



République Algérienne Démocratique et Populaire
Ministère
de l'enseignement Supérieur
Et de la Recherche scientifique



Université Echahid Hamma Lakhderd'El-Oued
Faculté de Technologie

Mémoire de Fin d'Étude
En vue de l'obtention du diplôme de
MASTER ACADEMIQUE

Domaine: Science et Technologie

Filière: Télécommunication
Spécialité: Systèmes de Télécommunication

Thème

Développement d'un système automatisé de détection des lésions de la paume
(Oryctes Agamemnon Burmeister) par drone

Réalisé par:

Amirat Zahia

Atik Ben Amor Khouloud

Ayachi Amor Safa

Labbi Manel

Soutenu en Mai 2023 devant le jury composé de:

Mr. Hettiri Messaoud

Maitre de conférences "A"

Président

Mr. TIDJANI Amina

Maitre de conférences "B"

Examineur

Mr. AJGOU Riadh

Professeur

Rapporteur

Année Universitaire: 2022/2023

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

شكر وتقدير

(وَلَقَدْ آتَيْنَا لُقْمَانَ الْحِكْمَةَ أَنْ اشْكُرْ لِلَّهِ وَمَنْ يَشْكُرْ فَإِنَّمَا يَشْكُرُ لِنَفْسِهِ وَمَنْ كَفَرَ فَإِنَّ اللَّهَ غَنِيٌّ حَمِيدٌ)

{١٢} [لقمان آية: ١٢]

الحمد لله رب العالمين والصلاة والسلام على أشرف الأنبياء والمرسلين سيدنا محمد وعلى آله

وصحبه ومن تبعهم بإحسان إلى يوم الدين، أما بعد.

نحمدُ الله جلَّ وعلا على ما آتانا من فضله، فقد هيا لنا كل الظروف ويسر لنا إنجاز هذا العمل

بفضله العظيم وكرمه العميم، فله الحمد أولاً وآخرًا على كل شيء سبحانه وتعالى،

ونتقدم بجزيل الشكر المسبق للجنة المناقشة على ما سيقدمونه من ملاحظات و توجيهات والتي

ترقى بعملنا لتزيده إتقانًا وجمالًا

كما نود أن نغتتم هذه الفرصة لنتقدم بجزيل الشكر والعرفان لأولئك الأفاضل الكرام في مقدمتهم

الأستاذ الفاضل المشرف على مشروع مذكرتنا الدكتور أجقو رياض على ما قدمه لنا في

مسيرتنا، و أيضا نشكر الدكتور الليبي ياسين على مرافقته و مده لنا يد المساعدة طيلة هاته الفترة

وتوجيهاته لإعداد هذه المذكرة، أيضا إلى من لم يدخر جهدا في مساعدتنا الدكتور هيمة عبد

القادر.

والشكر موصول لكل من غرس في نفوسنا حب العلم، من كانوا عوننا لنا ونحن نشق الطريق نحو

النجاح في مسيرتنا العلمية

وأخيرا إلى كل من ساعدنا من قريب أو بعيد في إتمام هذه الدراسة، سائلين المولى عز و جل ان

يجزي الجميع خير الجزاء في الدنيا و الآخرة.

فأدامكم الله للأخلاق أهلا،،،،،،،،،، وللعلم قصدا و عنوانا

Dédicace

Grâce à Dieu pour mon arrivée à ce jour

je dédie ce travail à ma famille

*à ma mère, à mon père, à mes frères et sœurs, et à tous ceux qui
m'ont accompagné tout au long de mon voyage, souhaitant à
Dieu la réussite*

zahia

اهداء

شكر الله العليّ القدير الذي أنعم عليّ بِنعمة العقل والدين . القائل في محكم التنزيل "وَفَوْقَ كُلِّ ذِي عِلْمٍ عَلِيمٌ" سورة يوسف آية 76.... صدق الله العظيم .

أهدي تخرجي هذا إلى من علمني العطاء وإلى من أحمل اسمه بكل افتخار وأرجو من الله أن
يد في عمرك لترى ثمارا قد حاز قطافها بعد طول انتظار "والدي العزيز"

وإلى ملاك في الحياة وإلى معنى الحب والحنان والتفاني وإلى بسمه الحياة وسر الوجود وإلى من
كان دعائها سر نجاحي أغلى الحباب "امي الحبيبة"

وإلى من له الفضل الكبير في تشجيعي وتحفيزي ومن منه تعلمت المثابرة والاجتهاد وإلى من بهم أكبر
وعليهم أعتد وإلى من بوجودهم اكتسب قوة ومحبة لا حدود لها وإلى من عرفت معهم معنى الحياة "إخوتي
وأخواتي"

وإلى من تحلوا بالإخاء وتميزوا بالوفاء والعطاء وإلى من رفقتهم في دروب الحياة السعيدة والحزينة وإلى من
كانوا معي على طريق النجاح والخير "أصدقائي الأعزاء" وأسأل الله التوفيق لي ولكم .

خلود

اهداء

أشكر المولى عز وجل الذي رزقني العقل وحسن التوكل عليه ، وألهمنا الصحة والعزيمة للإتمام عملنا هذا

أهدي ثمرة عملي ،،،

...، واتسع قلبه لحلمي حين ضاقت به الدنيا...، إلى من زرعني على ضفاف العلم

إلى من تكلل العرق جبينه ليثبني لي سلاسل العلا،

إلى من يسرف في حياته ليراني أرتقي صهوات المجد...،إلى والدي العزيز

حفظه الله وأطال في عمره

إلى اليد الطاهرة التي تحصد الأشواك عن دربي...، إلى من علمت وربت وتعبت وألهمت ...،

إلى التي تودعني بدعوة، وتستقبلني بابتسامة إلى أمي الغالية

ثوب الصحة والعافية حفظها الله وألبسها

إلى إخوتي وإلى أخواتي

وإلى كل ما رافقني في درب الدراسة وذاق معي طعم النجاح ...،

إلى من وسعه قلبي ولم تسعه كلمات قلبي

منال

اهداء

ان الحمد لله الذي بنعمته تتم الصالحات بعد مسيرة دراسية حملت في طياتها الكثير

من الصعوبات والمشقة والتعب، اليوم نقطف ثمارها والحمد لله،

اهدي تخرجي إلى أُملي في الحياة وقرة عيني وسر نجاحي "أُمي

الغالية" ادامها الله وأطال في عمرها،

وإلى من أحمل اسمه بكل فخر وأرجو من الله أن يمد في عمره ليرى ثمارا

قد حان قطافها بعد طول انتظار "والدي العزيز"،

وإلى سندي في شدي وبهم أقوى على ديتي اخوتي و

اقربائي، وإلى اساتذتي الكرام أصحاب الفضل الكبير والمؤثر وإلى كل من

دعمني وساندني خلال فترتي الدراسية وما هي سوى نهاية مرحلة وبداية

مرحلة قادمة أتمنى فيها الخير لي ولكم

صفاء

Abstract

The identification of plant diseases is key to prevent yield losses and agricultural product quantity reductions. Therefore, the infestation of palm trees by the rhinoceros beetle (*Oryctes agamemnon* Burmeister - Scarabaeidae Coleoptera) is one of the most destructive pests for palm trees worldwide. Monitoring the health and detecting diseases in palm trees is essential for sustainable agriculture, as machine learning techniques and data processing can contribute to finding effective solutions to this problem. In this context, we have developed a mechanism to analyze data, classify infected palm trees, and develop predictive models for early detection of rhinoceros beetle infestation. This will be an automated system that processes images taken by a drone and sent to a computer. By using artificial intelligence applications and deep learning algorithms, we trained our own model using neural networks to analyze images and identify infected palms.

Keywords: Drone , Artificial Intelligence , Deep Learning , SSD Mobile Net , Convolutional neural networks (CNN) , Recurrent neural networks (RNN).

Résumé

L'identification des maladies des plantes revêt une importance capitale pour prévenir les pertes de rendement et de quantité de produits agricoles. Parmi les insectes ravageurs les plus destructeurs pour les palmiers à travers le monde, l'infestation du ver rhinocéros (*Oryctes agamemnon* Burmeister - Coléoptère Scarabaeidae) est particulièrement préoccupante. Ainsi, la surveillance de la santé des palmiers et la détection précoce des maladies revêtent une importance cruciale dans le cadre d'une agriculture durable. Grâce aux avancées dans le domaine de l'apprentissage automatique et du traitement des données, des solutions efficaces peuvent être trouvées pour contrer ce problème. Dans cette optique, nous avons mis au point un mécanisme permettant d'analyser les données et de classifier les palmiers infectés. Nous avons également développé des modèles prédictifs pour la détection précoce de l'infestation par le ver rhinocéros. Ce système automatisé utilise des images prises par un drone, qui sont ensuite traitées par un ordinateur. En utilisant des applications d'intelligence artificielle et des algorithmes d'apprentissage profond, nous avons entraîné notre propre modèle basé sur des réseaux de neurones afin d'analyser les images et d'identifier les palmiers infectés.

