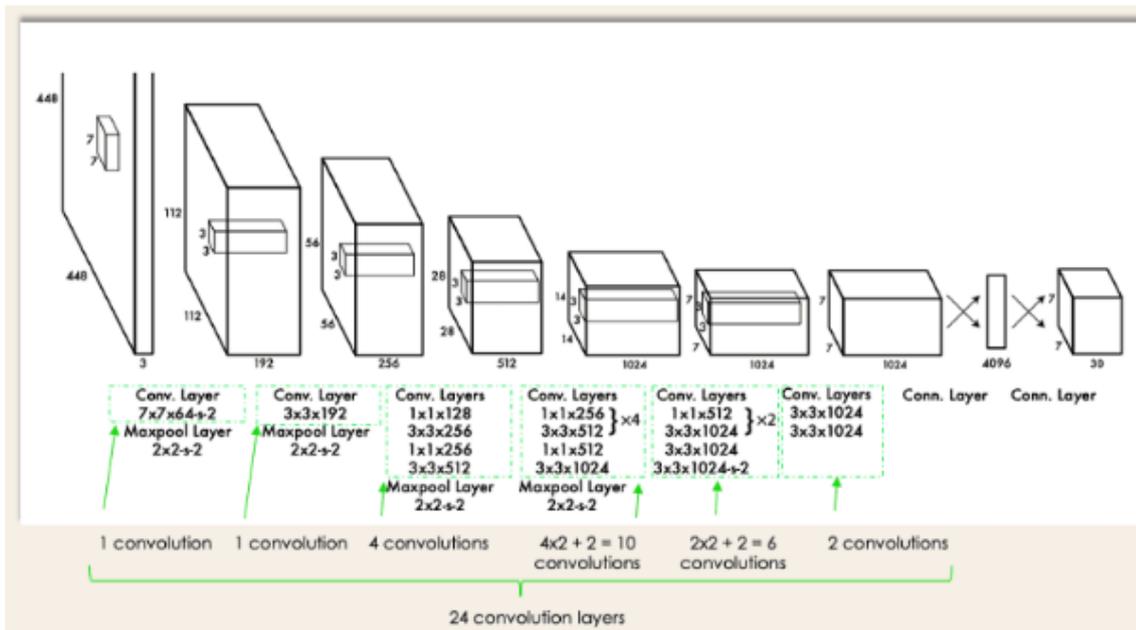


FIGURE 2.5 – Architecture de YOLO [3].

aux rotations et aux déformations. Les couches de convolution sont également utilisées pour détecter les objets dans l'image [61].

Pendant l'entraînement, YOLO attribue le Bounding Box de chaque objet au prédicteur avec l'Intersection over Union (IoU) la plus élevée, améliorant ainsi la capacité du modèle à prédire des tailles, des formes ou des classes d'objets spécifiques [65].

La suppression non maximale (Non-Maximum Suppression, NMS) est une technique importante dans les modèles YOLO pour affiner la détection d'objets en sélectionnant le Bounding Box avec le score de confiance le plus élevé et en supprimant les cadres redondants ou qui se chevauchent [65].

Cette étape de post-traitement améliore la précision et l'efficacité en conservant uniquement les cadres de délimitation les plus précis et sans chevauchement [66].

2.4.4 Importance de YOLO

Les méthodes de détection d'objets telles que les réseaux de neurones régionaux (R-CNN) et leurs variantes se concentrent sur des régions spécifiques d'une image et entraînent chaque composant séparément [6].

Cependant, ce processus nécessite que R-CNN classe 2 000 régions par image, ce qui le rend très lent et impropre à une utilisation en temps réel. En revanche, le modèle YOLO est beaucoup plus rapide (45 images par seconde) et plus facile à optimiser que les algorithmes précédents. YOLO est basé sur un réseau neuronal unique qui effectue tous les éléments de la tâche de reconnaissance

d'objets, la rendant plus efficace et plus facile à mettre en œuvre [65].

2.4.5 Limitation de YOLO

YOLO impose de fortes contraintes spatiales sur la limite des prédictions de box, puisque chaque cellule de la grille ne prédit que deux box et ne peut avoir qu'une seule classe [65].

Les contraintes spatiales imposées par YOLO sur les prédictions de boîtes englobantes limitent le nombre d'objets proches que le modèle peut prédire.

Le modèle a du mal à détecter des objets petits qui apparaissent en groupes, comme des flocks de oiseaux [65].

2.5 Conclusion

Ce chapitre a souligné l'importance du deep learning, en particulier des CNN, dans le domaine de la classification des maladies des feuilles d'arbres.

Nous avons également exploré comment des modèles tels que YOLO peuvent être exploités pour détecter les arbres et les feuilles dans des images prises par des drones, offrant ainsi une solution rapide et précise pour la surveillance des cultures.

Dans le prochain chapitre, nous aborderons la conception du drone utilisé pour la surveillance des cultures, en particulier des arbres fruitiers.

Nous examinerons les différents composants matériels utilisés et discuterons de leurs rôles dans le fonctionnement du système de détection et de classification des maladies des arbres, ainsi que dans la navigation spatiale.

Chapitre 3

Conception et réalisation du drone

3.1 Introduction

L'un des éléments essentiels dans la conception et la réalisation d'un drone est le choix judicieux des composants matériels.

Chaque composant joue un rôle crucial dans les performances et la fiabilité globale du drone.

Dans cette section, nous examinerons en détail les différents composants matériels utilisés dans la construction d'un drone.

3.2 Matériel utilisé

Nous avons utilisé l'ensemble des composants définis ci-dessous :

3.2.1 Châssis

Le châssis est la structure de base sur laquelle tous les autres composants du drone sont montés. Il joue un rôle crucial dans la stabilité, la manœuvrabilité et la résistance aux chocs du drone.

Le choix du châssis dépend de plusieurs facteurs, notamment le type d'application, la taille et le poids prévus du drone, ainsi que des contraintes budgétaires [4].

Il existe une grande variété de châssis disponibles sur le marché, allant des modèles en fibre de carbone légers et robustes aux cadres imprimés en 3D plus économiques.

Les principaux types de châssis comprennent les quadricoptères, les hexacoptères et les octocoptères, en fonction du nombre de moteurs et d'hélices utilisés [4].



FIGURE 3.1 – Châssis [4].

3.2.2 Moteurs Brushless

Les moteurs Brushless (BLDC), également connus sous le nom de moteurs sans balais, sont largement utilisés dans la propulsion des drones en raison de leur efficacité, de leur fiabilité et de leur faible entretien.

Contrairement aux moteurs à courant continu avec balais, les moteurs brushless utilisent des aimants permanents et des bobines fixes pour générer un champ magnétique et produire un mouvement rotatif.

Les moteurs que nous utilisons sont les Techtonics A2212/13T 1000 kV [5].



FIGURE 3.2 – Moteurs Brushless [5].

3.2.3 Contrôleurs de vitesse électroniques (ESC)

Les Contrôleurs de Vitesse Électroniques (ESC) de 30A sont des composants essentiels dans les systèmes de propulsion des drones et d'autres véhicules télécommandés.

Ils régulent la vitesse des moteurs en contrôlant la puissance électrique qui leur est fournie, ce qui permet de contrôler avec précision la vitesse de rotation des hélices ou des moteurs [6].



FIGURE 3.3 – Contrôleurs de vitesse électroniques (ESC) [6].

3.2.4 Hélices

Les hélices pour drones se déclinent en une variété de tailles et de pas adaptées à différents types d'applications [7].

Le choix de la taille et du pas dépend du type de drone, de la charge qu'il transporte et des performances de vol recherchées [7].

Un équilibre entre la taille et le pas est crucial pour assurer une efficacité optimale et des performances de vol stables [7].

Le nombre de pales sur une hélice peut varier, généralement de deux à quatre. Les hélices à trois pales sont les plus répandues dans les drones multicopters en raison de leur équilibre entre performance et efficacité.

Le nombre de pales influe sur la stabilité, l'efficacité et le bruit de l'hélice en vol.

Les hélices peuvent être fabriquées à partir de différents matériaux tels que le plastique, la fibre de carbone ou le bois. Chaque matériau présente ses propres avantages et inconvénients en termes de poids, de durabilité et de résistance aux dommages.

Il est essentiel de choisir des hélices qui tournent dans le bon sens (horaire ou anti-horaire) pour chaque moteur afin d'assurer un vol équilibré et stable.

Un équilibrage précis des hélices est également nécessaire pour éviter les vibrations excessives, qui peuvent affecter les performances de vol et endommager les composants du drone [7].



FIGURE 3.4 – RC Propellers CW 5x5 [7].

3.2.5 Batterie

La batterie est un composant crucial du drone, fournissant l'énergie nécessaire pour alimenter tous les systèmes embarqués, y compris les moteurs, le contrôleur de vol, et les divers capteurs et accessoires. La performance globale et l'autonomie du drone dépendent largement des caractéristiques et de la qualité de la batterie utilisée.

Les batteries utilisées dans les drones sont généralement des batteries lithium-polymère (LiPo) en raison de leur densité énergétique élevée et de leur capacité à délivrer des courants élevés. Cependant, d'autres types de batteries, comme les lithium-ion (Li-ion) et les lithium-fer-phosphate (LiFePO4), peuvent également être utilisés en fonction des exigences spécifiques du drone [8].

La capacité de la batterie, mesurée en milliampères-heures (mAh), indique la quantité d'énergie que la batterie peut stocker. Une capacité plus élevée signifie généralement une plus grande autonomie, permettant au drone de voler plus longtemps sans nécessiter de recharge. Le taux de décharge, exprimé en "C", représente la capacité de la batterie à fournir du courant. Par exemple, une batterie avec un taux de décharge de 25C et une capacité de 2000 mAh peut délivrer un courant maximal de 50 ampères ($2000 \text{ mAh} * 25\text{C}$). Un taux de décharge élevé est essentiel pour répondre aux besoins énergétiques instantanés des moteurs lors des manœuvres rapides ou des changements brusques d'altitude [8].

La tension nominale de la batterie, souvent exprimée en termes de cellules (S), est également un paramètre crucial. Les batteries LiPo sont disponibles en configurations variées, telles que 3S (11.1V) ou 4S (14.8V). La tension doit être compatible avec les spécifications des composants du drone pour éviter tout dommage ou inefficacité. Le poids et la taille de la batterie influencent la conception du drone et sa performance en vol. Une batterie plus lourde peut réduire l'agilité du drone et augmenter la consommation d'énergie, tandis qu'une batterie plus légère pourrait limiter l'autonomie.

Dans notre projet, nous utilisons la batterie illustrée à la figure 3.5 .



FIGURE 3.5 – 11.1V 3S 5200MAH/35C LIPO BATTERY [8].

3.2.6 Distributeur d'alimentation

Le distributeur d'alimentation (PDB) assume un rôle vital dans l'acheminement de l'électricité provenant de la batterie du drone vers les divers circuits électriques de manière sécurisée.

Doté de multiples points de connexion, il permet le branchement des composants électriques du drone tels que les ESC, le contrôleur de vol et d'autres accessoires.

De plus, certains PDB sont munis de dispositifs de protection contre les courts-circuits, prévenant ainsi tout dommage éventuel aux composants en cas de dysfonctionnement ou de surcharge électrique [9].

Cette combinaison de distribution d'électricité sécurisée et de protection contre les courts-circuits assure le bon fonctionnement et la durabilité du système électrique du drone [9].



FIGURE 3.6 – Dual BEC 5V/12V PDB [9].

3.2.7 Émetteur radio pour système de transmission

L'émetteur Flysky pour drone est un appareil de contrôle à distance spécialement conçu pour piloter des drones de manière précise et efficace.

Ces émetteurs offrent généralement plusieurs canaux de contrôle, ce qui permet aux pilotes d'exécuter diverses commandes et manoeuvres avec facilité [10].



FIGURE 3.7 – Émetteur radio pour système de transmission [10].

3.2.8 Émetteur radio FPV

Le FPV (First Person View) radio transmetteur est un composant essentiel dans les systèmes de drones, particulièrement pour ceux utilisés dans les applications de course et d'exploration où le contrôle précis et la transmission en temps réel des données visuelles sont critiques [10].

Ce dispositif permet au pilote de recevoir une vue en direct depuis la caméra embarquée sur le drone, offrant une expérience immersive semblable à celle d'être à bord de l'appareil [10].



FIGURE 3.8 – Émetteur radio FPV[10].

3.2.9 Contrôleur De Vol (Pixhawk)

Le contrôleur de vol Pixhawk est le cerveau électronique central des drones et des véhicules autonomes [11].

Il s'agit d'un calculateur de vol open-source hautement performant, conçu pour fournir une stabilité, une précision et une fiabilité maximales lors du pilotage des drones.

Le contrôleur de vol Pixhawk utilise un microcontrôleur puissant qui exécute un firmware open-source tel que PX4 ou ArduPilot [11].

Ces firmwares offrent une gamme étendue de fonctionnalités de pilotage automatique, de planification de missions et de contrôle avancé pour répondre aux besoins des différents types d'applications [11].



FIGURE 3.9 – Contrôleur De Vol (Pixhawk) [11].

3.2.10 Camera Stéréo

Une caméra stéréo, également appelée caméra binoculaire ou caméra 3D, est un type de caméra qui utilise deux objectifs ou capteurs d'image séparés pour capturer des images en relief de la même scène, simulant ainsi la perception de la profondeur comme le fait le système visuel humain.

Chaque objectif ou capteur de la caméra stéréo est placé à une distance similaire à celle des yeux humains, ce qui permet à la caméra de percevoir la profondeur et de reconstruire la topographie tridimensionnelle de la scène capturée [12].



FIGURE 3.10 – imx219 83 camera [12].

3.2.11 Module GPS

Les récepteurs GPS pour drones sont des composants essentiels qui permettent aux drones de connaître leur position exacte dans le monde.

Ces récepteurs reçoivent les signaux du système de positionnement global (GPS) provenant des satellites en orbite autour de la Terre et calculent les coordonnées géographiques (latitude, longitude et altitude) du drone en fonction de ces signaux [13].



FIGURE 3.11 – GPS Module [13].

3.2.12 Kit de développement Jetson Nano

Le Jetson Nano, développé par NVIDIA, est un ordinateur monocarte compact et abordable conçu pour des applications d'intelligence artificielle et de traitement d'images [14].

Doté d'une architecture GPU embarquée, il offre une puissance de calcul parallèle optimale pour les tâches d'IA et de ML.

Grâce à son processeur quad-core ARM Cortex-A57, il assure une performance de traitement solide pour diverses applications informatiques [14].

Le Jetson Nano est compatible avec les principaux frameworks d'IA tels que TensorFlow et PyTorch, facilitant ainsi le développement et le déploiement d'applications d'IA. Avec sa connectivité étendue, incluant des ports USB 3.0, HDMI, Ethernet, GPIO et CSI, ainsi que des interfaces Wi-Fi et Bluetooth intégrées, il offre une flexibilité remarquable pour la connexion de périphériques externes. Malgré ses performances, il est conçu pour une consommation d'énergie optimisée, le rendant idéal pour une utilisation dans des applications embarquées et mobiles.