Mots-clés : Drone , Intelligence artificielle , Apprentissage profond , SSD Mobile Net, Réseaux de neurones convolutifs (CNN) , Réseaux neuronaux récurrents (RNN).

ملخص

تعتبر تحديد أمراض النباتات مفتاحًا للوقاية من تقلصات الإنتاج وتقليل كمية المنتجات الزراعية. لذا، فإن غزو نخلة البق الوحشي (*Oryctes agamemnon* Burmeister - سرابينيداي الخنفساء) هو واحد من الآفات الحشرية الأكثر تدميرًا لنخيل البلدان في العالم. لذا فإن رصد صحة النخيل وكشف الأمراض ضروريان للزراعة المستدامة، حيث يمكن لتقنيات التعلم الآلي ومعالجة البيانات المساهمة في إيجاد حلول فعالة لهذه المشكلة. في هذا السياق، قمنا بتطوير آلية لتحليل البيانات وتصنيف النخيل المصابة وتطوير نماذج توقعية للكشف المبكر عن غزو البق الوحشي. سيكون هذا النظام تلقائيًا يتعامل مع الصور الملتقطة بواسطة طائرة بدون طيار وإرسالها إلى جهاز كمبيوتر. باستخدام تطبيقات الذكاء الاصطناعي وخوارزميات التعلم العميق، قمنا بتدريب نموذجنا الخاص باستخدام الشبكات العصبية لتحليل الصور وتحديد النخيل المصابة..

الكلمات المفتاحية: طائرة بدون طيار ، الذكاء الاصطناعي ، التعلم العميق ، SSD Mobile Net ، الشبكات العصبية التلافيفية CNN ، الشبكات العصبية المتكررة RNN .

Sommaire

REMERCIEMENTS	I
DEDICACE.....	II
ABSTRACT.....	V
RESUME.....	VI
ملخص.....	VII
LISTE DES TBLEAUX.....	X
LISTE DES FIGURES.....	XI
LISTES DES ACRONYMES.....	XIII
INTRODUCTION GENERALE.....	XIII

CHAPITRE I

APPLICATIONS DES DRONES QUADRI-ROTOR DANS L'AGRICULTURE

I.1 INTRODUCTION :	2
I.2 DEFINITION D'UN DRONE :	2
I.3.HISTORIQUE :	3
I.4 DIFFERENTS TYPES DE DRONES SELON LEUR UTILISATION :	4
I.5 DRONE QUADRIROTOR:	5
I.5.1 Description :	5
I.5.2 Avantages des drone quadrirotor :	5
I.6APPLICATIONS :	6
I.7 DRONE AGRICULTURE :	7
I.7.1 Définition :	7
I.7.2 Types de plateformes :	8
I.8 APPLICATIONS DES DRONES AGRICOLES :	9
I.8 1-Cartographie :	9
I.8 2-Pulvérisation :	11
I.8 3-Plantation :	11
I.8 4-Suivi des cultures :	12
I.8.5-Irrigation:.....	13
I.8 6- Diagnostic Des Insectes Nuisibles :	13
I.8 7-Pollinisation Artificielle :	14
I.9 CONCLUSION :	15

CHAPITRE II

L 'APPRENTISSAGE AUTOMATIQUE ET L'APPRENTISSAGE EN PROFONDEUR

II.1 INTRODUCTION :	17
II.2 L 'INTELLIGENCE ARTIFICIELLE (AI):	17
II.2.1 Différents types d'intelligence artificielle:	18
Type 1 Basé sur la fonctionnalité:	18
II.2.1.1 Machine réactive:.....	18
II.2.1.2 Théorie limitée:.....	19
II.2.1.3 Théorie de l'esprit:.....	19
II.2.1.4 IA consciente d'elle-même:	20

II.2.1.5 Intelligence artificielle étroite (Artificial Narrow Intelligence ANI):	20
II.2.1.6 Intelligence artificielle générale (Artificial General Intelligence AGI):	20
II.1.2.7 L 'Intelligence Artificielle Super (Artificial Super Intelligence ASI):	21
II.3 L 'APPRENTISSAGE AUTOMATIQUE:	21
II.3.1 Composants de l'apprentissage automatique:	22
II.3.1.1 Les données:	22
II.3.1.2 Algorithmes:	22
II.3.1.3 Modèle	22
II.3.1.4 Extraction de fonctionnalités :	23
II.3.1.5 Formation:	23
II.4 L'APPRENTISSAGE EN PROFONDEUR(DEEP LEARNING DL):	23
II.4.1 Application de l'apprentissage en profondeur(deep learning):	23
II.4.2 Définition des réseaux de neurones artificiel(artificial neural network ANN):	24
II.4.3 Structure du réseau neuronal	25
II.4.3.1 Composants d'un neurone biologique:	25
II.4.3.2 Composants d'un neurone artificiel:	26
II.4.4 Structures communes des réseaux de neurones artificiels :	26
II.4.4.1 Les réseaux de neurones convolutifs (convolutionl Neural Networks):	26
II.4.4.2 Composants des réseaux de neurones convolutifs (CNN):	27
II.4.4.3 Le réseau neuronal récurrent (Recurrent Neural Networks (RNN) :	27
II.4.4.4 L 'évolution des réseaux RNN:	28
II.4.4.5 Fonctionnement de RNN et modèles approuvés:	29
II.4.4.6 La différence fondamentale entre intelligence artificielle AI - L'apprentissage automatique ML et l'apprentissage en profondeur :	29
II.5 CONCLUSION	30

CHAPITRE III

IMPLEMENTATION DU SYSTEME

III.1 INTRODUCTION:	32
III.2 PRESENTATION DES OUTILS DE DEVELOPPEMENT :	32
III.2.1 le matériels	32
III.2.2. Méthodes	33
III.3. ZONE D'ETUDE ET PREPARATION A L'EXPERIENCE :	34
III.4. STADES DE L'INFECTION ETUDIES	35
III.5. ÉTAPES DE BASE POUR LA DETECTION DES MALADIES :	39
III.5.1. Acquisition d'images :	40
III.5.2. Prétraitement de l'image :	40
III.5.3. Segmentation d'image :	40
III.5.4. Extraction des caractéristiques :	40
III.5.5. Classification:	41
III.6. BASE DE DONNEES :	42
III.7. MISE EN ŒUVRE DU SYSTEME :	43
III.7.1. Préparation des données :	43
III.7.2. Extraction des caractéristiques HOG pour les images d'entraînement :	44
III.7.3. Augmentation des images d'entraînement :	46
III.7.4. Extraction des caractéristiques HOG pour les images de test :	48
III.7.5. Normalisation des caractéristiques :	49
III.7.6. Entraînement du classificateur du réseau neuronal :	49
III.7.7. Prédiction des étiquettes pour les images de test :	50
III.7.8. Évaluation de la précision de la classification :	51
III.8.RESULTATS ET DISCUSSION:	51
III.9. CONCLUSION	57