Grâce à une documentation complète, des exemples de code et une communauté active, le Jetson Nano offre un support complet aux développeurs cherchant à exploiter pleinement ses capacités dans divers domaines tels que la robotique, les drones et l'automatisation industrielle.



FIGURE 3.12 – Jetson Nano [14].

3.3 L'assemblage de drone

L'assemblage du drone a été réalisé en suivant un processus méthodique et Rigoureux.

Les différentes étapes comprenaient la fixation des moteurs dans le cadre, l'installation du contrôleur de vol Pixhawk au centre du cadre, la connexion des ESC aux moteurs et au contrôleur de vol, ainsi que la fixation de la batterie et du récepteur radio.

De plus, nous avons soigneusement sélectionné et monté les hélices pour assurer une performance optimale en termes de poussée et de stabilité en vol.

Un récepteur GPS a également été intégré au système pour permettre une navigation précise et un positionnement fiable du drone dans l'espace. Voici le schéma illustré ci-dessus dans la figure 3.13, qui nous a été utile pour l'assemblage du drone.

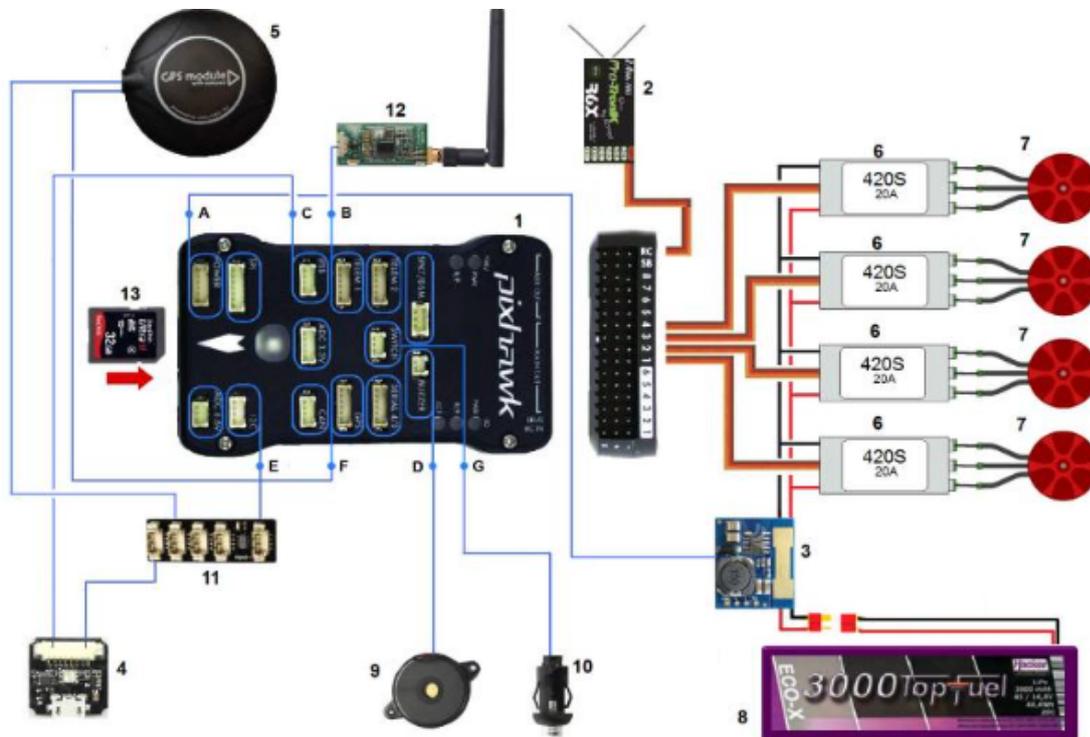


FIGURE 3.13 – Schéma L'assemblage de drone [15].

3.4 Calibrage De Drone

Pour la calibration du drone, nous avons utilisé Mission Planner. Voici les étapes que nous avons suivies.

3.4.1 Connexion de Mission Planner avec Pixhawk

Pour la connexion, nous devons d'abord sélectionner la méthode/le canal de communication que nous souhaitons utiliser, puis configurer le matériel physique et les pilotes de périphériques Windows. Nous pouvons connecter notre ordinateur et le pilote automatique avec des câbles USB ou des radios de télémétrie.

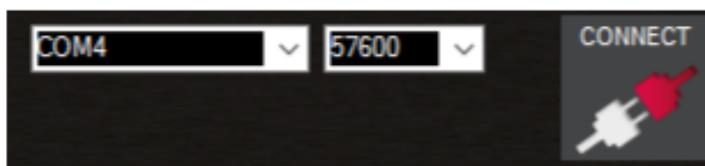


FIGURE 3.14 – Connexion de Mission Planner avec Pixhawk .

Lorsque nous connectons une radio USB ou de télémétrie, Windows attribue automatiquement un numéro de port COM au pilote automatique, visible dans le menu déroulant (le numéro spécifique n'est pas crucial). Assurons-nous également de sélectionner le bon débit en bauds : par exemple, les connexions USB utilisent souvent 115 200 bauds, tandis que les radios peuvent utiliser 57 600 bauds.

Une fois le port COM sélectionné et le bon débit en bauds configuré, nous appuyons sur le bouton CONNECT pour établir la connexion avec le pilote automatique. Une fois connecté, Mission Planner chargera les paramètres du pilote automatique, et le bouton se transformera en bouton DÉCONNEXION, comme illustré dans l'image [67].

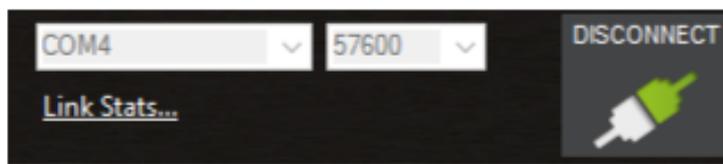


FIGURE 3.15 – Etat connecté .

3.4.2 Configuration de classe et de type de trame

Nous devons configurer les paramètres FRAME_CLASS et FRAME_TYPE pour correspondre au type de châssis physique utilisé.

Pour cela, accédons à la Configuration initiale, choisissons la classe correspondante, puis sélectionnons le type approprié .

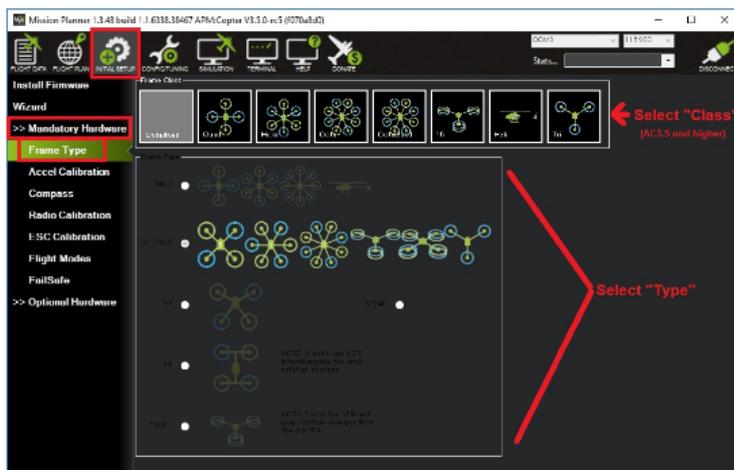


FIGURE 3.16 – Choix du type [16].

3.4.3 Accelerometer Calibration

Nous devons calibrer les accéléromètres du pilote automatique pour corriger leurs décalages sur les trois axes ainsi que toute variation hors axe . Pour ce faire, sous Setup | Mandatory Hardware, sélectionnons Accel Calibration dans le menu de gauche. Ensuite, nous devons cliquer sur le bouton

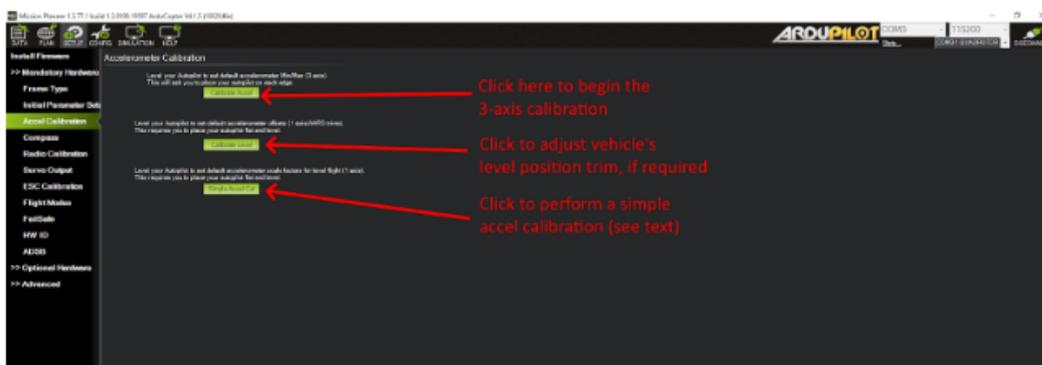


FIGURE 3.17 – Accelerometer Calibration.

Calibrate Accel pour démarrer un étalonnage complet sur les 3 axes.

Mission Planner nous guide pour placer le véhicule sur chaque axe lors de l'étalonnage. Nous appuyons sur n'importe quelle touche pour indiquer que le pilote automatique est en position, puis passons à la direction suivante.

Les positions d'étalonnage sont : horizontale, côté droit, côté gauche, à piquer, à cabrer et inversé.

3.4.4 Compass Calibration

La calibration du compas dans Mission Planner est une étape cruciale pour assurer la précision de la navigation de votre drone. Voici les étapes générales :

Dans la section CONFIGURATION > Matériel obligatoire, sélectionnez Compas.

Ensuite, démarrez le processus en cliquant sur "Démarrer". Pendant le processus, soyez attentif aux bips émis par le pilote automatique.

Un bip suivi d'un bip court émis une fois par seconde indique que le processus est en cours.

Maintenez le véhicule en l'air et effectuez des rotations dans toutes les directions : avant, arrière, gauche, droite, haut et bas. Pendant les rotations, observez les barres vertes s'étendant sur l'écran.

Elles doivent progressivement se remplir des deux côtés jusqu'à ce que l'étalonnage soit terminé.

En cas de succès, vous entendrez trois bips croissants et une fenêtre apparaîtra indiquant "Veuillez lancer le pilote automatique".

Pour finaliser la configuration, redémarrez le pilote automatique

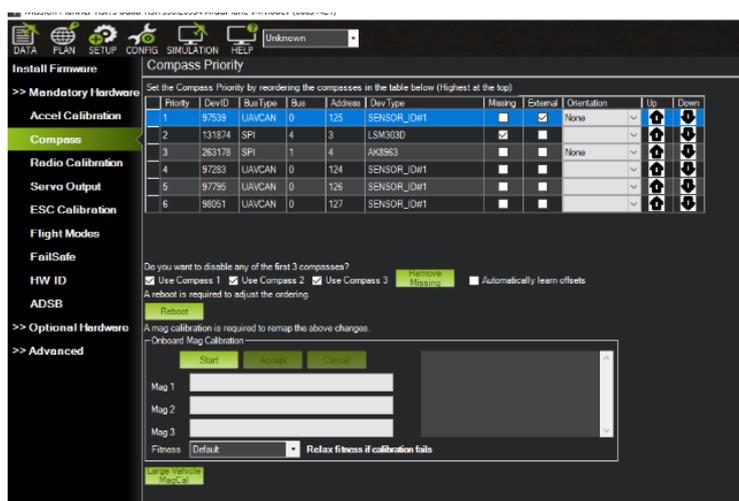


FIGURE 3.18 – Compass calibration [17].

3.4.5 Télécommande radio Calibration

Cliquons sur le bouton vert « Calibrer la radio » dans le coin inférieur droit. Appuyons sur « OK » lorsque nous sommes invités à confirmer que le matériel de commande radio est allumé, que la batterie n'est pas connectée et que les hélices ne sont pas installées. Déplaçons les joysticks, boutons et interrupteurs de l'émetteur jusqu'à leurs limites. Des lignes rouges apparaîtront sur la barre d'étalonnage, indiquant les valeurs minimales et maximales observées jusqu'à présent .



FIGURE 3.19 – Télécommande radio Calibration

3.5 Conclusion

Dans ce chapitre nous avons vu que le choix des composants matériels est crucial pour assurer la performance et la fiabilité d'un drone. Après avoir examiné les différents composants matériels nécessaires à la construction d'un drone, nous allons maintenant aborder la phase de réalisation et d'implémentation dans le chapitre qui suit.

Chapitre 4

L'implémentation et Les résultats obtenus

4.1 Introduction

Dans ce chapitre, nous allons décrire la mise en œuvre des différentes étapes de réalisation du système intelligent que nous avons proposé et qui nous permettra d'offrir une solution aux agriculteurs pour surveiller leurs cultures.

Notre application qui consiste en l'implémentation et la conception d'un drone capable de détecter les images des arbres, puis des feuilles, et enfin les classifier selon leurs maladies en utilisant des techniques de l'apprentissage profond. Nous commencerons par présenter le langage de programmation et les outils qui ont été utilisés dans le développement de notre application. Ensuite, nous détaillerons les algorithmes intelligents utilisés pour la détection des arbres et leur feuilles, la classification des maladies et nous fournissons les informations détaillées sur les datasets que nous avons utilisé. Après une série d'expériences nous allons évaluer les performances et l'efficacité de notre système proposé en analysant les résultats des algorithmes intelligents obtenus.

Ce chapitre fournit des expérimentations qui ont contribué à valider l'efficacité de notre approche et à atteindre nos objectifs de recherche.

4.2 L'implémentation des composantes de notre système

Dans cette section, nous allons décrire les parties de notre système, à savoir la partie de la détection des arbres puis des feuilles et la partie de classification des images.

4.2.1 Détection des arbres et des feuilles dans notre système

Nous avons utilisé un modèle pré-entraîné YOLOv5 pour la détection d'arbres et de feuilles à partir d'images capturées par un drone. Le modèle YOLOv5 est un réseau de neurones convolutionnel (CNN) conçu pour la détection d'objet en temps réel, offrant un bon compromis entre la vitesse et la précision.

Nous avons choisi le modèle YOLOv5s pour sa légèreté et sa rapidité, ce qui le rend adapté à l'utilisation sur des systèmes embarqués tels que le NVIDIA Jetson utilisé dans notre projet.

4.2.2 Datasets

Dans le cadre de notre projet nous avons utilisé trois datasets pour entraîner et évaluer notre nos modèles le premier dataset est Tree-Detection dataset qui a été utilisé pour la détection des arbres, il contient des images annotés avec les boîtes englobantes autour des arbres qui nous a permis d'entraîner notre premier modèle YOLO pour détecter les arbres dans les images. Le deuxième dataset est PlantDoc dataset qui a été utilisé pour la détection des feuilles dans l'arbre, il contient des images annotés avec les boîtes englobantes autour des feuilles dans l'arbre qui nous a permis d'entraîner notre deuxième modèle YOLO pour détecter les feuilles dans les images. Enfin, nous avons utilisé le dataset Apple Leaf Disease Dataset pour entraîner notre troisième modèle de CNN pour faire la tâche de classification des feuilles selon leurs maladies, ce dataset contient des images de feuilles de pommiers annotés des informations sur les maladies.

1. Tree-Detection Dataset

Le dataset Tree-Detection est une ressource précieuse pour notre recherche [68], fournissant une gamme diversifiée d'images pour l'entraînement et le test de nos modèles de détection d'arbres. Ce jeu de données contient des images capturées à partir de différents endroits et dans différentes conditions, Le dataset Tree-Detection se compose d'images annotées avec des boîtes englobantes autour des arbres, fournissant des étiquettes de vérité terrain pour l'entraînement de notre modèle de détection d'objets, ce dataset a été conçu par roboflow et qui disponible publiquement. Ce dataset contient 795 images de résolution différents que nous allons appliquer un redimensionnement de (640,640).

2. Plant Doc Dataset

Le dataset PlantDoc est une ressource essentielle pour notre modèle de détection de feuilles. Il comprend une vaste collection d'images de feuilles de plantes affectées par diverses maladies et

ravageurs, ce qui en fait une base idéale pour l'entraînement et l'évaluation de notre modèle, cette dataset a été partagé par Davinder Singh et. al en 2019 [69], et contient un ensemble de 2569 images de resolution differents que nous allons appliquer un redimensionnement de (416,416)

3. Plant Disease Dataset

Le Plant Disease est une ressource disponible sur Kaggle [20] qui a été partagé par ahmed ashraf helmi. Ce dataset est une collection de données sur les maladies des plantes entre les rouilles et l'oïdium afin d'identifier ces deux maladies dans une autre classe de plantes saines. Les images sont devenues plus réalistes et utilisables pour les modèles utilisés dans l'agriculture intelligente ou dans des domaines connexes, ce dataset contient environs de 1710 images de résolutions différents que nous allons redimensionner de (224,224). nous avons divisé ce dataset en un ensembles d'entraînement, de validation et de test. Pour l'ensemble d'entrainement elle contient plus de 430 images pour chaque classe, pour l'ensemble de validation elle contient plus de 20 images pour chaque classe et pour l'ensemble de test elle contient plus de 50 images pour chaque classe.

4.3 Conception

Dans la phase de conception, nous avons élaboré un plan détaillé pour intégrer notre système intelligent dans les drones.

4.3.1 Connexion entre jetson nano et le drone

La première étape consiste à établir une connexion entre notre système embarqué et le drone que nous avons déjà présenté dans le chapitre précédent. Pour cela, nous avons choisi d'opter pour une liaison directe via un câble USB. Ce câble a été utilisé pour connecter le Jetson Nano au port de communication approprié sur le drone, établissant ainsi

une connexion physique entre les deux composants. Cette approche directe garantit une communication fiable et stable entre le système embarqué et le drone, une condition essentielle pour assurer le bon fonctionnement de notre solution. Une fois cette connexion physique établie, nous avons ensuite eu recours à la bibliothèque logicielle open-source DroneKit. Cette dernière offre une interface de programmation conviviale permettant d'interagir avec les drones via des protocoles de communication standard tels que MAVLink. Grâce à DroneKit, nous avons pu développer des scripts

personnalisés pour contrôler le mouvement du drone. Le code suivant illustre comment établir une connexion avec un drone en utilisant DroneKit :

```
from dronekit import connect  
vehicle = connect('127.0.0.1:14550', wait_ready=True)
```

4.3.2 Implémentation des modèles d'IA sur Jetson Nano

Après avoir établi la connexion entre le Jetson Nano et le drone, nous avons entrepris la deuxième étape de notre processus d'intégration en intégrant nos modèles dans le Jetson Nano. Nous avons transféré nos modèles d'intelligence artificielle, spécialement conçus pour détecter les maladies des arbres, sur le Jetson Nano. Ce système embarqué offre une puissance de calcul adéquate pour exécuter efficacement ces modèles, ce qui est essentiel pour effectuer une analyse en temps réel des données collectées par le drone.

Pour ce faire, nous avons exploité des bibliothèques et des frameworks d'apprentissage automatique compatibles avec le Jetson Nano, tels que TensorFlow et PyTorch. Ces outils nous ont permis de charger nos modèles préalablement entraînés sur le Jetson Nano et de les utiliser pour analyser les images capturées par le drone.

Dans cette phase, nous avons également fait usage de ROS2, un système de communication pour robots. ROS2 offre un ensemble de fonctionnalités pour faciliter le développement de logiciels pour robots en fournissant des outils et des bibliothèques pour résoudre divers problèmes courants dans la construction de systèmes robotiques.

Voici comment nous avons configuré nos nœuds ROS2 dans le contexte de notre projet :

1. Nœud de Réaction et Exécution de Mission

Ce nœud interagit avec le serveur et exécute les missions assignées. Après avoir accompli une mission, il capture des images et les envoie à un autre nœud.

2. Nœud de Détection des Arbres

Ce nœud reçoit les images du nœud de réaction et exécution de mission et détecte les arbres présents dans les images. Les arbres détectés sont ensuite transmis à un autre nœud.

3. Nœud de Détection et Classification des Feuilles

Ce nœud analyse les arbres détectés et effectue la détection et la classification des feuilles. Il envoie les résultats à un autre nœud pour le traitement final.

4. Nœud de Traitement des Résultats

Ce nœud traite les résultats de la détection et de la classification des feuilles. Une fois le traitement terminé, il envoie les résultats au serveur pour un rapport complet.

Ce flux de données et de traitements en plusieurs étapes permet une analyse précise et en temps réel des images capturées par le drone, améliorant ainsi notre capacité à détecter et classer les maladies des arbres efficacement.

Voici comment le déroulement des tâches peut être résumé :

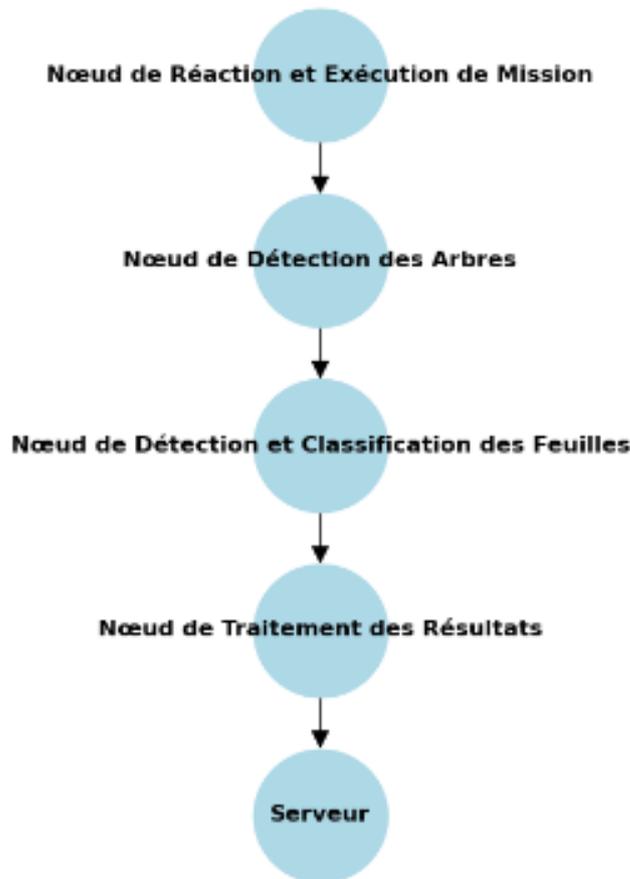


FIGURE 4.1 – Schema de déroulement des tâches.

4.3.3 Serveur Django pour Interaction Utilisateur et Données du Drone

La troisième étape de notre processus d'intégration consistait à créer un serveur Django pour permettre l'interaction entre l'utilisateur et le système. Dans ce cadre, le drone envoie les résultats

de chaque arbre analysé, et l'utilisateur peut également envoyer des missions au drone pour qu'il se rende à une position spécifique afin de collecter des données sur un arbre donné à sa demande.

Pour mettre cela en œuvre, nous avons développé une application web utilisant Django, un framework Python robuste et flexible pour le développement web. Ce serveur Django offre une interface conviviale à l'utilisateur, lui permettant de visualiser les résultats de l'analyse des arbres, de gérer les missions du drone et d'interagir avec le système de manière intuitive.

Lorsque le drone détecte une maladie ou effectue une analyse, il envoie les résultats au serveur Django. Ces résultats sont ensuite affichés en temps réel sur l'interface utilisateur, permettant à l'utilisateur de prendre des décisions informées sur la gestion des arbres.

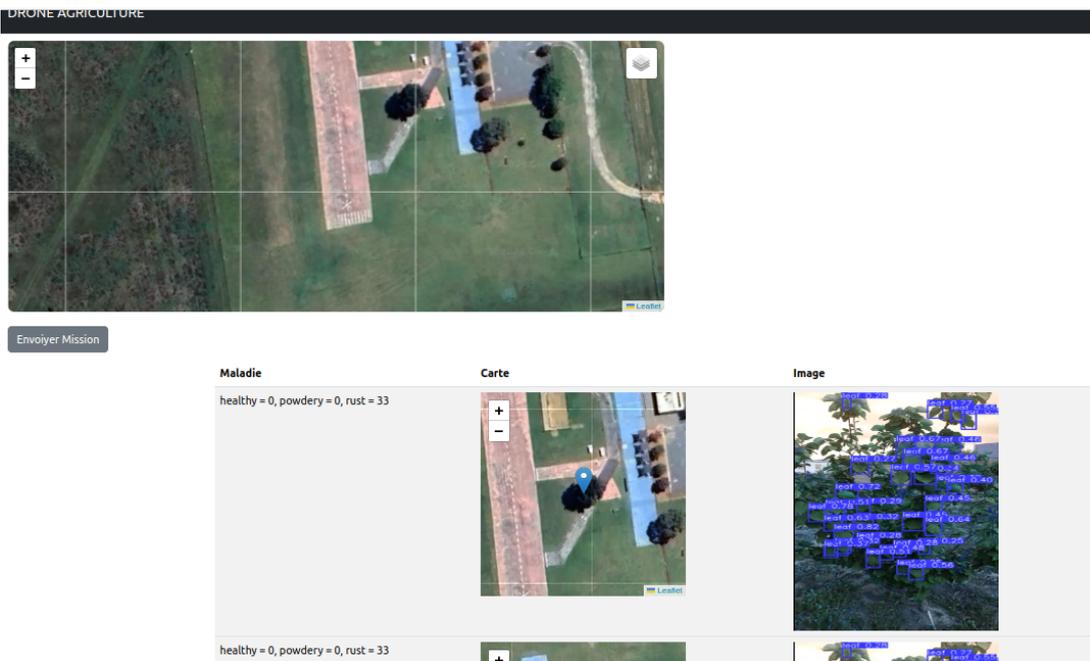


FIGURE 4.2 – interface de connexion entre drone et serveur.

4.3.4 Modèles d'apprentissage profond

Dans ce projet, nous avons mis en œuvre trois modèles intelligents pour accomplir différentes tâches cruciales : la détection des arbres, la détection des feuilles, et la classification des maladies des feuilles. Chacun de ces modèles joue un rôle essentiel dans notre système de surveillance des cultures.

1. La détection des arbres

Pour la détection des arbres nous avons utilisé YOLOv5 qui est un modèle de détection d'objets avancé et pré-construit sur le dataset déjà mentionné. Ce choix s'est basé sur sa capacité à fournir des résultats rapides et précis. Pour entraîner ce modèle nous avons utilisé

l'algorithme d'apprentissage Adam reconnu pour sa capacité à ajuster dynamiquement les taux d'apprentissage et à améliorer la convergence du modèle. La fonction de coût choisie est L2 LOSS pour la précision de la localisation des Bounding Box, ainsi que des composantes de perte pour la classification et la confiance de détection, assurant ainsi une optimisation globale du modèle.



FIGURE 4.3 – Exemple de détection d'arbres avec YOLOv5s

2. La détection des feuilles

Pour la détection des feuilles nous avons utilisé le même modèle YOLOv5 que nous avons utilisé pour accomplir la première tâche sur le dataset déjà mentionné. Ce choix s'est basé sur sa capacité à fournir des résultats rapides et précis. Pour entraîner ce modèle nous avons utilisé l'algorithme d'apprentissage Adam reconnu pour sa capacité à ajuster dynamiquement les taux d'apprentissage et à améliorer la convergence du modèle. La fonction de coût choisie est L2 LOSS pour la précision de la localisation des Bounding Box, ainsi que des composantes de perte pour la classification et la confiance de détection, assurant ainsi une optimisation globale du modèle.

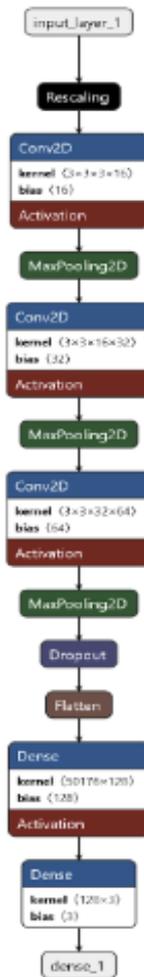


FIGURE 4.5 – Structure du modèle CNN proposé.

4.4 Procédure d'entraînement

Dans cette section nous allons décrire le processus d'entraînement pour chaque modèle utilisé comme suit :

4.4.1 Détection des arbres

Nous avons entraîné et testé notre modèle sur notre dataset, dans le quelle nous avons divisé sur deux partie, 80% Nous avons formé le modèle avec les paramètres d'entraînement décrits dans le tableau 1 puis nous avons utilisé la fonction ModelCheckPoint que son rôle est de sauvegarder automatiquement le modèle qui a les meilleurs performance durant la phase d'entraînement aussi en minimisant la perte sur l'ensemble de test. Cette fonctionnalité nous permet de stocker le meilleur modèle obtenu pour une utilisation ultérieure.

Paramètres	Valeur
Modèle de détection d'arbres	YOLOv5
Epoch	60
Taille du Batch	16

TABLE 4.1 – Paramètres utilisés dans la phase d'entraînement pour la détection des arbres.

4.4.2 Détection des feuilles

Nous avons entraîné et testé notre modèle sur notre dataset, dans le quelle nous avons divisé sur deux partie, 80Nous avons formé le modèle avec les paramètres d'entraînement décrits dans le tableau 2 puis nous avons utilisé la fonction ModelCheckPoint pour sauvegarder automatiquement le meilleur modèle.