CONCLUSION GENERALE:	XV
BIBLIOGRAPHIE.....	XVI

Liste des Tableaux

TABLEAU III .1: PROPRIETES DE IMAGE	43
---	----

Liste des figures

FIGURE I.1: KETTERING BUG(A GAUCHE) AERIAL TARGET(A DROITE) .	3
FIGURE I.2: AVION VOISIN BN3[1].	3
FIGURE I.3: DRONE DENNY 1(TDD - 1)	4
FIGURE I.4 : KF607 QUADCOPTER FPV EXAMEN.	5
FIGURE I.5: TYPES DE PLATEFORMES DRONE	8
FIGURE I.6 : PLUSIEURS TYPES DE DRONES AGRICOLES : DRONE DE RECOLTE,DRONE DE PULVERISATION, DRONE DE CARTOGRAPHIE ET DRONE DE DETECTION.	9
FIGURE I.7: CARTES OBTENUES POUR LES VERGERS D'AGRUMES ET DE PECHERS MONTANT LA VARIATION DE LA COUVERTURE VEGETALE	10
FIGURE I.8: CULTURE DE CEREALES PAR DRONE.	11
FIGURE I.9: (A) PLATE-FORME UAV ;(B) ZONES D'ECHANTILLONNAGE SPECTRALES MARQUEES AVEC DES RECTANGLES NOIRS ET DES VALEURS BGI2 MOYENNES PAR PLACETTE.	12
FIGURE I.10: EMLACEMENT ET TAILLE DES MESURES DE L'INDICE DE SURFACE FOLIAIRE SUR UNE CARTE NGRDI[4].	13
FIGURE I.11: VUE DETAILLEE D'UNE CARTE NDVI D'UN CHAMP DE POMMES DE TERRE, METTANT EN EVIDENCE LES TROIS SITES D'ORIGINE DE LA BRULURE DE LA POMME DE TERRE(CERCLES EN POINTILLES)ET LA PROPAGATION ULTERIEURE	14
FIGURE I.12: (A) POILS D'ANIMAUX ALIGNES VERTICALEMENT SUR UNE BANDE AVEC UN REVETEMENT ILG;(B) POLLINISATEUR ARTIFICIEL MODIFIE PAR DES POILS D'ANIMAUX REVETU D'ILG	15
FIGURE II.1: TYPES D'INTELLIGENCE ARTIFICIELLE (AI)	18
FIGURE II.2: CELLULES BIOLOGIQUES ET ARTIFICIELLES NORMALES	24
FIGURE II.3: STRUCTURE SIMPLIFIEE DES NEURONES BIOLOGIQUES	25
FIGURE II.4: COMPOSANTS D'UN NEURONE ARTIFICIEL	26
FIGURE II.5: RESEAUX DE NEURONES CONVOLUTIFS (CNN)	27
FIGURE II.6: LE RESEAU NEURONAL RECURRENT	28
FIGURE II.7: LA DIFFERENCE FONDAMENTALE ENTRE AI - ML ET DL	29
FIGURE III.1: KF607 QUADCOPTER FPV EXAMEN.	32
FIGURE III.2: MATLAB INTERFACE	33
FIGURE III.3: IMAGE REELLE PAR DRONE D'UN GROUPE DE PAUMES A DIFFERENTS STADES DE BLESSURE	34
FIGURE III.4: VISUALISATION DE L'EXPÉRIENCE, OÙ LES ZONES ROUGES INDIQUENT DES PALMIERS INFESTÉS ET LES ZONES VERTES INDIQUENT DES PALMIERS NON INFECTÉS.	35
FIGURE III.5: UNE IMAGE REELLE ORDINAIRE D'UN PALMIER DE CLASSE 1 (INTACT)	36
FIGURE III.6: IMAGE THERMIQUE D'UN PALMIER SAIN EXEMPT D'INFECTIO	36
FIGURE III.7: UNE IMAGE REELLE D'UN PALMIER DE CLASSE 2 (L'APPARITION DE L'INFECTION)	37
FIGURE III.8: IMAGE THERMIQUE D'UN PALMIER AU DEBUT DE L'INFECTION.	37
FIGURE III.9: IMAGE REELLE D'UN PALMIER INFECTE DE CLASSE 3(INFECTION MODEREE)	38
FIGURE III.10: IMAGE THERMIQUE D'UN PALMIER EN CAS MODERE D'INFECTION	38
FIGURE III.11: IMAGE REELLE D'UN PALMIER INFECTE DE CLASSE 4(COMPLETEMENT INFECTE)	38
FIGURE III.12: IMAGE THERMIQUE D'UN PALMIER COMPLETEMENT INFECTE.	39
FIGURE III.13: ÉTAPES DE BASE POUR LA DETECTION ET LA CLASSIFICATION DE L'INFESTATION DE PALMIERS	39
FIGURE III.14: RESEAU DE RETROPROPAGATION	42
FIGURE III.15: VISUALISATION D'EXEMPLE DE JEU DE DONNEES	43
FIGURE III.16: DEFINITION DES CHEMINS D'ACCES POUR L'ENTRAINEMENT ET LES TESTS	44
FIGURE III.17: COMPTAGE DES FICHIERS D'ENTRAINEMENT ET DE TEST, ET DEFINITION DE LA TAILLE DE L'IMAGE ..	44
FIGURE III.18: EXTRACTION DES CARACTERISTIQUES HOG POUR LES IMAGES D'ENTRAINEMENT	

FIGURE III.19: AUGMENTATION DES IMAGES D'ENTRAINEMENT	48
FIGURE III.20: EXTRACTION DES CARACTERISTIQUES HOG POUR LES IMAGES DE TEST	49
FIGURE III.21: ENTRAINEMENT DU CLASSIFICATEUR DU RESEAU NEURONAL AVEC RETROPROPAGATION DU GRADIENT STOCHASTIQUE	50
FIGURE III. 22: PREDICTION DES ETIQUETTES POUR LES IMAGES DE TEST A L'AIDE DU RESEAU NEURONAL ENTRAINE	50
FIGURE III.23: ÉVALUATION DE LA PRECISION DE LA CLASSIFICATION POUR LE RESEAU NEURONAL ENTRAINE....	51
FIGURE III. 24: ENTRAINEMENT DU RESEAU NEURONAL ET RESULTATS	52
Figure III.25: Résultats de l'évaluation du modèle de réseau neuronal.....	52
Figure III.26: Histogramme des erreurs.....	53
Figure III.27 : Comparaison des performances du modèle de réseau neuronal.....	54
Figure III.28: Précision de la classification du modèle de réseau neuronal et ressources de calcul.....	56

Listes des Acronymes

Notations et abbreviations	Signification
UAV	Unmanned Aerial Vehicle
AIST	National Institute of Advanced Industrial Science and Technology
GPS	Global Positioning System
AI	Artificial Intelligence
ANI	Artificial Narrow Intelligence
AGI	Artificial General Intelligence
ASI	Artificial Super Intelligence
ML	Machine learning
CNN	convolutional Neural Networks
RNN	Recurrent Neural Network
DL	Deep learning
ANN	Artificial neural network
Lipo	Lithium polymer

GPS	The Global Positioning System
HD	High definition
FPV	First Person View
SSD	Single-short multibox detection
DJI	Chinese technology company makes commercial unmanned aerial vehicles
RVB	Rouge-Vert -Bleu
SIH	System Information Hydrogeological
SGDM	Spatial Gray-level Dependence Matrices
GLCM	gray-level co-occurrence matrix
SOFM	Self-organizing feature maps
MOM	message-oriented middleware
BPNN	back-propagation neural network

Introduction Générale

Introduction Générale

Le palmier est l'arbre fruitier le plus important dans les zones d'environnement sec et désertique , car c'est une source majeure de nourriture et de revenus pour de nombreux pays du monde arabe et des régions au climat chaude. L'infestation de palmiers est un problème auquel sont confrontés les agriculteurs et ceux qui s'intéressent à sa culture,notamment en l'infectant avec le scarabée rhinocéros *Oryctes Agamemmon* Burmeister (coléoptère scarabaeidae), car cette maladie provoque la destruction et la réduction de la productivité des cultures et cet insecte est l'un des insectes les plus dangereux pour la santé des palmiers,les symptômes de la maladie apparaissent sous la forme des taches sur les feuilles du palmier et de noyaux sur le tronc,ce qui entraine des chutes et des dommages,ainsi qu'une détérioration de la qualité des cultures et une faible productivité,les producteur de palmiers dattiers utilisaient des pesticides spéciaux et diverses autre méthodes agricoles pour limiter leur propagation,mais ils ne travaillaient pas beaucoup ,un système automatisé a été développé pour détecter un insecte palmier en utilisant la vision par ordinateur et les techniques d'apprentissageprofond,les technologies modernes sont utilisées dans le domaine de la vision par ordinateur pour réaliser l'analyse,le traitement et la compréhension des images numériques,afin de en bénéficier dans différentes applications,la vision par ordinateur est l'un des domaines de l'informatique,visant à construire des application intelligentes capable de comprendre le contenu de l'image comme une compréhension humaine, l'utilisation de la technologie des réseaux de neurones artificiels (ANN) dans le domaine de l'informatique ,avec sa capacité à détecter à classer les insectes, et augmenter la précision de la détermination risques et dangers,le réseau neuronal est l'une des technologies modernes dans le domaine de l'intelligence artificielle et est utilisé pour résoudre des problèmes de classification,de prédiction et de reconnaissance de formes et de motifs,le réseau neuronal est basé sur un modèle inspiré du cerveau humaine,développé d'une manière qui imite le fonctionnement des cellules cérébrales.

En raison des dangers de la propagation de ce ravageur mortel (maladie du rhinocéros)dans cette révolution, nous avons travaillé dur pour établir un projet de détection précoce afin de réduire ses risques et de détruire les palmiers.

Introduction Générale

L'organisation d'une note repose sur trois chapitres.

Premier chapitre:

Nous avons fourni des informations détaillées sur les drones, incluant leur définition, leur historique, leurs différents types et applications, en mettant l'accent sur leur utilisation dans le domaine de l'agriculture.

Deuxième chapitre :

Ce chapitre explore le concept de l'intelligence artificielle (IA) et ses différents types. Nous avons présenté en détail l'apprentissage automatique (machine learning - ML), en expliquant son concept et ses composants essentiels. Nous avons également abordé l'apprentissage profond (deep learning - DL) et ses applications, en mettant en avant les réseaux neuronaux artificiels (ANN). De plus, ce chapitre met en évidence la différence fondamentale entre l'intelligence artificielle (IA) et l'apprentissage automatique (ML) ainsi que l'apprentissage profond (DL).