Paramètres	Valeur
Modèle de détection des feuilles	YOLOv5
Epoch	60
Taille du Batch	16

TABLE 4.2 – Paramètres utilisés dans la phase d'entraînement pour la détection des feuilles.

4.4.3 Classification des maladies des arbres

Nous avons entraîné et testé notre modèle sur notre dataset, dans le quelle nous avons divisé sur deux partie, 80Nous avons formé le modèle avec les paramètres d'entraînement décrits dans le tableau 3 puis nous avons utilisé la fonction ModelCheckPoint pour sauvegarder automatiquement le meilleur modèle.

Paramètres	Valeur
Modèle de classification	CNN
Epoch	30
Taille du Batch	32
Optimizer	Adam
Fonction d'activation	Softmax
Fonction Loss	SparseCategoricalCrossentropy

TABLE 4.3 – Paramètres utilisés dans la phase d'entraînement pour la classification des maladies.

4.5 Mesures de performance

Nous avons évalué nos modèles en utilisant des mesures de performance bien établies. Pour la classification des maladies, nous avons employé la matrice de confusion, l'accuracy et la loss. En

ce qui concerne la détection d'objets, nous avons opté pour la matrice de confusion, ainsi que la précision, le rappel, le mAP@50 ,le mAP@50-95.

1. Matrice de confusion

Une matrice de confusion est un tableau qui est souvent utilisé pour décrire la performance d'un modèle de classification et présente un résumé des résultats des prédictions du modèle, montrant le nombre de prédictions correctes et incorrectes pour chaque classe.

- True Positive (TP) : si l'arbre est détecté comme malade.
- True Négative (TN) : si l'arbre est détecté correctement comme arbre seine.
- False Positive (FP) : représente une classification incorrecte ou l'arbre est seine et il est détecté comme malade.
- False Négative (FN) : représente une classification incorrecte ou l'arbre est malade et il est détecté comme seine.

Accuracy :

C'est la fraction des prédictions totales qui sont correct.

$$Acc = \frac{\text{True Positives} + \text{True Negatives}}{\text{True Positives} + \text{False Positives} + \text{True Negatives} + \text{False Negatives}}$$

3. Précision

La précision mesure la proportion des prédictions positives correctes parmi toutes les prédictions positives faites par le modèle.

$$Precision = \frac{\text{TruePositives}}{\text{True Positives} + \text{False Positives}}$$

4. Rappel

Le rappel mesure la proportion d'échantillons positifs réellement identifiés parmi tous les échantillons positifs présents dans les données

$$Rappel = \frac{\text{TruePositives}}{\text{True Positives} + \text{FalseNegatives}}$$

5. mAP@50

mesure la moyenne de la précision moyenne (AP) sur plusieurs classes ou un ensemble de données spécifique, calculée à un seuil de d'IoU de 0.5. Cela signifie que la détection est considérée comme correcte si le chevauchement (IoU) entre la boîte prédite et la boîte de vérité terrain est d'au moins 0.5 (50%).

6. mAP@50-95

mAP@50-95" fait référence à la moyenne de la précision moyenne (AP) sur plusieurs classes ou un ensemble de données spécifique, calculée sur une plage de seuils d'Intersection over Union (IoU) allant de 0,5 à 0,95. Cela signifie que la détection est évaluée sur plusieurs seuils IoU, allant de 50% à 95%, pour capturer une gamme de précisions des prédictions de détection d'objets.

4.6 Résultat et discussion

Après l'entraînement de nos modèles, nous avons réussi à obtenir des résultats en matière de détection et de classification. Ces résultats sont montrés dans la Table 4.4 qui présente les valeurs de précision et de perte pour chaque modèle utilisé. Ces résultats prometteurs soulignent la capacité de nos modèles à identifier avec précision les arbres et à classifier les différentes maladies des feuilles. Les valeurs élevées de précision et les faibles valeurs de perte témoignent de la robustesse et de l'efficacité de nos approches.

Modèles	Accuracy (%)	Loss	Précision	Rappel	MAP 50
Détection des arbres		1.35	0.89	0.9	0.86
Détection des feuilles		0.010	0.86	0.88	0.9
Classification des maladies	90.67	4.53			

TABLE 4.4 – Table des Résultats des Modèles de Détection et de Classification des Maladies des Plantes.

4.6.1 Performances

Nous allons évaluer les résultats de nos modèles après la phase d'entraînement.

1. Détection des arbres

Les quatre graphiques de la figure 4.6 illustrent l'évolution des pertes (loss) au cours des itérations d'entraînement et de validation :

- `train/box_loss` : La perte de la boîte englobante commence autour de 1,4 et diminue régulièrement pour atteindre environ 0,6 après 60 époques. Cette diminution indique que le modèle apprend progressivement à prédire les boîtes de délimitation avec plus de précision.
- `train/cls_loss` : La perte de classification commence à environ 1,6 et diminue de manière constante pour atteindre environ 0,6 après 60 époques. Cela suggère que le modèle devient meilleur pour classer correctement les objets dans les images au fil du temps.
- `val/box_loss` : La perte de localisation en validation commence à environ 2,5 et diminue pour atteindre environ 0,8 après 60 époques. Cette courbe montre une amélioration similaire à celle de l'entraînement, ce qui suggère une bonne généralisation du modèle.
- `val/cls_loss` : La perte de classification en validation commence à environ 2,25 et diminue pour atteindre environ 0,7 après 60 époques. La diminution régulière indique que le modèle améliore également ses performances de classification sur les données de validation. Ces courbes démontrent une amélioration continue des performances du modèle, tant pour l'entraînement que pour la validation, ce qui suggère une bonne convergence sans sur-apprentissage (overfitting) apparent.

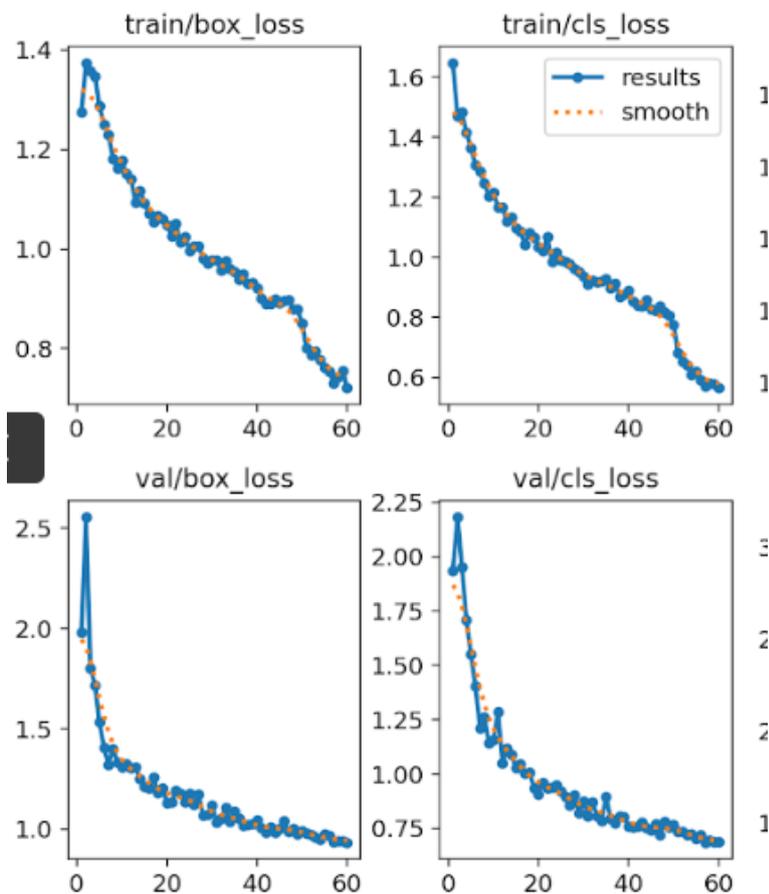


FIGURE 4.6 – Courbes loss d'entraînement et de validation pour yolov5 detction d'arbre.

Les graphiques de la figure 4.7 présentent l'évolution des principales métriques de performance :

- metrics/precision : La précision du modèle pour détecter les arbres commence autour de 0,35 et monte rapidement pour se stabiliser autour de 0,90 après 30 époques. Cela indique que le modèle fait peu de faux positifs, atteignant une précision stable autour de 0,90.
- metrics/recall : Le rappel du modèle, représentant sa capacité à détecter toutes les arbres présentes, commence autour de 0,40 et atteint 0,75 après environ 10 époques, puis se stabilise autour de 0,80. Cela montre que le modèle détecte la majorité des arbres, avec un rappel stable de 0,80.
- metrics/mAP_0.5 : La moyenne des précisions (mAP) à un seuil IoU de 0,5 montre une forte augmentation initiale de 0,30 à 0,85 dans les 10 premières époques, pour atteindre près de 0,90. Cette valeur indique une bonne performance globale en détection à ce seuil.
- metrics/mAP_0.5 :0.95 : La moyenne des précisions (mAP) sur des seuils IoU variés de 0,5 à 0,95 commence autour de 0,25 et monte progressivement pour atteindre 0,55 après 10 époques, se stabilisant autour de 0,65. Bien que plus lente à se stabiliser, elle indique

une performance robuste du modèle dans des conditions variées de détection. Ces courbes confirment l'efficacité du modèle YOLOv5 pour la détection des arbres, avec des performances solides en termes de précision, de rappel et de mAP (Mean Average Precision).

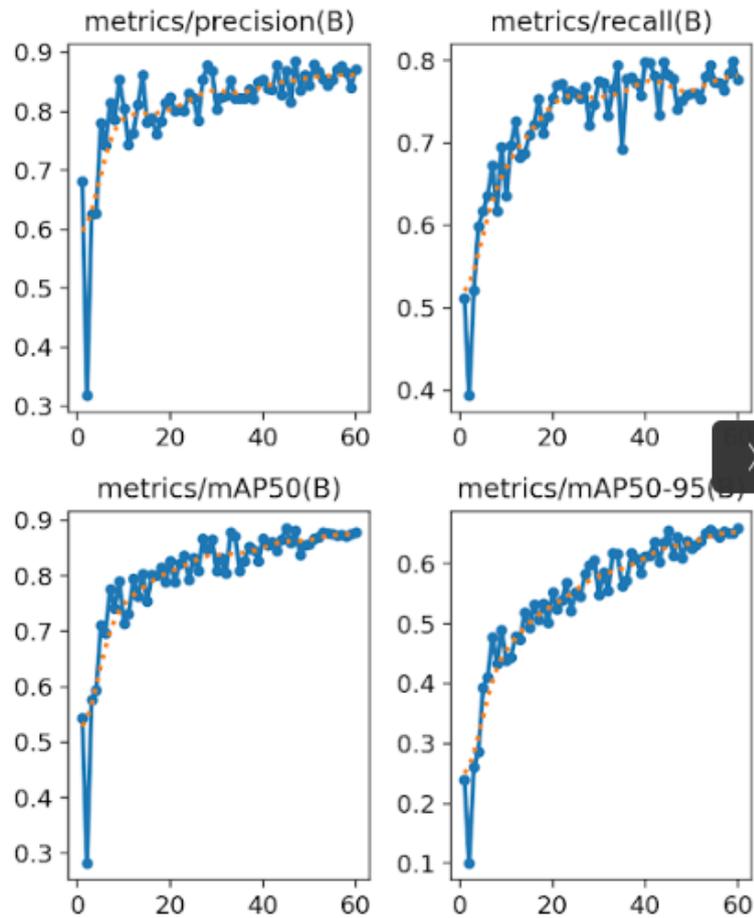


FIGURE 4.7 – Courbes metrics n pour yolov5 détection d'arbre.

La matrice de confusion dans la figure 4.8 montre la performance du modèle en termes de classification des feuilles et du fond :

- Arbre (Tree) : 346 vrais positifs (cellule en haut à gauche) indiquent que le modèle identifie correctement les arbres.
- Fond (Background) : 101 faux positifs (cellule en haut à droite) où les arbres sont classés comme fond, et 63 faux négatifs (cellule en bas à gauche) où le fond est classé comme arbre. Ces erreurs suggèrent une certaine confusion entre les arbres et le fond.

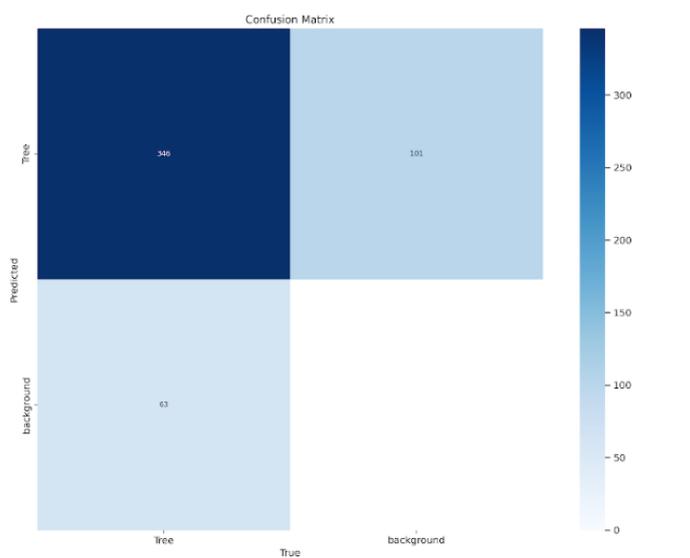


FIGURE 4.8 – matrice de confusion pour yolov5 detction d'arbre.

2. Détection des feuilles

Les graphiques de la figure 4.9 montrent les pertes pour l'entraînement et la validation du modèle, spécifiquement pour la perte de localisation (box loss) et la perte d'objet (obj loss).

— train/box_loss (Perte de localisation) :

La perte de localisation commence à environ 0.09 et diminue rapidement pour se stabiliser autour de 0.03 après environ 20 epochs. Cette diminution indique que le modèle apprend efficacement à prédire les boîtes de délimitation des feuilles.

— train/obj_loss (Perte d'objet) :

La perte d'objet commence à environ 0.048 et diminue régulièrement pour atteindre environ 0.036 après 40 epochs. Cela suggère que le modèle devient de plus en plus précis pour identifier la présence des feuilles dans les images.

— val/box_loss (Perte de localisation en validation) :

La perte de localisation en validation commence à environ 0.045 et diminue pour se stabiliser autour de 0.025 après environ 20 epochs. La tendance similaire à celle de l'entraînement indique une bonne généralisation du modèle pour la localisation des feuilles.

— val/obj_loss (Perte d'objet en validation) :

La perte d'objet en validation commence à environ 0.013 et diminue pour se stabiliser autour de 0.009 après environ 20 epochs. La perte d'objet en validation suit une tendance similaire à celle de l'entraînement, indiquant une bonne performance du modèle en généralisation pour la détection des objets.

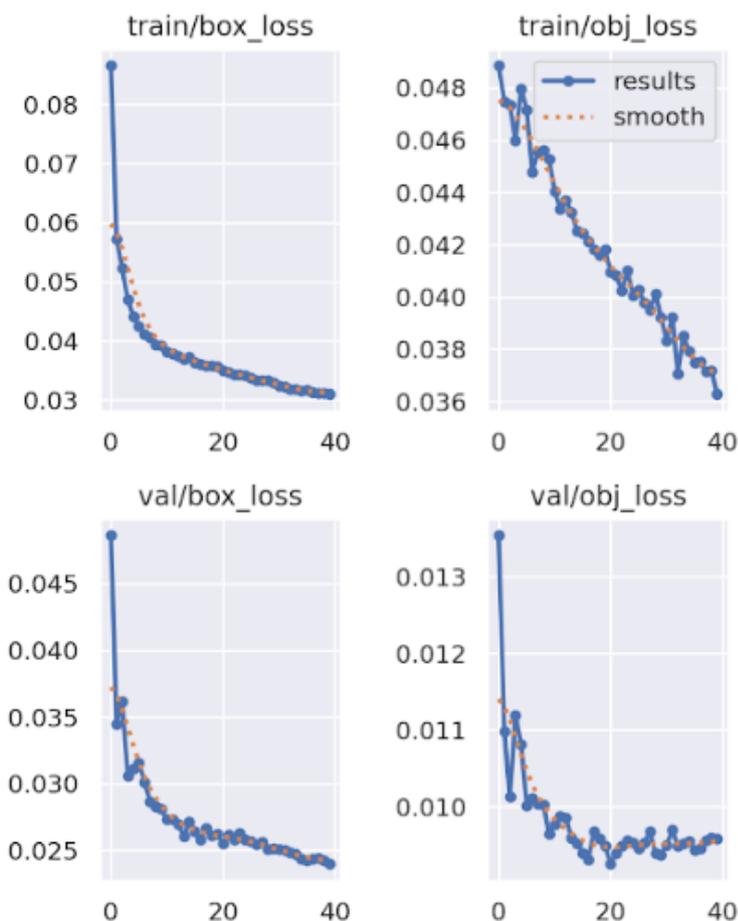


FIGURE 4.9 – Courbes loss d'entraînement et de validation pour yolov5 detction des feuilles.

Les graphiques de la figure 4.10 présentent l'évolution des principales métriques de performance pour la détection des feuilles :

- metrics/precision : Précision du modèle pour détecter les feuilles. La précision commence autour de 0.60 et monte rapidement pour se stabiliser autour de 0.85 après 10 epochs. Ceci indique que le modèle fait peu de faux positifs, atteignant une valeur stable de précision autour de 0.85.
- metrics/recall : Rappel du modèle, représentant sa capacité à détecter toutes les feuilles présentes. Le rappel commence autour de 0.65 et atteint 0.80 après environ 10 epochs, puis se stabilise autour de 0.85. Cela montre que le modèle détecte la majorité des feuilles, avec un rappel stable de 0.85.
- metrics/mAP_0.5 : La moyenne des précisions (mAP) à un seuil IoU de 0.5. La courbe mAP_0.5 montre une forte augmentation initiale de 0.65 à 0.85 dans les premières 10 epochs, pour atteindre près de 0.90. Cette valeur indique une bonne performance globale en détection à ce seuil.
- metrics/mAP_0.5 :0.95 : La moyenne des précisions (mAP) sur des seuils IoU variés de 0.5

à 0.95. - Cette courbe commence autour de 0.35 et monte progressivement pour atteindre 0.55 après 10 epochs, se stabilisant autour de 0.60. - Bien que plus lente à se stabiliser, elle indique une performance robuste du modèle sur des conditions variées de détection.

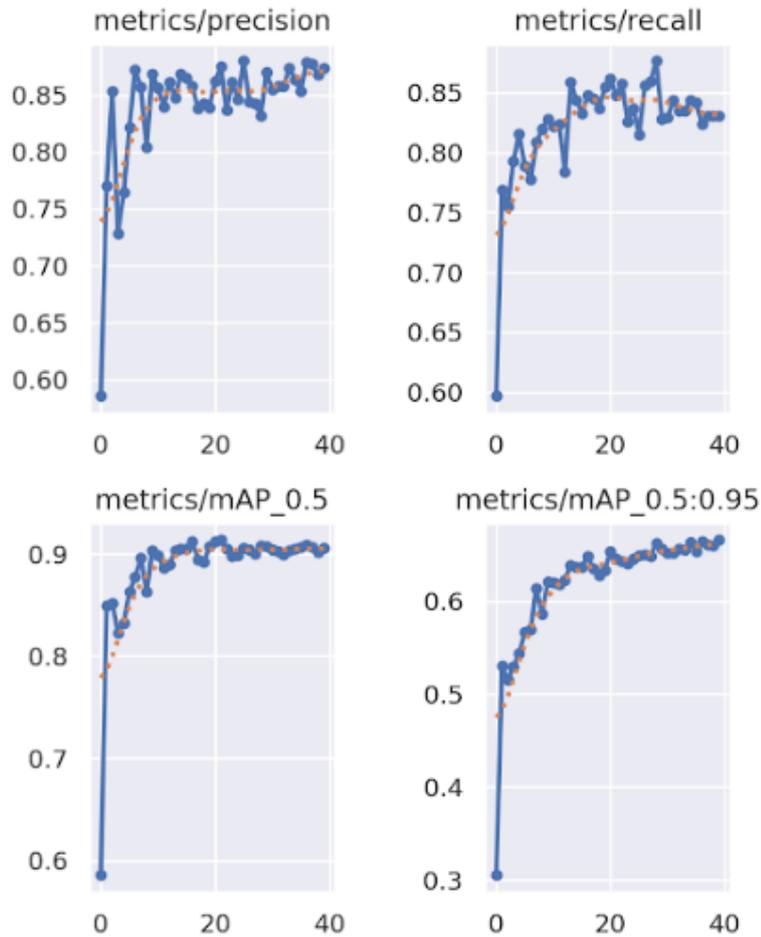


FIGURE 4.10 – Courbes metrics pour yolov5 detction des feuilles.

La matrice de confusion dans la figure 4.11 montre la performance du modèle en termes de classification des feuilles et du fond :

- Feuille (Leaf) : 0.87 vrais positifs (cellule en haut à gauche) montrent que le modèle identifie bien les feuilles.
- Fond (Background) : 1.00 faux positifs (cellule en haut à droite) où des régions de fond sont classées comme feuilles, indiquant une confusion entre le fond et les feuilles. 0.13 faux négatifs (cellule en bas à gauche) où des feuilles sont classées comme fond, montrant que le modèle manque parfois de détecter certaines feuilles.

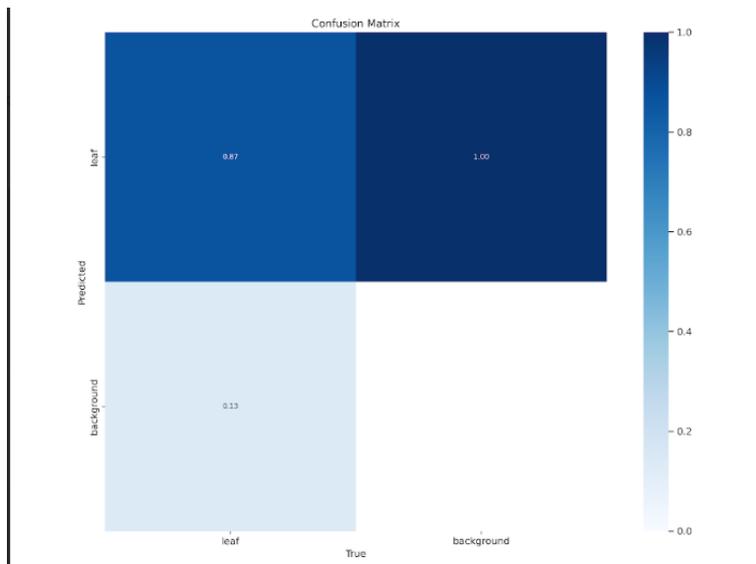


FIGURE 4.11 – Matrice de confusion pour yolo v5 detction des feuilles.

3. Classification des maladies

La figure 4.12 illustre les courbes de précision et de perte d'entraînement et de validation pour le modèle CNN de classification des maladies des arbres. Le modèle CNN a obtenu un résultat satisfaisant après avoir une précision de 90.67 % et perte minimale de 4.53 % autour de 50 itérations.

Pour une analyse complète, la matrice de confusion est présentée dans la figure 9.

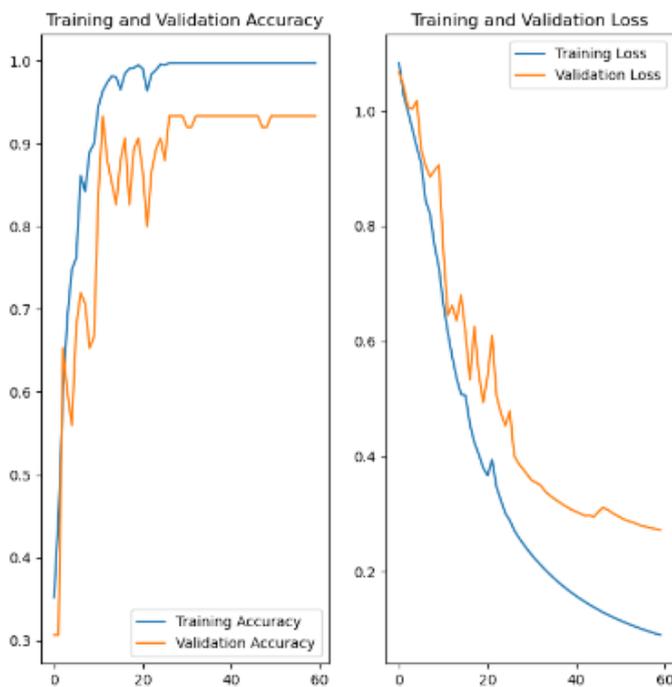


FIGURE 4.12 – Courbes d'accuracy/loss d'entraînement et de validation pour CNN modèle.

Les courbes de perte et de précision montrent que notre modèle CNN se comporte bien. La courbe de précision de l'entraînement augmente rapidement pour atteindre presque 1,0, indiquant que le modèle s'adapte très bien aux données d'entraînement. La précision de validation fluctue initialement puis se stabilise autour de 0,9, ce qui est également très bon. La courbe de perte d'entraînement diminue régulièrement, montrant que le modèle apprend bien les données d'entraînement, tandis que la perte de validation diminue également mais avec quelques fluctuations. Ces résultats suggèrent que le modèle ne présente pas de signes évidents de sous-apprentissage, car les deux précisions augmentent et les pertes diminuent. Bien que la précision de validation soit légèrement inférieure à celle de l'entraînement, elle reste élevée, indiquant que nous n'avons pas de sur-apprentissage excessivement. Les fluctuations initiales dans les courbes de validation peuvent être dues à la variabilité naturelle des données de validation. notre modèle CNN semble bien se comporter à la fois sur les ensembles d'entraînement et de validation, ce qui est un bon indicateur de sa capacité de généralisation.

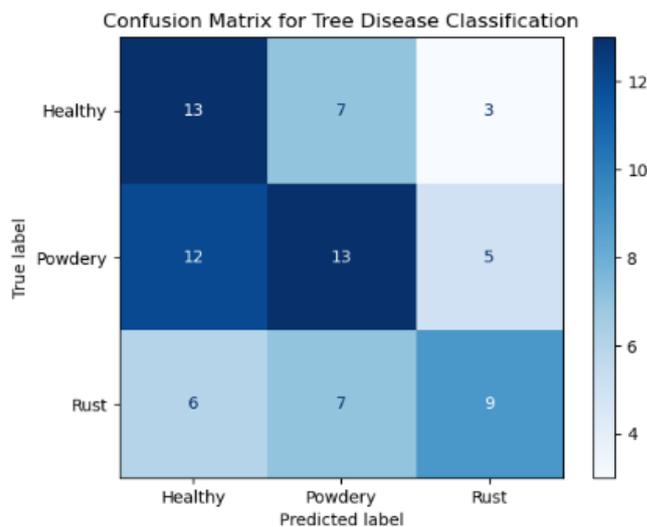


FIGURE 4.13 – matrice de confusion pour le modèle CNN.

la matrice de confusion illustré dans figure 4.13 montre les performances de notre modèle de classification des maladies des arbres. Chaque ligne représente les instances réelles et chaque colonne représente les instances prédites par le modèle. Pour les arbres sains (Healthy), nous avons 13 cas correctement classés comme sains, ce sont les vrais positifs. Cependant, il y a aussi 7 cas de feuilles saines qui ont été incorrectement classées comme ayant l'oïdium (Powdery) et 3 cas classés comme ayant la rouille (Rust). Pour l'oïdium, le modèle a correctement identifié 13 cas. Mais nous avons également 12 instances d'oïdium qui ont été classées à tort comme saines et 5 comme ayant la rouille. Pour la rouille, le modèle a bien identifié 9 cas. Cependant,

6 cas de rouille ont été incorrectement classés comme sains et 7 comme ayant l'oïdium.

4.7 Conclusion

Ce chapitre a présenté le développement d'un système intelligent de surveillance des cultures utilisant des drones et des techniques d'apprentissage profond. Grâce à des modèles de détection d'objets et de classification des maladies des feuilles, nous avons conçu un système capable de fournir des informations précieuses aux agriculteurs. Les résultats démontrent l'efficacité de notre approche pour améliorer la productivité agricole et réduire les pertes dues aux maladies. En intégrant ces technologies, nous ouvrons la voie à des solutions innovantes pour une agriculture de précision.

Chapitre 5

Business Model Canvas

5.1 Introduction

Drone Agriculture est une entreprise innovante dédiée à la surveillance et à la gestion des maladies des arbres à l'aide de drones équipés de capteurs avancés et de technologies d'intelligence artificielle. Notre mission est de révolutionner l'agriculture en offrant des solutions de détection précoce des maladies des arbres, réduisant ainsi les pertes de récoltes et optimisant l'efficacité opérationnelle des agriculteurs, des gestionnaires de plantations et des autorités forestières. Notre projet se distingue par son approche intégrée et innovante, permettant une couverture rapide et précise de vastes zones agricoles et forestières, même dans des régions difficiles d'accès.