Troisième chapitre :

Ce chapitre présente la finalisation d'un système automatisé de détection de l'insecte palmier *Oryctes Agamemmon Burmeister* (coléoptère scarabaeidae). Ce système utilise à la fois la vision par ordinateur et un algorithme. Le travail effectué concerne les étapes initiales de la collecte d'images, suivies de leur entraînement dans un système capable de classifier les images selon les besoins spécifiques.



Chapitre I

Applications des drones Quadri-rotor dans l'agriculture

I.1 Introduction :

Le monde a observé les avantages des composés de drones et leur impact réel dans de nombreux domaines économiques, nous avons donc consacré ce chapitre à mentionner le drone quad car c'est l'une des technologies modernes utilisées dans le domaine de l'agriculture, car elle contribue à l'efficacité de la production et à l'amélioration de la qualité de la culture, Grâce à leur capacité à survoler une vaste zone sans interruption, ces avions sont également utilisés pour collecter des données et des images des cultures afin d'évaluer leur état de santé et de prédire rapidement les ravageurs qui affectent la maladie.

I.2 Définition d'un drone :

Un drone ou UAV(Unmanned Aerial Vehicle) est un aéronef sans passager ni pilote, capable de vol autonome ou semi-autonome pouvant être contrôlé à distance depuis le sol.

Il est susceptible d'emporter différentes charges utiles, le rendant capable d'effectuer des tâches spécifiques, pendant une durée de vol qui peut varier en fonction de ses capacités. L'utilisation des drones à d'abord été connue dans les applications militaires, comme la surveillance et la reconnaissance et comme plateforme de désignation de cible ou comme arme. Puis, plusieurs applications civiles sont devenues concurrentes, notamment dans l'observation des phénomènes naturels (Avalanches, volcans...), la pulvérisation des pesticides sur les surfaces agricoles, la surveillance de l'environnement (exemple mesures de la pollution) et des réseaux routier, la maintenance des infrastructures.[1]

I.3. Historique :

La conception des drones a commencé pendant la Première Guerre mondiale des prototypes ont été proposés, avec des tentatives de « torpilles aériennes télécommandées par télégraphie sans fil et embarquant un gyroscope, mais qui n'ont jamais été opérationnels sur le terrain. En 1916, au Royaume-Uni, fut conçu l'Aerial Target, un projet d'avion-cible, par l'ingénieur "Archibald Low".




Figure I.1: Kettering Bug (à gauche) Aerial Target (à droite) [1].

Le 2 juillet 1917 en France le pilote "Max Boucher", fait voler un avion Voisin (sans l'intervention de l'homme) sur 1 km. Au début de l'année 1918, un projet d'avions sans pilotes a été lancé. Après l'amélioration du système de pilotage automatique, l'avion Voisin BN3 a volé pendant 51 min sur un parcours de 100 km.




Figure I.2: Avion Voisin BN3 [1].

Chapitre I Applications des drones Quadrirotor dans l'agriculture

En 1941, l'US marine passa commande de plus de mille exemplaires d'un nouveau modèle baptisé Target Drone Denny 1 (TDD-1). En 1938 l'armée allemande développa des recherches sur des vecteurs guidés à distance et prenant la forme de bombes planantes anti-navires, de bombes antichar radioguidées et surtout de véhicules à chenilles filoguidés.

Dans les années 1990, la doctrine de la guerre « zéro mort » conduit à développer les projets de drones armés à travers le monde mais la toute première utilisation de ceux-ci a eu lieu durant la guerre Iran-Irak où l'Iran a déployé un drone armé de six RPG-7.



Figure I.3: Drone Denny 1 (TDD - 1) [1].

Dans les années 2000, le drone est de tous les conflits et opérations de maintien de la paix, dont au Kosovo ou au Tchad, lors des attaques aériennes américaines au Pakistan ou contre la piraterie maritime, par les Américains qui l'ont introduit en 2009 [1]

I.4 Différents types de drones selon leur utilisation :

Les drones peuvent être catégorisés suivant leurs fonctions et leurs rôles. Ainsi donc, on distingue :

- Le drone militaire
- Le drone civil
- Ambulancier le drone

I.5 Drone quadrirotor:

I.5.1 Description :

Un quadrirotor est un drone à voilure tournante composé de quatre rotors. Les quadcoptères sont classés en giravions, par opposition aux drones à voilure fixe, car leur portance est générée par un ensemble de rotors

Les quadrotors utilisent généralement deux paires d'hélices à pas fixe identiques, deux dans le sens des aiguilles d'une montre (CW) et deux dans le sens inverse (CCW). En modifiant la vitesse de chaque rotor, il est possible de générer spécifiquement une poussée totale souhaitée, localiser le centre de poussée latéralement et longitudinalement, et pour créer un couple total souhaité, ou force de rotation.[1]



FigureI.4 :KF607 Quadcopter FPV examen.

I.5.2 Avantages des drone quadrirotor :

Quad drone aide à résoudre les problèmes et à simplifier les solutions en fournissant un cadre approprié pour analyser le problème et déterminer les objectifs et les étapes nécessaires pour l'atteindre, car il aide à identifier les différentes sources du problème et à identifier les facteurs qui affectent la solution du problème et présentent des avantages, dont certains sont mentionnés.

Chapitre I Applications des drones Quadrirotor dans l'agriculture

Leurs tailles réduites et leur manœuvrabilité permettent de se déplacer dans des environnements fermés (Indoor) ou ouverts (Outdoor) et en évitant les obstacles contrairement aux autres véhicules aériens.

- La simplicité de sa mécanique facilite sa maintenance.
- Aucun embrayage n'est exigé entre le moteur et le rotor et aucune exigence n'est donnée sur l'angle d'attaque des rotors.
- Quatre petits rotors remplacent le grand rotor de l'hélicoptère ce qui réduit énormément l'énergie cinétique stockée et minimise les dégâts en cas d'accidents.
- Décollage et atterrissage verticaux
- Contrôlé en modifiant uniquement la vitesse de rotation des quatre moteurs.
- Leur capacité de portance à cause de la présence de quatre rotors au lieu d'un qui peut être augmenté en rallongeant les pales d'un rotor ou en augmentant leur nombre.
- Sa dynamique est plus faible que celle de l'hélicoptère ce qui ne nécessite pas un temps de réaction rapide.[1]

I.6 Applications :

- ❖ Recherche et sauvetage : En cas d'accident ou de catastrophe naturelle, le drone peut aider l'équipe de secours à retrouver rapidement la victime.
- ❖ Militaire et maintien de l'ordre : Les véhicules aériens type quadrirotor sont utilisés pour la surveillance et la reconnaissance par les forces armées et les forces de l'ordre, ainsi que pour les missions de recherche et de sauvetage en milieu urbain.
- ❖ Photographie : Les quadrirotors conviennent à cet emploi à cause de leur nature autonome et de leurs économies considérables.

Journalisme : Les médias utilisent des drones de broyage pour informer et vérifier les informations sur les événements, tels que les inondations, les manifestations et les

Guerres Les drones

- ❖ peuvent être utilisés dans plusieurs autres domaines, tels que les télécommunications, livraison, publicité, médecine...
- ❖ Inspection : Les drones peuvent inspecter des structures de haute tension, des bâtiments, des routes et des lignes électriques à des sites d'accès distants ou difficiles pour localiser des matières dangereuses.
- ❖ Cartographie : Par rapport aux avions traditionnels, les drones peuvent construire des cartes topologiques plus précises. Ils peuvent voler près de la terre avec l'appareil Caméra ou sonde pour créer des cartes 3D haute résolution.[1]

I.7 Drone Agriculture :


I.7.1 Définition :

Les auteurs ont développé une drone agricole est un véhicule aérien sans pilote appliqué à l'agriculture afin d'aider à augmenter la production agricole et à surveiller la croissance des cultures. Les capteurs et les capacités d'imagerie numérique peuvent donner aux agriculteurs une image plus riche de leurs champs. Ces informations peuvent s'avérer utiles pour améliorer les rendements des cultures et l'efficacité des exploitations.

Les drones agricoles permettent aux agriculteurs de voir leurs champs depuis le ciel. Cette vue à vol d'oiseau peut révéler de nombreux problèmes tels que les problèmes d'irrigation, la variation du sol et les infestations de ravageurs et de champignons. Les images multi spectrales montrent une vue dans le proche infrarouge ainsi qu'une vue du spectre visuel. La combinaison montre à l'agriculteur les différences entre les plantes saines et malsaines, une différence qui n'est pas toujours clairement visible à l'œil nu. Ainsi, ces vues peuvent aider à évaluer la croissance et la production des cultures.