5.2 Proposition de valeur

5.2.1 Quels problèmes résolvons-nous pour nos clients ?

Notre projet de surveillance des maladies des arbres à l'aide de drones résout plusieurs problèmes cruciaux pour nos clients, notamment les agriculteurs, les gestionnaires de plantations, et les autorités forestières. Il permet une détection précoce des maladies, réduisant ainsi les pertes et les coûts de main-d'œuvre grâce à l'automatisation des inspections. Les drones équipés de capteurs avancés améliorent la précision des diagnostics, couvrent de vastes zones, et accèdent à des régions difficiles d'accès. Cela optimise l'utilisation des ressources en fournissant des informations précises sur l'état de santé des arbres et soutient la prise de décision en fournissant des rapports détaillés et des visualisations des données, aidant à améliorer la santé et la productivité des arbres de manière durable.

5.2.2 Quels besoins de nos clients satisfont nos produits ou services ?

Nos produits et services répondent aux besoins essentiels de nos clients en permettant une surveillance continue et précise de la santé des arbres, réduisant ainsi les pertes agricoles par une détection précoce des maladies. Ils optimisent l'efficacité opérationnelle en remplaçant les méthodes manuelles par l'utilisation de drones, accessibles même dans des zones difficiles. Grâce à des modèles d'intelligence artificielle avancés, nous fournissons des diagnostics fiables et des rapports détaillés, facilitant une prise de décision informée. En fournissant des informations précises, nous aidons à planifier et cibler les traitements phytosanitaires de manière optimale, répondant ainsi aux besoins de précision, d'efficacité et de réduction des coûts de nos clients.

5.2.3 En quoi notre offre est-elle différente de celle de nos concurrents ?

Notre solution n'a pas de rival direct en Algérie, ce qui en fait une offre unique. L'offre de notre système Drone Agriculture de surveillance et de classification des maladies des arbres se distingue par son approche intégrée et innovante, combinant l'utilisation de drones, de modèles d'intelligence artificielle avancés et de technologies de communication robustes. Contrairement à d'autres solutions qui peuvent se concentrer uniquement sur un aspect particulier de la gestion des arbres, notre système couvre l'ensemble du processus, de la détection des arbres à la classification précise des maladies des feuilles. En utilisant des drones équipés de capteurs sophistiqués, notre solution permet une couverture rapide et précise de vastes zones, y compris des terrains difficiles d'accès, tout en fournissant des diagnostics fiables et des rapports détaillés. Cette approche holistique répond de manière exhaustive aux besoins des agriculteurs et gestionnaires forestiers, optimisant ainsi l'efficacité opérationnelle et réduisant les coûts associés à la gestion des maladies des arbres.

5.2.4 Quelle est notre proposition unique de valeur ?

La proposition unique de valeur de Drone Agriculture réside dans son intégration innovante de la détection des arbres, la classification des maladies des feuilles et l'analyse en temps réel des données collectées. Cette solution est à la pointe de la technologie, offrant une solution novatrice pour la classification des maladies des arbres. Conçu pour être intuitif et facile à utiliser, notre appareil ne nécessite pas de compétences techniques avancées. C'est une solution abordable qui ne sacrifie pas la qualité, permettant à un plus grand nombre de clients d'en bénéficier. Nous fournissons un service complet pour assurer la satisfaction et répondre aux besoins de nos clients.

5.3 Segments de clients

5.3.1 Quels sont nos clients principaux ?

Les clients principaux de Drone Agriculture sont les agriculteurs qui ont de vastes zones agricoles.

5.3.2 Quels sont les différents segments de clients que nous visons ?

- Les agriculteurs et les exploitants agricoles qui gèrent de grandes plantations et vergers.
- Les gestionnaires forestiers et les responsables de la sylviculture, qui peuvent bénéficier de notre technologie.
- Les institutions de recherche agricole.
- Les entreprises fournissant des services agricoles et les coopératives agricoles représentent un autre segment de clients potentiel.

5.3.3 Quels sont les besoins spécifiques de chaque segment de clients ?

- **Agriculteurs et exploitants agricoles** : Ils recherchent des outils qui permettent une détection précoce des problèmes phytosanitaires, réduisant ainsi les pertes de récoltes et les coûts associés aux traitements tardifs.
- **Gestionnaires forestiers et responsables de la sylviculture** : Ils recherchent des systèmes capables de détecter rapidement les maladies des arbres, même dans des zones vastes et difficiles d'accès. Ils ont également besoin de données précises pour prendre des décisions informées sur la gestion forestière.
- **Institutions de recherche agricole** : Ils recherchent des outils capables de fournir des données précises et détaillées, ainsi que des analyses complètes pour soutenir leurs recherches.
- **Entreprises fournissant des services agricoles et coopératives agricoles** : Ils recherchent des technologies qui leur permettent de surveiller les cultures de leurs clients de manière proactive, d'identifier rapidement les problèmes de santé des plantes, et de fournir des recommandations basées sur des données fiables.

5.3.4 Comment pouvons-nous catégoriser nos clients en groupes distincts ?

Pour catégoriser nos clients en groupes distincts, nous pouvons prendre en compte plusieurs critères, notamment la taille et le type d'exploitation agricole, les besoins spécifiques en surveillance et en gestion des cultures, le niveau de connaissance technologique, et le rôle des institutions ou

entreprises dans le secteur agricole. En utilisant ces critères, nous pouvons créer des segments de clients spécifiques qui nécessitent des solutions adaptées à leurs besoins et à leurs capacités.

5.4 Relation avec les clients

5.4.1 Quel type de relation chaque segment de clients attend-il de nous ?

- **Agriculteurs et exploitants agricoles** : Ils attendent un support technique personnalisé pour maximiser l'efficacité de notre solution. Ils souhaitent une assistance dédiée pour l'installation, l'utilisation et la maintenance de nos systèmes.
- **Gestionnaires forestiers et responsables de la sylviculture** : Ils attendent une consultation experte pour adapter notre technologie à leurs besoins spécifiques.
- **Institutions de recherche agricole** : Elles attendent une collaboration étroite en matière de recherche et développement. Elles souhaitent participer à l'amélioration et à la personnalisation des solutions pour répondre à leurs objectifs de recherche.
- **Entreprises fournissant des services agricoles et coopératives agricoles** : Elles attendent un support client réactif pour résoudre rapidement les problèmes et répondre à leurs questions. Elles souhaitent une communication fluide et efficace pour garantir la satisfaction de leurs clients finaux.

5.4.2 Comment entretenons-nous actuellement les relations avec nos clients ?

- Nous fournissons une assistance technique dédiée et un service client disponible pour répondre rapidement aux questions et résoudre les problèmes. Nos experts sont joignables via plusieurs canaux de communication pour garantir une réponse rapide et efficace.
- Nous offrons des mises à jour annuelles gratuites pour nos systèmes afin de garantir qu'ils restent à la pointe de la technologie et continuent de fonctionner de manière optimale. Ces mises à jour incluent des améliorations logicielles et de nouvelles fonctionnalités basées sur les retours des utilisateurs.
- Nous proposons des programmes de formation pour nos clients, afin de leur permettre de comprendre et d'utiliser efficacement nos technologies. Ces programmes sont adaptés aux différents niveaux de compétence des utilisateurs et incluent des tutoriels, des webinaires et des ateliers pratiques.
- Nous nous efforçons de proposer des solutions qui se distinguent par leur design pratique et leur coût abordable, répondant ainsi aux attentes de nos clients en termes d'efficacité et de

budget. Cette approche nous aide à maintenir une relation positive et durable avec nos clients.

5.4.3 Comment pouvons-nous améliorer ou personnaliser nos interactions avec nos clients ?

- Offrir des services personnalisés en fonction des besoins spécifiques de chaque client, tels que des recommandations d'outils et de techniques adaptées à leurs cultures spécifiques.
- Développer un portail en ligne dédié où les clients peuvent accéder à leurs données, suivre leurs commandes, et obtenir des mises à jour sur les nouvelles fonctionnalités et services.
- Mettre en place un système de support technique proactif qui surveille les performances des systèmes des clients et anticipe les problèmes avant qu'ils ne surviennent.
- Introduire un programme de fidélité qui récompense les clients réguliers avec des avantages exclusifs, tels que des réductions supplémentaires, des consultations gratuites, ou des accès anticipés aux nouvelles fonctionnalités.
- Envoyer régulièrement des enquêtes de satisfaction et des demandes de feedback pour recueillir des informations précieuses sur l'expérience des clients et identifier les domaines d'amélioration.
- Offrir des consultations personnalisées avec des experts pour discuter des défis spécifiques que rencontrent les clients et proposer des solutions adaptées.

5.5 Canaux de distribution

5.5.1 Par quels canaux nos clients veulent-ils être atteints ?

Les clients veulent souvent être atteints par une variété de canaux, y compris les magasins physiques, les affiches publicitaires, les plateformes en ligne, des annonces ciblées sponsorisées sur les réseaux sociaux, les centres d'appels, les services de messagerie et la participation à des expositions. Chaque canal offre une expérience unique, et il est important de comprendre les préférences de chaque segment de clients pour choisir les canaux les plus efficaces pour atteindre et servir nos clients.

5.5.2 Quels canaux sont les plus efficaces pour atteindre chaque segment de clients ?

- **Agriculteurs et exploitants agricoles :**

- Vente en ligne : Plateformes de commerce électronique avec des descriptions détaillées et des témoignages d'autres agriculteurs.
- Publications agricoles : Annonces et articles dans des magazines et journaux agricoles.
- **Gestionnaires forestiers et responsables de la sylviculture :**
 - Conférences et séminaires : Participation à des événements spécialisés pour démontrer les avantages et les utilisations de notre technologie.
 - Webinaires : Sessions en ligne pour expliquer les bénéfices et les fonctionnalités de notre système.
- **Institutions de recherche agricole :**
 - Collaboration directe : Propositions de partenariats pour des projets de recherche et des études de cas.
 - Publications scientifiques : Articles et études dans des revues académiques pour présenter les résultats et les avancées technologiques.
- **Entreprises fournissant des services agricoles et coopératives agricoles :**
 - Vente en ligne : Plateformes de commerce électronique avec des options de démonstration de produits.
 - Présentations en entreprise : Démonstrations sur site pour montrer l'efficacité et les bénéfices de notre solution.
 - Participation à des expositions : Avec des démonstrations interactives et du matériel en braille.

5.5.3 Comment pouvons-nous intégrer différents canaux pour améliorer l'expérience client ?

- Combiner magasins et vente en ligne : Offrir une expérience omni canal où les clients peuvent essayer les produits en magasin et les acheter en ligne. Par exemple, permettre aux clients de scanner un code QR en magasin pour en savoir plus sur le produit et l'acheter en ligne.
- Utiliser les réseaux sociaux pour sensibiliser et rediriger : Utiliser des annonces ciblées sur les réseaux sociaux pour diriger les clients vers des ressources en ligne ou des événements en magasin.
- Affiches publicitaires avec codes QR : Placer des affiches publicitaires avec des codes QR qui mènent directement aux pages produits en ligne ou à des informations supplémentaires.
- Participer à des expositions et événements : Présenter nos produits et recueillir des retours directs des clients pour améliorer continuellement nos offres. Utiliser ces événements pour

promouvoir la vente en ligne et les magasins physiques.

- **Support client intégré** : Offrir un support client accessible via téléphone, chat en ligne et email pour répondre aux questions et assister les clients quel que soit le canal utilisé pour l'achat.
- **Programme de fidélité intégré** : Créer un programme de fidélité qui récompense les achats effectués sur tous les canaux, encourageant ainsi une utilisation multiple des canaux disponibles.

5.6 Partenaires clés

5.6.1 Qui sont nos partenaires clés ?

- **Les fournisseurs** : Ils fournissent les composants nécessaires pour la fabrication de nos appareils.
- **Société d'impression de circuits imprimés** : Fournit les circuits électroniques essentiels pour le fonctionnement de nos produits.
- **Société d'injection plastique et d'impression 3D** : Produit les boîtiers et autres composants en plastique de nos appareils.
- **Compagnie de livraison et d'emballage** : Assure la distribution et l'emballage de nos produits pour les livrer aux clients.

5.6.2 Quels sont les partenariats qui nous aident à réduire les coûts, à accéder à de nouvelles ressources ou à améliorer notre proposition de valeur ?

- **Les fournisseurs** : Des accords à long terme avec nos fournisseurs peuvent permettre des réductions de coûts sur les composants et garantir une qualité constante.
- **Société d'impression de circuits imprimés** : Ce partenariat nous permet d'accéder à des technologies avancées pour la production de circuits imprimés de haute qualité à des coûts réduits grâce à des économies d'échelle.
- **Société d'injection plastique et d'impression 3D** : En travaillant étroitement avec cette société, nous pouvons réduire les coûts de production des boîtiers en plastique et améliorer la qualité et le design de nos produits grâce à des technologies d'impression 3D avancées.
- **Compagnie de livraison et d'emballage** : Un partenariat avec une compagnie de livraison et d'emballage efficace réduit les coûts de logistique et améliore la rapidité et la fiabilité des

livraisons, ce qui améliore l'expérience client.

5.6.3 Comment pouvons-nous aligner nos intérêts avec ceux de nos partenaires ?

- **Établir des contrats à long terme** : Offrir des contrats à long terme avec des conditions mutuellement bénéfiques peut assurer la stabilité et la prévisibilité pour les deux parties, tout en permettant des réductions de coûts grâce à des engagements de volume.
- **Collaboration et communication régulières** : Maintenir des canaux de communication ouverts et réguliers pour partager des informations sur les prévisions de demande, les innovations technologiques et les retours clients. Cela peut aider à ajuster les processus et à répondre rapidement aux changements du marché.
- **Co-développement de produits** : Travailler en partenariat avec nos fournisseurs et sociétés de fabrication pour développer de nouveaux produits ou améliorer les produits existants peut aligner nos objectifs en termes de qualité et d'innovation.
- **Programmes de partage de profits et d'incitations** : Mettre en place des programmes qui partagent les bénéfices et offrent des incitations basées sur les performances, comme des bonus pour le respect des délais de livraison ou l'amélioration de la qualité des composants.
- **Partage des connaissances et formation** : Organiser des sessions de formation et d'échange de connaissances pour améliorer les compétences des partenaires et s'assurer qu'ils sont à jour avec les dernières technologies et processus, ce qui peut conduire à des améliorations continues de la qualité et de l'efficacité.
- **Évaluations et feedback réguliers** : Effectuer des évaluations régulières des performances des partenaires et fournir des feedbacks constructifs pour améliorer continuellement les processus et les relations.