I.7.2 Types de plateformes :

Il existe deux principaux types de plates-formes UAV : à voilure fixe et à voilure tournante (voir Figure 4). Un UAV à voilure fixe ressemble en apparence à un avion. Il vole par poussée et force de levage aérodynamique[2]–[3]. Un UAV à voilure fixe est généralement plus grand qu'un modèle à voilure tournante et est principalement utilisé pour la pulvérisation et photographie sur une large gamme. Les drones à voilure tournante peuvent être classés en types d'hélicoptères et multi-rotors. Le type d'hélicoptère comporte une grande hélice au sommet de l'avion. Il est largement utilisé pour la pulvérisation et la photographie aérienne. Les modèles multi-rotors sont nommés en fonction du nombre de rotors qu'ils possèdent, tels que "quadcopter", ce qui signifie quatre rotors. L'hexacopter a six rotors et l'octocopter a huit rotors.



FigureI.5: Types de Plateformes drone[4].

I.8 Applications des drones agricoles :

Actuellement, les drones agricoles effectuent de nombreuses tâches dans divers environnements de travail. Ils sont utilisés dans les rizières, les champs et les vergers, et la demande ne cesse d'augmenter. Cette section présente les applications des drones agricoles actuels.




Figure I.6 : Plusieurs types de drones agricoles : drone de récolte, drone de pulvérisation, drone de cartographie et drone de détection[4].

I.8 1-Cartographie :

Les cartes 2D ou 3D d'un champ agricole réalisées par des drones peuvent fournir des informations utiles. Par exemple, la superficie des terres agricoles, les conditions du sol et l'état des cultures peuvent être utilisés comme modèles d'amélioration et d'efficacité [5],[6]. Par conséquent, la recherche cartographique continue d'attirer l'attention.

Chapitre I Applications des drones Quadrirotor dans l'agriculture

Obtenu des cartes haute résolution délimitant les variations spatiales de l'interception des rayonnements à l'aide d'images UAV (voir Figure7). Les cartes générées permettent des tâches d'agriculture de précision rentables, telles que le contrôle agronomique de zones homogènes et la séparation des zones de qualité des fruits.




Figure I.7: Cartes obtenues pour les vergers d'agrumes et de pêchers montrant la variation de la couverture végétale[4].

I.8 2-Pulvérisation :

Par rapport à un pulvérisateur rapide ou à un pulvérisateur à grande surface, les UAV peuvent réduire l'utilisation de pesticides et maximiser l'efficacité[7], [8]. La mesure des pesticides par hectare de terres agricoles est corrélée aux risques de maladies des travailleurs et de pollution de l'environnement. Les UAV peuvent minimiser l'utilisation des pesticides. Cette stratégie permet d'atteindre une décontamination à grande échelle allant jusqu'à 50 ha par jour et ne nécessite qu'environ 10 minutes de travail par zone de 0,5 ha. Ainsi, la recherche sur les drones vise à réduire les besoins en main-d'œuvre. a étudié les fermes d'agrumes pour déterminer le niveau optimal de travail préventif en les pulvérisant à différentes hauteurs à l'aide d'un drone[9].

I.8 3-Plantation :

Il n'est pas surprenant que la plantation puisse être rendue plus efficace à l'aide de drones. Les avantages incluent la possibilité de travailler [10].

sur une grande surface de rizières inégales. Un système est utilisé pour distribuer les graines et les éléments nutritifs des plantes lors du semis afin de fournir des conditions parfaites pour la croissance des plantes. Bien que l'utilisation des drones pour la plantation soit encore en développement, on s'attend à ce que cette stratégie produise un travail efficace, à condition que le drone soit équipé d'une technologie de reconnaissance d'image et de tâches de plantation optimisées.



Figure I.8: Culture de céréales par drone[4].

I.8 4-Suivi des cultures :

Le suivi des cultures est le travail effectué pour prédire la qualité d'une culture via l'analyse des données sur les cultures. Le suivi des cultures est essentiel pour une production optimale des cultures. Cependant, la surveillance d'une grande ferme nécessite beaucoup de temps et de travail. Les très grandes exploitations sont souvent surveillées par satellite. Cependant, cela ne convient pas à la surveillance de précision des cultures. Le suivi des cultures via des drones a été proposé pour cela. Ainsi, des données à haute résolution ont été obtenues et les effets météorologiques ont été réduits. a réalisé une étude pour appliquer les données 3D collectées à partir de caméras instantanées légères fixées à des véhicules aériens (voir Figure). Parce que les capteurs utilisés sont légers, les drones volant à basse altitude peuvent surveiller les cultures à moindre coût. Des études ont également été menées pour analyser l'indice de végétation des raisins en acquérant des données de vignobles à l'aide de caméras multi-spectrales. Ces données d'index sur les légumes fournissent d'importants indicateurs d'amélioration et de productivité.




Figure I.9: (a) Plate-forme UAV ;(b) Zones d'échantillonnage spectrales marquées avec des rectangles noirs et des valeurs BGI2 moyennes par placette[4].

I.8.5-Irrigation:

Un drone équipé de caméras multi-spectrales et de capteurs de chaleur peut identifier les zones où l'eau est rare, comme le montre la figure :




Figure I.10: Emplacement et taille des mesures de l'indice de surface foliaire sur une carte NGRDI[4].

I.8 6- Diagnostic Des Insectes Nuisibles :

Aux États-Unis, environ 33 milliards de dollars de dommages annuels sont causés par des infestations de ravageurs et des infections. Un diagnostic précoce est essentiel car les dommages se propagent rapidement. ont mené une étude dans laquelle des caméras RVB haute résolution et des capteurs multi spectres montés sur des UAV ont

été combinés pour examiner les champs de pommes de terre à la recherche d'infections (voir Figure 11). Ils ont montré une détection précise et rapide des agents pathogènes à l'aide de mesures spectrales de haute qualité.




Figure I.11: Vue détaillée d'une carte NDVI d'un champ de pommes de terre, mettant en évidence les trois sites d'origine de la brûlure de la pomme de terre (cercles en pointillés) et la propagation ultérieure [4].

I.8 7-Pollinisation Artificielle :

Alors que la population d'abeilles mellifères continue de diminuer dans le monde entier, la recherche sur les robots pollinisateurs a gagné du terrain. Ainsi, l'Institut national des sciences et technologies industrielles avancées AIST (National Institute of Advanced Industrial Science and Technology) a développé un petit UAV pour la pollinisation, comme le montre la figure . Le robot utilise des poils d'animaux enduit

de gel pour transporter le pollen. L'AIST prévoit d'intégrer l'IA, le **GPS (Global Positioning System)** et les caméras à ces robots UAV. La pollinisation a également été effectuée en utilisant l'énergie éolienne générée par les drones, plutôt que par contact direct. ont mené une étude sur l'influence de l'énergie éolienne des drones de type hélicoptère sur la distribution du pollen de riz. Plus précisément, ils ont découvert que le champ de vent créé par les drones exerçait une influence asymétrique sur la distribution du pollen .




Figure I.12: (a) Poils d'animaux alignés verticalement sur une bande avec un revêtement ILG; (b) Pollinisateur artificiel modifié par des poils d'animaux revêtu d'ILG[4].

I.9 Conclusion :

En conclusion, les drones agricoles quadricoptères sont une solution prometteuse pour la surveillance des cultures agricoles. Leur utilisation permet de réaliser des économies d'efforts et de temps significatives, tout en préservant la qualité et la santé de la production agricole. Grâce à leur capacité à collecter des données précises et à fournir des informations en temps réel, ils contribuent à une gestion plus efficace des cultures et à une agriculture plus durable. Il est donc crucial de continuer à explorer et à développer cette technologie pour répondre aux défis futurs de l'agriculture.

Chapitre II

**L 'apprentissage automatique et
l'apprentissage en profondeur**

II.1 Introduction :

L'apprentissage machine (ML) et l'apprentissage profond (DL) sont deux domaines récents et avancés dans le domaine de l'intelligence artificielle. Les deux reposent sur la capacité unique des ordinateurs à apprendre, s'adapter et analyser des données sans intervention humaine directe. Cependant, l'apprentissage profond diffère de l'apprentissage machine en termes de complexité et de capacité à comprendre et analyser de grandes quantités de données. Dans ce chapitre on explore l'intelligence artificielle avec différents types.

II.2 L'intelligence artificielle (AI):

L'intelligence artificielle AI (Artificial Intelligence) a émergé en 1956 par John Markathy lors d'une conférence à Dartmouth et l'a été jusqu'à présent. Dans les années soixante, le domaine de (IA) a connu une explosion de la recherche et des applications, et dans les années soixante-dix, des travaux sont apparus sur les premiers pas dans ce que l'on appelle (l'ingénierie de la connaissance) et dans les années quatre-vingt, l'utilisation de l'apprentissage automatique est apparue et, dans les années quatre-vingt-dix, les scientifiques de (IA) sont revenus à leur première biographie, en particulier les réseaux de neurones, en fonction des développements survenus au cours de ces années très rapidement. Avec l'avancement de la technologie et les innovations dans le domaine de(IA), le développement et l'amélioration de ce domaine se poursuivent dans le présent et l'avenir.

L'intelligence artificielle est une branche de l'ordinateur qui travaille pour lui faire effectuer des tâches qu'une personne peut faire intellectuellement, telles que la déduction, l'apprentissage et l'autocorrection, et représente également l'étude des capacités mentales et mentales à travers son utilisation dans le domaine des calculs.[20]

II.2.1 Différents types d'intelligence artificielle:

Il existe principalement deux types d'AI basés sur la fonctionnalité et les capacités




Figure II.1: Types d'intelligence artificielle (AI)[11]

Type 1 Basé sur la fonctionnalité:

II.2.1.1 Machine réactive:

La forme la plus fondamentale et ancienne d'intelligence artificielle est connue pour sa capacité à répondre à divers stimuli, tout comme un être humain. Cependant, ce type d'IA manque de capacité de mémoire et ne peut pas utiliser les connaissances ou l'expérience passées pour améliorer les résultats. Par conséquent, il ne peut pas s'auto-entraîner comme le font les systèmes d'IA modernes

Exemple : Deep Blue, le supercalculateur d'IBM qui joue aux échecs, est l'exemple parfait de ce type de machines. Il est célèbre pour avoir vaincu le grand maître international Garry Kasparov à la fin des années 1990. Deep Blue peut identifier différentes pièces de l'échiquier et comment chacune se déplace. Il peut identifier toutes les actions légales possibles pour lui-même et ses opposants. En fonction de l'option, il sélectionne le meilleur mouvement possible. Cependant, il n'a pas la capacité d'apprendre de ses mouvements passés car ces machines n'ont pas de mémoire propre.[11]

II.2.1.2 Théorie limitée:

Ce type d'IA, ainsi que la capacité des machines réactives, ont des capacités de mémoire afin qu'elles puissent utiliser les informations expériences passées pour prendre de meilleures décisions futures. La plupart des applications courantes qui existent autour de nous entrent dans cette catégorie. Ces applications d'IA peuvent être entraînées par un grand volume de données d'entraînement qu'elles stockent dans leur mémoire dans un modèle de référence

Exemple: La technologie de mémoire limitée est utilisée dans de nombreuses voitures autonomes. Ils stockent des données telles que la localisation GPS, la vitesse des voitures à proximité, la taille nature des obstacles, parmi une centaine d'autres types de données pour conduire comme le fait un humain.[11]

II.2.1.3 Théorie de l'esprit:

La théorie de l'esprit est le prochain niveau de l'IA, qui a une présence très limitée ou nulle dans notre vie quotidienne. Ces types d'IA sont principalement au stade « Travail en cours » et sont généralement confinés aux laboratoires de recherche. Ces types d'IA, une fois développés, auront une compréhension très profonde de l'esprit humain allant de leurs besoins, goûts, émotions, processus de pensée, etc. En se basant sur leur compréhension de l'esprit humain et de leurs caprices, l'IA sera en mesure de modifier sa propre réponse.

Exemple: Le chercheur Winston dans ses recherches, a montré un prototype d'un robot qui peut marcher dans le petit couloir avec d'autres robots venant de la direction opposée; l'IA peut prévoir les mouvements d'autres robots et peut tourner à droite, à gauche ou dans tout autre sens afin d'éviter une éventuelle collision avec les robots entrants. Selon Wilson, ce robot détermine son action en fonction de son « bon sens » de la façon dont les autres robots se déplaceront.[11]

II.2.1.4 IA consciente d'elle-même:

Ceci est la dernière étape de l'IA. Son existence actuelle n'est que hypothétique et ne se trouve que dans les films de science-fiction. Ce type d'IA peut comprendre et évoquer des émotions humaines et avoir ses propres émotions. Ces types d'IA sont à des décennies, voire des siècles, de se matérialiser. C'est ce genre d'IA qui rend les sceptiques de l'IA comme Elon Musk méfiants. C'est parce qu'une fois qu'elle est consciente d'elle-même, l'IA peut entrer en mode d'autoprotection ; elle pourrait considérer l'humanité comme une menace potentielle et poursuivre directement ou indirectement des efforts pour mettre fin à l'humanité.[11]

Type 2 Basé sur les capacités

II.2.1.5 Intelligence artificielle étroite (Artificial Narrow Intelligence ANI):

Toutes les applications d'IA existantes que nous voyons autour de nous entrent dans cette catégorie. L'ANI comprend un système d'IA qui peut effectuer des tâches spécifiques étroitement définies, tout comme les humains. Cependant, ces machines ne peuvent pas effectuer des tâches pour lesquelles elles n'ont pas été programmées auparavant, de sorte qu'elles ne parviennent pas à effectuer une tâche sans précédent. Basé sur la classification mentionnée ci-dessus, ce système est une combinaison de toute l'IA à mémoire réactive et limitée. Les algorithmes d'IA que nous utilisons dans le monde d'aujourd'hui pour effectuer la modélisation prédictive la plus complexe entrent dans cette catégorie d'IA[11].

II.2.1.6 Intelligence artificielle générale (Artificial General Intelligence AGI):

AGI a la capacité de former, d'apprendre, de comprendre et d'exécuter des fonctions comme le fait un humain normal. Ces systèmes auront des capacités multifonctionnelles couvrant différents domaines. Ces systèmes seront plus agiles et réagiront et improviseront comme des humains face à des scénarios inédits. Il n'y a pas d'exemple concret de ce type d'IA, mais de nombreux progrès ont été réalisés dans ce domaine[11].

II.1.2.7 L 'Intelligence Artificielle Super (Artificial Super Intelligence ASI):

Sera le point culminant du développement de l'IA. L 'ASI sera la forme d'intelligence la plus puissante jamais existée sur cette planète. Elle sera capable d'accomplir toutes les tâches mieux que les humains en raison de sa capacité de traitement des données, de sa mémoire et de sa capacité de prise de décision extraordinairement supérieures. Certains chercheurs craignent que l'avènement de l'ASI ne conduise finalement à une "singularité technologique". Il s'agit d'une situation hypothétique dans laquelle la croissance de la technologie atteindra un stade incontrôlable, entraînant un changement inimaginable dans la civilisation humaine... À l'heure actuelle, il est très difficile de prévoir à quoi ressemblera notre avenir lorsque se matérialisera une forme plus habile d'IA. Cependant, avec une grande certitude, nous sommes encore loin d'atteindre ce stade car nous ne sommes qu'à un stade très précoce du développement d'une IA avancée. Pour les partisans de l'IA, nous pouvons dire que nous ne faisons que gratter la surface pour découvrir le véritable potentiel de l'IA, et pour les sceptiques de l'IA, il est trop tôt pour avoir des frissons à propos de la singularité technologique.[11]

II.3 L 'apprentissage automatique:

L'apprentissage automatique (machine learning ML) fait partie de l'intelligence artificielle (AI), permettant aux applications de prédire les résultats avec une plus grande précision sans avoir besoin d'être programmées explicitement. Les algorithmes d'apprentissage automatique utilisent des données préexistantes pour prédire les valeurs de nouvelles sorties, et les applications populaires de cette technologie incluent les recommandations des moteurs de recherche et des magasins en ligne. L 'apprentissage automatique est également utilisé dans les programmes de détection de fraude, le tri des courriers indésirables, la détection des menaces, l'automatisation des tâches et la maintenance prédictive.[12]

II.3.1 Composants de l'apprentissage automatique:

II.3.1.1 Les données:

Les machines ont besoin de beaucoup de données pour fonctionner, apprendre et, en fin de compte, prendre des décisions en fonction de celles-ci. Ces données peuvent être n'importe quel fait, valeur, son, image, texte non traité qui peut être interprété et analysé. Un ensemble de données est une donnée consolidée d'un genre similaire qui est capturée dans différents environnements. Par exemple, un ensemble de données de billets de banque contiendra des images de billets capturées dans différentes orientations, lumière, caméras mobiles et arrière-plan afin d'obtenir une précision maximale dans la classification et l'identification des billets .

Une fois qu'un jeu de données est prêt, il est utilisé pour la formation, la validation et le test du modèle ML. Plus l'ensemble de données est grand, meilleures sont les possibilités d'apprentissage pour le modèle, plus les chances d'obtenir des résultats précis sont élevées.[13]

II.3.1.2 Algorithmes:

Il suffit de considérer un algorithme comme un programme mathématique ou logique qui transforme un ensemble de données en modèle. Différents types d'algorithmes peuvent être choisis, en fonction du type de problème que le modèle tente de résoudre, des ressources disponibles et de la nature des données .