5.7 Activités clés

5.7.1 Quelles sont les actions principales que nous devons entreprendre pour livrer notre proposition de valeur ?

Pour livrer notre proposition de valeur dans le domaine de l'agriculture basée sur les drones, plusieurs actions clés sont essentielles. Tout d'abord, nous devons continuer à développer et intégrer des technologies de drones avancées, spécifiquement adaptées à la détection des maladies des arbres

et à la surveillance des cultures. Cela comprend l'installation précise des capteurs et des caméras pour assurer la collecte de données de haute qualité. En parallèle, nous devons établir des systèmes robustes pour la collecte continue de données agricoles et les analyser de manière approfondie. Le traitement de ces données à l'aide de techniques avancées d'apprentissage automatique et de vision par ordinateur est crucial pour fournir des informations précieuses aux agriculteurs, comme la détection précoce des maladies et les recommandations agronomiques. Parallèlement, il est primordial de développer des modèles prédictifs afin de prévoir les conditions futures et d'optimiser les pratiques agricoles. En outre, fournir une formation approfondie et un soutien continu aux utilisateurs des drones est essentiel pour assurer une utilisation efficace et maximiser les avantages pour nos clients agricoles. Enfin, établir des partenariats stratégiques et étendre notre réseau pour collaborer avec des institutions agricoles et des entreprises du secteur renforcera notre capacité à répondre aux besoins variés et évolutifs du marché agricole.

5.7.2 Quelles sont les opérations essentielles pour notre entreprise ?

- **Recherche et développement (R&D)** : Investir dans la R&D pour développer de nouvelles technologies et améliorer les produits existants.
- **Production et fabrication** : Gérer la production pour assurer des niveaux élevés de qualité et de contrôle des coûts.
- **Gestion des fournisseurs et de la chaîne d'approvisionnement** : Maintenir des relations solides avec les fournisseurs pour garantir la disponibilité et la qualité des matériaux.
- **Logistique et distribution** : Optimiser la logistique pour assurer une livraison rapide et fiable des produits à nos clients.
- **Marketing et ventes** : Promouvoir nos produits et atteindre nos clients cibles grâce à des campagnes de marketing efficaces.
- **Service client et support après-vente** : Assurer un service client de qualité pour répondre aux questions, résoudre les problèmes et offrir des services de mise à jour et de maintenance.

5.7.3 Quelles sont les activités qui créent le plus de valeur pour nos clients ?

- Développer des produits innovants qui offrent des solutions uniques et efficaces aux problèmes de nos clients.
- Assurer une haute qualité dans la fabrication des produits pour garantir leur fiabilité et leur durabilité.

- Offrir des options de personnalisation pour répondre aux besoins spécifiques de chaque segment de clients.
- Fournir un support technique exceptionnel pour aider les clients à utiliser nos produits de manière optimale.
- Maintenir des prix compétitifs tout en offrant une haute qualité, ce qui rend nos produits accessibles à un plus grand nombre de clients.
- Concevoir des produits intuitifs et faciles à utiliser pour garantir une adoption rapide et une satisfaction élevée des clients.

5.8 Ressources clés

5.8.1 Quels sont nos actifs matériels, immatériels et humains essentiels ?

Matériels

- Drones équipés de caméras multispectrales : Utilisés pour la collecte d'images haute résolution des champs.
- Capteurs de précision : Mesurent des paramètres comme l'humidité du sol, la température et la santé des plantes.
- Stations de base : Pour le traitement des données et l'analyse des images collectées.
- Ordinateurs robustes : Avec des capacités de traitement avancées pour l'analyse des données en temps réel.
- Logiciels de cartographie et d'analyse : Pour interpréter les données collectées et fournir des insights précis.

Immatériels

- Algorithmes d'intelligence artificielle : Développés pour la détection précoce des maladies des cultures et la gestion des rendements.
- Propriété intellectuelle : Comprenant des brevets sur les technologies de traitement d'image et d'analyse de données agricoles.
- Marque et réputation : Construites autour de la fiabilité et de l'efficacité de nos solutions dans le domaine de l'agriculture de précision.

Humains

- Ingénieurs agricoles : Experts dans la mise en œuvre et l'optimisation des technologies de drone pour l'agriculture.

- Data scientists : Responsables de l'analyse des données agricoles pour générer des recommandations basées sur les données.
- Équipe de support client : Assurant une assistance continue aux utilisateurs des technologies de drone agricole.
- Partenaires stratégiques : Tels que des chercheurs et des agronomes, contribuant à l'innovation et à la validation des solutions.

5.8.2 Quels sont les outils, les technologies ou les partenariats dont nous avons besoin pour réussir ?

Outils et technologies

- Environnement de développement intégré (IDE) : Pour programmer les microcontrôleurs Jetson Nano et composants de drone.
- Outils de prototypage : Imprimantes 3D pour créer des prototypes de boîtiers et de composants.
- Plateformes de gestion de projet : Pour coordonner le développement et la production.

Partenariats

- Fournisseurs de composants électroniques : Pour garantir l'approvisionnement continu en Jetson Nano, composants du drone.
- Sociétés d'injection plastique et d'impression 3D : Pour produire les boîtiers et autres composants en plastique.
- Compagnies de livraison et d'emballage : Pour assurer une logistique efficace et une distribution fiable des produits finis.
- Institutions de recherche et développement : Collaborations pour rester à la pointe de l'innovation technologique.

5.8.3 Quels sont les principaux avantages concurrentiels de nos ressources ?

- Programmeurs et ingénieurs agricoles expérimentés : Notre équipe technique est capable de développer et de maintenir des solutions innovantes et de haute qualité.
- Jetson Nano : Ce module offre une haute performance pour la détection des arbres et la classification de leurs maladies tout en étant abordable et compact.
- Batterie rechargeable : Permet une utilisation autonome et portable de nos appareils, ce qui augmente leur praticité pour les utilisateurs.

- Propriété intellectuelle : Nos brevets et autres protections immatérielles nous protègent de la concurrence et augmentent notre valeur de marché.
- Partenariats solides : Nos relations avec les fournisseurs, les sociétés de fabrication et les compagnies de livraison garantissent une production et une distribution efficaces et économiques.

5.9 Charges et coûts

5.9.1 Quels sont les coûts fixes et variables associés à notre modèle économique ?

Coûts fixes

- Salaires des ingénieurs : 50 000 DA (fixe indépendamment du volume de production)
- Frais de commercialisation : 12 000 DA (fixe pour les campagnes et promotions)
- Coûts de location des locaux et des infrastructures : Variable selon la région et les installations utilisées
- Maintenance des équipements et infrastructures : Coût régulier pour maintenir les machines et les bureaux opérationnels

Coûts variables

- Prix de la matière première : 14 000 DA par unité produite
- Coût de livraison : 1 000 DA par produit livré
- Prix des services d'impression de circuits et d'impression plastique : Variable selon la demande et le volume de production

5.9.2 Quels sont les coûts les plus importants pour notre entreprise ?

- Salaires des ingénieurs : 50 000 DA, étant un coût fixe et essentiel pour le développement et l'innovation.
- Prix de la matière première : 14 000 DA par unité, représentant une part importante des coûts de production.
- Frais de commercialisation : 12 000 DA, essentiels pour atteindre et attirer des clients.
- Prix des services d'impression de circuits et d'impression plastique : Variables mais importants pour la fabrication des produits.

5.9.3 Comment pouvons-nous réduire les coûts ou améliorer l'efficacité de nos opérations ?

- Obtenir des réductions de prix pour la matière première en négociant des contrats à long terme ou en achetant en plus grandes quantités pour bénéficier d'économies d'échelle.
- Investir dans des machines et des technologies qui automatisent des étapes de production pour réduire les coûts de main-d'œuvre et augmenter l'efficacité.
- Travailler avec des compagnies de livraison pour négocier des tarifs réduits sur le volume ou optimiser les routes de livraison pour réduire les coûts de transport.
- Utiliser des méthodes de marketing numérique plus ciblées et moins coûteuses, comme les campagnes sur les réseaux sociaux, pour atteindre un public plus large à moindre coût.
- Collaborer avec des partenaires spécialisés pour certaines parties de la production ou du développement, ce qui peut être plus économique que de tout faire en interne.
- Établir des partenariats avec des fournisseurs locaux pour réduire les coûts de transport et de livraison des matériaux.
- Offrir des formations et des incitations pour augmenter la productivité des ingénieurs et du personnel, ainsi que revoir les structures salariales et les avantages pour attirer et retenir les talents sans surpayer.

5.10 Revenus

5.10.1 Quels produits ou services nos clients sont-ils prêts à payer ?

- Drones équipés de capteurs avancés capables de cartographier les terres agricoles et surveiller la santé des cultures de manière précise et en temps réel.
- Services qui fournissent une analyse approfondie des données agricoles collectées par les drones, y compris des recommandations pour optimiser les pratiques agricoles.
- Services de pulvérisation précise des pesticides ou engrais, permettant une utilisation plus efficace des intrants agricoles tout en minimisant l'impact environnemental.
- Offres comprenant des formations sur l'utilisation des technologies de drones, ainsi qu'un support technique fiable pour résoudre les problèmes rapidement.

5.10.2 Quels sont les différents moyens par lesquels nous pouvons générer des revenus ?

- Ventes directes de produits : Proposer des drones équipés de capteurs spécialisés pour la cartographie, la surveillance des cultures, la pulvérisation précise, etc.
- Services complémentaires : Offrir des services basés sur l'analyse des données collectées par les drones, avec des rapports détaillés sur la santé des cultures et des recommandations pour les agriculteurs.
- Abonnements et services basés sur l'utilisation : Mettre en place des modèles d'abonnement pour l'accès à des plateformes logicielles de gestion des données agricoles et de surveillance des cultures.
- Formation et consultation : Proposer des services de formation pour les agriculteurs sur l'utilisation des drones, ainsi que des consultations personnalisées pour optimiser leurs pratiques agricoles.
- Modèles d'abonnement : Proposer des abonnements mensuels ou annuels pour l'accès à des fonctionnalités supplémentaires ou à un support premium.

5.10.3 Quel est notre modèle de tarification ?

- **Prix du produit** : 95 000 DA par unité.
- **Ventes des premiers mois** : Environ 15 produits vendus, équivalents à un revenu de 1 425 000 DA.
- **Total** : 10 000 000 DA de ventes réalisées, ce qui peut indiquer une réduction de prix ou des promotions initiales pour stimuler les ventes au début du lancement du produit.

5.11 Conclusion

La proposition de valeur de Drone Agriculture se distingue par son approche innovante et intégrée, combinant l'utilisation de drones et d'intelligence artificielle pour offrir une surveillance précise et efficace des maladies des arbres. En répondant aux besoins spécifiques de nos divers segments de clients, nous fournissons des solutions abordables et faciles à utiliser qui améliorent significativement la gestion des cultures et des forêts.

Notre engagement envers l'innovation, la qualité et le support client nous permet de maintenir des relations solides et durables avec nos clients, garantissant leur satisfaction et leur succès à long terme. En continuant à évoluer et à nous adapter aux exigences changeantes du secteur agricole, nous

aspire à devenir un leader dans la surveillance des maladies des arbres par drone, contribuant ainsi à une agriculture plus durable et efficace.

En conclusion, Drone Agriculture offre non seulement une technologie de pointe mais aussi un partenariat stratégique pour les agriculteurs et gestionnaires forestiers, leur permettant d'optimiser leurs opérations et de protéger leurs cultures de manière proactive et durable.

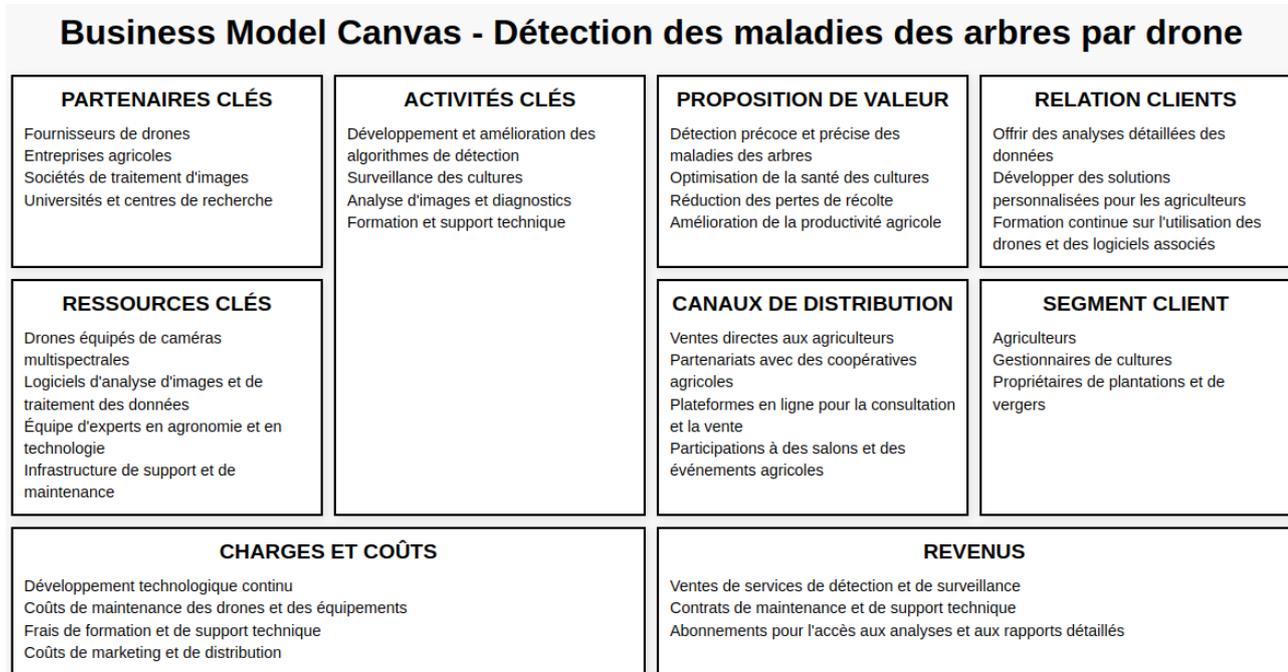


FIGURE 5.1 – Business Model Canvas

Conclusion Générale

Le développement et l'implémentation d'un système intelligent de surveillance des cultures à l'aide de drones et de techniques d'apprentissage profond constituent une avancée significative dans le domaine de l'agriculture de précision. Tout au long de ce travail, nous avons conçu et mis en œuvre un système capable de détecter et d'analyser des arbres et leurs feuilles, puis de classifier les maladies des feuilles, fournissant ainsi des informations précieuses pour les agriculteurs.

Les étapes de notre projet ont inclus l'utilisation de modèles de détection d'objets tels que YOLOv5 pour identifier les arbres et les feuilles, ainsi que du modèle CNN pour la classification des maladies. Les datasets utilisés, notamment Tree-Detection, PlantDoc et Plant Disease, ont permis de former et d'évaluer nos modèles de manière efficace, garantissant ainsi des résultats précis et fiables.

Nous avons intégré ces modèles dans un système embarqué basé sur le NVIDIA Jetson, connecté à un drone pour la collecte de données en temps réel. L'utilisation de ROS2 pour la communication entre les différents composants du système et de Django pour l'interface utilisateur a permis de créer une solution complète et fonctionnelle. Ce système offre une plateforme intuitive pour les agriculteurs, leur permettant de surveiller l'état de santé de leurs cultures de manière proactive et de prendre des décisions informées pour la gestion des maladies.