Les algorithmes d'apprentissage automatique utilisent des méthodes de calcul pour « apprendre » des informations directement à partir de données sans s'appuyer sur une équation prédéterminée comme modèle.[13]

II.3.1.3 Modèle

En apprentissage automatique, un modèle est une représentation informatique de processus réels. Un modèle ML est entraîné à reconnaître certains types de modèles en l'entraînant sur un ensemble de données à l'aide d'algorithmes pertinents. Une fois qu'un modèle est formé, il peut être utilisé pour faire des prédictions.[13]

II.3.1.4 Extraction de fonctionnalités :

L'extraction de caractéristiques est une technique utilisée pour régulariser le nombre de caractéristiques dans un ensemble de données. Les ensembles de données peuvent avoir plusieurs caractéristiques. Si les caractéristiques dans l'ensemble de données sont similaires ou varient considérablement, alors les observations stockées dans l'ensemble de données risquent de faire souffrir un modèle d'apprentissage automatique d'un sur ajustement. Le sur ajustement se produit lorsque le modèle apprend les détails et le bruit des données d'entraînement au point où cela affecte négativement les performances du modèle sur de nouvelles données. Pour résoudre ce problème, il est nécessaire d'utiliser des techniques d'extraction de caractéristiques pour réduire le nombre de caractéristiques dans un ensemble de données en créant de nouvelles caractéristiques à partir des existantes.[13]

II.3.1.5 Formation:

La formation comprend des approches qui permettent aux modèles d'apprentissage automatique d'identifier des modèles et de prendre des décisions. Il existe différentes façons d'y parvenir, y compris l'apprentissage supervisé, l'apprentissage non supervisé, l'apprentissage par renforcement[13].

II.4 l'apprentissage en profondeur(deep learning DL):

L'apprentissage profond représente(DL) une branche de l'intelligence artificielle et de l'apprentissage automatique, où les réseaux de neurones artificiels et les algorithmes inspirés du processus de réflexion du cerveau humain peuvent acquérir des compétences en apprenant à partir de grandes quantités de données. Ce domaine comprend un ensemble d'algorithmes qui apprennent par couches, contribuant ainsi à créer une séquence hiérarchique pour comprendre les concepts complexes de manière plus simple[21].

II.4.1 Application de l'apprentissage en profondeur(deep learning):

Les applications de l'apprentissage profond sont aujourd'hui utilisées comme outil puissant et courant pour résoudre des problèmes dans tous les domaines. L'apprentissage profond est utilisé pour résoudre des centaines de problèmes, de la vision par ordinateur au traitement du langage naturel. Dans de nombreux cas,

l'apprentissage profond est plus efficace qu'auparavant. Il est largement utilisé dans les universités pour étudier l'intelligence et dans l'industrie pour construire des systèmes intelligents pour aider les humains dans une variété de tâches. Voici quelques exemples d'applications d'apprentissage profond : assistants virtuels, collecte et détection de fraudes, intelligence émotionnelle, soins de santé et détection de fraudes.[21]

II.4.2 Définition des réseaux de neurones artificiel(artificial neural network ANN):

Un réseau de neurones artificiels est un système d'information. Essayez d'effectuer les tâches du réseau neuronal biologique (cerveau). Composé de milliards de neurones associés à certains d'entre eux ont traversé des milliards de connexions. Par conséquent, il a un modèle qui simule le fonctionnement d'un neurone. Naturel, dont le travail est résumé dans la synthèse cellulaire. Signaux des blancs adjacents, puis ils s'élèvent également en envoyant son signal à une autre cellule voisine.[22]

Cette figure montre les similitudes entre une cellule normale et une cellule artificielle:





Figure II.2: Cellules biologiques et artificielles normales[22]

II.4.3 Structure du réseau neuronal

II.4.3.1 Composants d'un neurone biologique:


Le cerveau humain est l'un des sujets les plus complexes dont les secrets n'ont pas encore été entièrement révélés, c'est un défi majeur pour les scientifiques et les chercheurs. Malgré leurs tentatives constantes d'imiter les neurones du cerveau humain, il est presque impossible d'imiter la précision et la complexité du cerveau humain.[14]



FigureII.3: Structure simplifiée des neurones biologiques[14]

II.4.3.2 Composants d'un neurone artificiel:

Ce figure montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amonts. A chacune de ces entrées est associée un poids w abréviation de weight (poids en anglais) représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals. A chaque connexion est associée un poids.[15]



FigureII.4: Composants d'un neurone artificiel[15]


II.4.4 Structures communes des réseaux de neurones artificiels :

II.4.4.1 Les réseaux de neurones convolutifs (convolutionl Neural Networks):

Égalementappelés CNN, ont révolutionné le monde des réseaux neuronaux en permettant la recherche d'objets dans les images et les vidéos, ainsi que la reconnaissance faciale, la conversion de formats, la génération et l'amélioration d'images, et la création d'effets tels que l'imagerie lente et l'amélioration de la qualité d'image. En bref, la structure des réseaux de neurones convolutifs est utilisée dans tous les cas impliquant des images et des vidéos.[23]

Le processus de convolution : Ce processus est appelé convolution en raison de la technique de pliage utilisée. La convolution peut être représentée sous forme de bloc dans un réseau neuronal. L 'objectif principal de la convolution dans le cas d'un (ConvNet) est d'extraire les caractéristiques de l'image d'entrée tout en préservant la relation spatiale entre les pixels de l'image en apprenant les caractéristiques à partir des petites matrices (noyaux) appliquées aux données d'entrée.

Nous pouvons considérer une image comme une matrice contenant des valeurs de pixels. Supposons maintenant que nous avons une image composée d'une matrice 5x5 et que les valeurs des pixels ne sont que 0 ou 1 pour simplifier (bien que pour une image en niveaux de gris, les valeurs des pixels varient entre 0 et 255). Nous avons également supposé qu'une autre matrice plus petite, 3x3, agira comme un noyau. Comme illustré dans le schéma ci-dessous, les caractéristiques résultantes du processus de convolution seront extraites.[23]



FigureII.5: Réseaux de neurones convolutifs (CNN)[23]

II.4.4.2 Composants des réseaux de neurones convolutifs (CNN):

Le réseau neuronal convolutif est constitué de couches de dérivation Regroupement de couches, couches entièrement connectées et couches de nivellement.

II.4.4.3 Le réseau neuronal récurrent (Recurrent Neural Networks (RNN) :

Est l'une des structures les plus courantes des réseaux de neurones artificiels aujourd'hui. Il est largement utilisé en raison de ses nombreux avantages, tels que la traduction automatique, la reconnaissance vocale et la création d'une voix distinctive pour les assistants personnels tels que Siri. En général, cette structure est considérée comme l'un des meilleurs choix pour les données séquentielles telles que le son, le texte ou la musique.[23]




Figure II.6: Le réseau neuronal récurrent [23]

II.4.4.4 L'évolution des réseaux RNN:

En 1990, Paulak a proposé un modèle de réseau neuronal récurrent. En 1998, Al et Frasconi ont utilisé des données pour lier la structure de l'arbre et ont utilisé les entrées et les sorties pour lier les nœuds de l'arbre. Il n'est pas nécessaire de calculer chaque nœud avec le réseau neuronal artificiel traditionnel (conversion de toutes les entrées en convergence, suivie d'une non-linéarité monotone). En 2011, Buto a introduit des réseaux neuronaux récurrents dans la pensée logique pour l'apprentissage séquentiel. En 2013, Socher a constaté que les relations modélisant.

les présentations vectorielles continues étaient utiles dans les opérations de mouvement et de formes binaires. [16]

II.4.4.5 Fonctionnement de RNN et modèles approuvés:

Les réseaux de neurones récurrents (RNN) sont utilisés dans le traitement de données séquentielles. Dans un modèle de réseau neuronal traditionnel, les données passent de la couche d'entrée à la couche cachée puis à la couche de sortie ; les couches sont entièrement connectées et il n'y a pas de connexion entre les nœuds entre chaque couche et le réseau. Les RNN peuvent se souvenir des informations du moment précédent et les utiliser pour calculer la sortie actuelle ; c'est ce qu'on appelle un nœud. La couche cachée relie chaque couche cachée, les entrées de la couche d'entrée et la dernière sortie de la couche cachée. Théoriquement, toute longueur de données séquentielles peut être traitée par un RNN. Cependant, en pratique, pour réduire la complexité, on suppose souvent que l'état actuel est lié uniquement aux états précédents. Le modèle optimisé basé sur RNN utilise une mémoire à court et long terme (LSTM) et une unité récurrente de porte (GRU) dans une structure multicouche complète[17].

II.4.4.6 La différence fondamentale entre intelligence artificielle AI - L'apprentissage automatique ML et l'apprentissage en profondeur :

L'apprentissage en profondeur et l'apprentissage automatique nécessitent deux sous-domaines de l'intelligence artificielle (AI) et de l'apprentissage en profondeur il s'agit en fait d'un sous-domaine de l'apprentissage automatique[18].