Les résultats obtenus montrent que notre approche est prometteuse pour améliorer la productivité agricole et réduire les pertes dues aux maladies des plantes. Cependant, des améliorations et des extensions futures sont possibles, telles que l'intégration de modèles plus avancés, l'élargissement des datasets pour inclure davantage de types de cultures et de maladies, et l'optimisation de la consommation d'énergie pour une utilisation prolongée sur le terrain.

Ce projet démontre la puissance des technologies de l'intelligence artificielle et des drones pour révolutionner l'agriculture moderne, en offrant des solutions pratiques et efficaces pour la surveillance et la gestion des cultures. Nous espérons que notre travail contribuera à inspirer de nouvelles recherches et innovations dans ce domaine en constante évolution.

Bibliographie

- [1] MDPI. Applications of drones in agriculture. *MDPI Agriculture*, 11(8) :707, 2021.
- [2] GeeksforGeeks. Deep belief network (dbn) in deep learning. <https://www.geeksforgeeks.org/deep-belief-network-dbn-in-deep-learning/>.
- [3] DataCamp. Yolo : Object detection explained. <https://www.datacamp.com/blog/yolo-object-detection-explained>.
- [4] Dronelec. Châssis f450. <https://www.dronelec.com/c/p/5-chassis-f450>.
- [5] Amazon. Techtonics a2212 1000kv brushless quadcopter motor. <https://www.amazon.in/Techtonics-A2212-1000kV-Brushless-Quadcopter/dp/B07QD7F2JW>.
- [6] DZduino. Xxd hw30a 30a moteur brushless esc. <https://www.dzduino.com/xxd-hw30a-30a-moteur-brushless-esc-fr>.
- [7] Uxcell. Propellers 2-vane airplane adapter. <https://www.amazon.com/uxcell-Propellers-2-Vane-Airplane-Adapter/dp/B07YYTSSJW>.
- [8] DZduino. 11.1v 3s 5200mah 35c lipo battery with xt60. <https://www.dzduino.com/rc-drones-en/111v-3s-5200mah35c-lipo-battery-with-xt60-en>.
- [9] Amazon. Xt-60 board power indicators. <https://www.amazon.com/XT-60-Board-Power-Indicators-Compatible/dp/B09FSB2G55>.
- [10] uBuy. Flysky fs-i6 afhds 2a 2.4ghz 6ch radio system transmitter. <https://www.algeria.ubuy.com/fr/product/2G82V54-flysky-fs-i6-afhds-2a-2-4ghz-6ch-radio-system-transmitter-for-rc-helicopter-glider-with-fs-ia6-receiver-mode-2>.
- [11] Made in China. Flight controller supplier : Pixhawk 2.4.8 px4 32 bits 915mhz telemetry. https://fr.made-in-china.com/co_xingkaitech/product_Flight-Controller-Supplier-Pixhawk-2-4-8-Px4-32-Bits-915MHz-Telemetry-4G-SD-Safety-Switch-Flight-Controller-with-Import-M8n-GPS_yosuyuyeg.html.

- [12] Robotistan. Imx219-83 stereo binoculars camera module with depth sensing 8mp. <https://www.robotistan.com/imx219-83-stereo-binoculars-camera-module-with-depth-sensing-8mp>.
- [13] uBuy. Qwinout mini m8n gps module neo-m8n gps. <https://www.algeria.ubuy.com/fr/product/3NZBOGLEC-qwinout-mini-m8n-gps-module-neo-m8n-gps-for-apm-2-6-2-8-pix-px4-2-4-6-pixhawk-flight-controller-diy-rc-drone>.
- [14] NVIDIA. Jetson nano. <https://www.nvidia.com/fr-fr/autonomous-machines/embedded-systems/jetson-nano/product-development/>.
- [15] Multi-Rotor Fans Club. Flight controller discussion. <https://multi-rotor-fans-club.com/viewtopic.php?t=18849start=525>.
- [16] ArduPilot. Frame type configuration. <https://ardupilot.org/copter/docs/frame-type-configuration.html>.
- [17] ArduPilot. Compass calibration in mission planner. <https://ardupilot.org/copter/docs/common-compass-calibration-in-mission-planner.html>.
- [18] R. Sonnard and F. Araldi. Protocole et suivi phytosanitaire du biodiverger (2017-2022). 2022.
- [19] Province du Brabant wallon. *Brochure : Maladies et ravageurs de plantes*. 2018.
- [20] Kaggle. Plant disease dataset. <https://www.kaggle.com/datasets/ahmedashrafhelmi/plant-disease>.
- [21] L. Deng and D. Yu. Deep learning : Methods and applications. *Foundations and Trends in Signal Processing*, 7 :197–387, 2014.
- [22] M. Dyrmann, H. Karstoft, and H.S. Midtiby. Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151 :72–80, 2016.
- [23] Data Analytics Post. Lexique : Réseau de neurones profonds. <https://dataanalyticspost.com/Lexique/reseau-de-neurones-profonds/>.
- [24] Elastic. What is a neural network? <https://www.elastic.co/fr/what-is/neural-network>.
- [25] Michael A. Nielsen. *Neural Networks and Deep Learning*. Determination Press, 2015.
- [26] Galaxy Project. Feedforward neural networks. <https://training.galaxyproject.org/training-material/topics/statistics/tutorials/FNN/tutorial.html>.
- [27] Trend Micro. What is machine learning? https://www.trendmicro.com/fr_fr/what-is/machine-learning.html.
- [28] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, and et al. Attention is all you need. In *Advances in neural information processing systems*, pages 5998–6008, 2017.

- [29] L. Alzubaidi et al. Review of deep learning : concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(53) :1–20, 2021.
- [30] G.E. Hinton and R.R. Salakhutdinov. Reducing the dimensionality of data with neural networks. *Science*, 313(5786) :504–507, 2006.
- [31] D.P. Kingma and M. Welling. Auto-encoding variational bayes. *arXiv preprint arXiv :1312.6114*, 2014.
- [32] V. Mnih, K. Kavukcuoglu, D. Silver, A.A. Rusu, J. Veness, M.G. Bellemare, A. Graves, M. Riedmiller, A.K. Fidjeland, G. Ostrovski, and et al. Human-level control through deep reinforcement learning. *Nature*, 518(7540) :529–533, 2015.
- [33] V7 Labs. Deep reinforcement learning guide. <https://www.v7labs.com/blog/deep-reinforcement-learning-guidewhat-is-deep-reinforcement-learning>.
- [34] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature*, 521 :436–444, 2015.
- [35] DataValue Consulting. Deep learning : Réseaux neuronaux récurrents (rnn). <https://datavalue-consulting.com/deep-learning-reseaux-neurones-recurrents-rnn/>.
- [36] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv :1406.1078*, 2014.
- [37] Pensée Artificielle. Comprendre lstm et gru : Fonctionnement et schéma. <https://penseeartificielle.fr/comprendre-lstm-gru-fonctionnement-schema/>.
- [38] S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural Computation*, 9 :1735–1780, 1997.
- [39] F. Gers, J. Schmidhuber, and F.A. Cummins. Learning to forget : Continual prediction with LSTM. *Neural Computation*, 2000.
- [40] OpenClassrooms. Découvrez les cellules à mémoire interne : les lstm. <https://openclassrooms.com/fr/courses/5801891-initiez-vous-au-deep-learning/5814656-decouvrez-les-cellules-a-memoire-interne-les-lstm>.
- [41] La Revue IA. Qu’est-ce qu’un réseau de croyance profond (dbn)? <https://larevueia.fr/quest-ce-quun-reseau-lstm/>.
- [42] Viso AI. Deep belief networks. <https://viso.ai/deep-learning/deep-belief-networks/>. Consulté le 30 juin 2024. Une ressource utile pour comprendre les réseaux de croyances profondes (DBN) en apprentissage profond.

- [43] S. Guan, N. Kamona, and M. Loew. Segmentation of thermal breast images using convolutional and deconvolutional neural networks. In *Proceedings of the 2018 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, Washington, DC, USA, October 2018.
- [44] S. Gehlot, A. Gupta, and R. Gupta. SDCT-AuxNet : DCT augmented stain deconvolutional CNN with auxiliary classifier for cancer diagnosis. *Medical Image Analysis*, 61 :101661, 2020.
- [45] GeeksforGeeks. Introduction to convolutional neural network. <https://www.geeksforgeeks.org/introduction-convolution-neural-network/>.
- [46] P. Giguère. Cours - cnn 2020. <http://www2.ift.ulaval.ca/pgiguere/cours/DeepLearning/2020/05-CNN-2020.pdf>.
- [47] Université Laval. Glo-4030 - cnn. <https://ulaval-damas.github.io/glo4030/assets/slides/06-cnn-1.pdf>.
- [48] Blent. Comment fonctionne un cnn ? <https://blent.ai/blog/a/cnn-comment-ca-marche>.
- [49] Databricks. Convolutional layer. <https://www.databricks.com/fr/glossary/convolutional-layer>.
- [50] DataScientest. Convolutional neural network. <https://datascientest.com/convolutional-neural-network>.
- [51] J. Gu, Z. Wang, J. Kuen, L. Ma, and G. Wang. Recent advances in convolutional neural networks. *Pattern Recognition*, 77 :354–377, 2015.
- [52] OpenClassrooms. Découvrez les différentes couches d'un cnn. <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn>.
- [53] R. Yamashita et al. Convolutional neural networks : an overview and application in radiology. *Insights into Imaging*, 9(4) :611–629, 2018.
- [54] Y. Zhao, L. Gong, Y. Huang, and C. Liu. A review of key techniques of vision-based control for harvesting robot. *Computers and Electronics in Agriculture*, 127 :311–323, 2016.
- [55] Z. Xue, R. Xu, D. Bai, and H. Lin. YOLO-tea : A tea disease detection model improved by YOLOv5. *Forests*, 14(2) :415, 2023.
- [56] F. Sultana, A. Sufian, and P. Dutta. A review of object detection models based on convolutional neural network. *Intelligent Computing : Image Processing Based Applications*, pages 1–16, 2020.
- [57] Zhiqiang Wang and Jun Li. A review of object detection based on convolutional neural network. In *2017 36th Chinese Control Conference (CCC)*, pages 11104–11109, China, July 2017. IEEE.
- [58] Innovatiana. What is yolo in ai ? <https://www.innovatiana.com/post/what-is-yolo-in-ai>.

- [59] Towards Data Science. A comprehensive guide to convolutional neural networks. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
- [60] A. Jana and P. Biswas. Yolo-based detection and classification of objects. *Semanticscholar*, 2020.
- [61] Unknown. A review of yolo object detection algorithms based on deep learning. 2021.
- [62] P. Jiang, D. Ergu, F. Liu, Y. Cai, and B. Ma. A review of YOLO algorithm developments. *Procedia Computer Science*, 199 :1066–1073, 2022.
- [63] J. Redmon and A. Farhadi. YOLO9000 : better, faster, stronger. In *Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, July 2017.
- [64] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. In *CoRR*, volume abs/1409.4842, 2014.
- [65] Joseph Redmon et al. You only look once : Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [66] V7 Labs. Yolo : Object detection. <https://www.v7labs.com/blog/yolo-object-detection>.
- [67] ArduPilot. Connect to mission planner autopilot. <https://ardupilot.org/copter/docs/common-connect-mission-planner-autopilot.html>.
- [68] Roboflow. Tree detection using deep learning. <https://universe.roboflow.com/dokuz-eyll-universitesi/tree-detection-d4nq6>.
- [69] Roboflow. Plantdoc dataset. <https://public.roboflow.com/object-detection/plantdoc>.

Résumé

Ces dernières années, l'intelligence artificielle a émergé comme une révolution technologique dans divers domaines, y compris l'agriculture. L'utilisation de drones équipés de capteurs avancés et de techniques d'apprentissage automatique permet une surveillance précise des cultures, facilitant la détection précoce et le diagnostic des maladies des plantes.

Ce mémoire de master vise à améliorer la précision et l'efficacité de la détection des maladies des arbres en utilisant des réseaux neuronaux profonds, en exploitant spécifiquement des images capturées par des drones. Pour ce faire, nous avons utilisé des techniques d'apprentissage profond et avons examiné plusieurs modèles de réseaux neuronaux convolutionnels, notamment YOLO et CNN. Les résultats expérimentaux ont systématiquement démontré que les modèles YOLO ont réussi à accomplir les deux tâches de détection des arbres puis des feuilles avec une performance élevée.

D'autre part, le modèle CNN a montré une précision prometteuse de 90,64 %. Ces résultats font des modèles des choix fiables pour le suivi et la gestion des maladies des arbres à l'aide de drones.

Abstract

Récemment, l'intelligence artificielle a émergé comme une révolution technologique dans divers domaines, y compris l'agriculture. L'utilisation de drones équipés de capteurs avancés et de techniques d'apprentissage automatique permet une surveillance précise des cultures, facilitant la détection précoce et le diagnostic des maladies des plantes.

Ce mémoire de master vise à améliorer la précision et l'efficacité de la détection des maladies des arbres en utilisant des réseaux neuronaux profonds, en exploitant spécifiquement des images capturées par des drones. Pour ce faire, nous avons utilisé des techniques d'apprentissage profond et avons examiné plusieurs modèles de réseaux neuronaux convolutionnels, notamment YOLO et CNN. Les résultats expérimentaux ont systématiquement démontré que les modèles YOLO ont réussi à accomplir les deux tâches de détection des arbres puis des feuilles avec une performance élevée. Le modèle CNN a montré une précision prometteuse de 90,64

Ces résultats font de ces modèles des choix fiables pour le suivi et la gestion des maladies des arbres à l'aide de drones.

الملخص

في السنوات الأخيرة، ظهر الذكاء الاصطناعي كثورة تكنولوجية في مجالات مختلفة، بما في ذلك الزراعة. استخدام طائرات بدون طيار مزودة بأجهزة استشعار متقدمة وتقنيات التعلم الآلي تسمح برصد المحاصيل بدقة، وتسهيل الكشف المبكر عن الأمراض النباتية وتشخيصها. تهدف أطروحة الماجستير هذه إلى تحسين دقة وكفاءة مرض الأشجار الكشف باستخدام الشبكات العصبية العميقة، وتحديد الاستفاد من الصور التي تم التقاطها طائرات بدون طيار. لتحقيق ذلك، استخدمنا تقنيات التعلم العميق وفحصنا العديد نماذج الشبكة العصبية التلافيفية، ولا سيما بوبو و ث نجحت بإنجاز المهام المزدوجة للكشف عن بوبو أظهرت النتائج التجريبية باستمرار أن نماذج الأشجار والأوراق بدقة عالية.

من ناحية أخرى أظهر نموذج دقة واحدة بنسبة ٦٤.٩٠%. هذه تجعل النتائج هذه النماذج خيارات موثوقة لرصد وإدارة الأشجار الأمراض باستخدام الطائرات بدون طيار.