Figure II.7: La différence fondamentale entre AI - ML et DL[18]

II.5 Conclusion

On peut dire que l'apprentissage machine et l'apprentissage profond sont deux évolutions majeures dans le domaine de l'intelligence artificielle, contribuant à permettre aux dispositifs informatiques d'apprendre et de s'adapter aux données de manière autonome et précise. L'apprentissage machine constitue la base de l'apprentissage profond, fournissant le cadre général et fondamental pour comprendre et analyser les données, ainsi que pour en extraire des connaissances.

Chapitre III

Implémentation du Système

III.1 Introduction:

Suite à la propagation rapide de la maladie du palmier, qui représente une menace majeure pour la production et la qualité des récoltes, il est devenu crucial de trouver des solutions efficaces. Dans cette optique, le traitement d'images est largement utilisé pour détecter les maladies affectant les plantes. Ce processus de détection comprend plusieurs étapes clés, telles que l'acquisition d'images, le prétraitement, la segmentation, l'extraction de caractéristiques et enfin la classification à l'aide d'un réseau neuronal pour le classificateur.

Le présent chapitre se concentre sur une méthode spécifique visant à détecter l'invasion du ver rhinocéros dans les palmiers en utilisant des photographies prises par un drone. Notre approche repose sur une méthode intelligente, dans laquelle nous avons employé des réseaux neuronaux pour la classification, ainsi que la technique de HOG (Histogramme de Gradients Orientés) pour l'extraction des paramètres à l'aide de MATLAB. Cette combinaison nous permet d'obtenir des résultats précis et fiables dans la détection de cette menace spécifique pour les palmiers.



Figure III.1: Examen du Quadcoptère FPV KF607

III.2 Présentation des outils de développement :

III.2.1 le matériels :

Pour notre étude, nous avons utilisé un drone KF607 équipé d'un système GPS (Global Positioning System) et de caméras réglables. Ce quadricoptère est doté d'un contrôle optique avec une caméra grand angle HD (Haute Définition) 5G 1080P. Le KF607 est un quadcoptère très compact, facilement transportable d'une seule main grâce à ses dimensions pliées de $13.6 \times 8.5 \times 6$ cm et son poids de seulement 320

grammes. Son boîtier extérieur est en plastique et est disponible uniquement en noir mat.

- Spécifications :

- ✓ Distance R / C : 100 m / Distance Wifi : environ 60 m.
- ✓ Batterie : 3.7V 1800mAh (Lipo).
- ✓ Batterie de l'émetteur : 3.7V 350mAh intégré.
- ✓ Temps de vol : 15-20 minutes.
- ✓ Temps de charge : 150 minutes.
- ✓ Caméra frontale : grand angle 1080P ou 4K.
- ✓ Caméra inférieure : 480P.
- ✓ Diamètre de l'hélice : 14.5 cm / 5.8 pouces.
- ✓ Taille du produit : 13,6 x 8,5 x 6 cm (plié) et 27 x 26 x 6 cm (déplié).
- ✓ Poids du produit : 0.32 kg / 0.7 lb.
- ✓ Fréquence : 2.4.
- ✓ Canal : 4CH.
- ✓ Gyroscope : 6 axes.

III.2.2. Méthodes :

Dans le cadre de notre étude, nous avons utilisé la bibliothèque de deep learning de MATLAB, qui offre une vaste gamme d'outils et de fonctionnalités pour la conception, la formation et le déploiement de réseaux neuronaux profonds. Cette bibliothèque joue un rôle essentiel dans l'application de techniques avancées de reconnaissance d'images et de modèles prédictifs pour la détection des maladies affectant les palmiers.



Figure III.2: Interface MATLAB.

En exploitant les fonctionnalités de la bibliothèque de deep learning, nous avons pu améliorer la précision de la classification et obtenir des résultats plus fiables dans notre système de détection.

III.3. Zone d'étude et préparation à l'expérience :

Les palmiers dattiers sont une culture vitale dans de nombreuses régions du monde, mais ils sont souvent touchés par diverses maladies qui affectent leur santé et réduisent leur productivité. Afin de contrôler la propagation précoce de ces maladies et d'améliorer la santé des palmiers, il est essentiel d'analyser les données en utilisant des drones pour capturer des images haute résolution et extraire les informations nécessaires.



Figure III.3 : Image réelle prise par un drone montrant un groupe de palmiers à différents stades d'infection.

Notre étude sur le terrain a été menée dans la wilaya d'El Oued, plus précisément dans la commune de Taleb-Arabi. Nous avons utilisé un drone (Quadcoptère FPV KF607), une entreprise chinoise spécialisée dans la fabrication de drones commerciaux sans pilote, pour capturer des images réelles en différents stades d'infection. Le drone était équipé d'une caméra haute résolution spécialement conçue pour la photographie. Nous avons pris des photos des palmiers sous différents angles et hauteurs afin d'obtenir une vue complète de leur état de santé. Les données collectées ont été stockées sous forme de photos, comme illustré dans la figure III.3.

Lors de la prise des photos, nous avons remarqué l'apparition de signes d'infection sur différentes parties des palmiers, témoignant du niveau de propagation de l'infestation. Cela est illustré dans la figure III.4.




Figure III.4 : Visualisation de l'expérience, où les zones rouges indiquent des palmiers infestés et les zones vertes indiquent des palmiers non infectés.

III.4. Stades de l'infection étudiés

Tous les palmiers infectés ont été minutieusement examinés afin de surveiller les symptômes et d'évaluer l'évolution de l'infection. Les symptômes ont été documentés par des photos, prises lors de survols réguliers des palmiers à l'aide d'un drone Quadcopter KF607 équipé d'une caméra RVB (rouge-vert-bleu).

Dans le cadre de notre étude, nous avons classé les palmiers en deux catégories distinctes en fonction de leur degré d'infection :

✓ Catégorie "Healthy" ("Sains") :

Cette catégorie comprend les palmiers sains, qui se distinguent par leur apparence exempte de toute impureté, leur feuillage dense et leur couleur verte vibrante, comme illustré dans la figure III.5, qui montre une image réelle d'un palmier sain, et la figure III.6, qui présente une image thermique d'un palmier sain.



Figure III.5 : Image réelle d'un palmier sain



Figure III.6 : Image thermique d'un palmier sain

✓ **Catégorie "Diseased" ("Malades" ou "classe d'infection") :**

Cette catégorie regroupe les palmiers infectés, présentant des symptômes tels que la diminution de la densité du feuillage, la décoloration des feuilles de palmier et d'autres signes d'infection. Les images réelles et thermiques suivantes illustrent différents stades d'infection :



Figure III.7 : Image réelle d'un palmier malade de classe 1 infecté (apparition de l'infection)





Figure III.9 : Image réelle d'un palmier malade de classe 2 infecté(infection modérée)



Figure III.10 : Image thermique d'un palmier en cas modéré d'infection



Figure III.11 : Image réelle d'un palmier malade de classe 3(complètement infecté)



Figure III.12 : Image thermique d'un palmier complètement infecté

III.5. Étapes de base pour la détection des maladies :

Le concept général qui constitue le cadre de tout algorithme lié à la vision pour la classification d'images est pratiquement le même. Tout d'abord, les images sont capturées à l'aide d'un appareil photo. Ensuite, des techniques de traitement d'images sont appliquées aux images obtenues afin d'extraire les caractéristiques pertinentes nécessaires à une analyse plus approfondie. Ensuite, diverses techniques d'analyse discriminatoire sont utilisées pour classer les images en fonction du problème spécifique à résoudre.




Figure III.13 : Étapes de base pour la détection et la classification de l'infestation des palmiers.

La Figure III.13 illustre la procédure de base de l'algorithme de détection basé sur la vision proposé dans cette étude.

III.5.1. Acquisition d'images :

Pour l'acquisition des images, des photographies des palmes sont prises à l'aide d'une caméra intégrée à un drone. La caméra est équipée d'une structure de conversion des couleurs de l'image en format RVB des feuilles de palmier. Ensuite, une conversion à l'espace colorimétrique indépendante du périphérique est appliquée à la structure de conversion des couleurs.

III.5.2. Prétraitement de l'image :

Le prétraitement de l'image désigne l'élimination du bruit lors de la suppression d'images ou d'autres objets indésirables par différentes techniques de prétraitement à appliquer. Cela comprend le recadrage de l'image de la feuille pour obtenir la région d'intérêt, appelée découpage d'image. Le lissage de l'image est effectué à l'aide d'un filtre de lissage pour réduire les variations indésirables. L'amélioration de l'image est réalisée pour augmenter le contraste et rendre les détails plus visibles.

III.5.3. Segmentation d'image :

La segmentation consiste à diviser une image en différentes parties présentant des caractéristiques similaires ou une certaine similitude. Plusieurs méthodes peuvent être utilisées pour réaliser la segmentation, telles que la méthode d'Otsu, le clustering k-means, la conversion de l'image RVB en modèle SIH (Hue, Saturation, Intensity), etc.

III.5.4. Extraction des caractéristiques :

L'extraction de caractéristiques ou extraction des paramètres des images joue un rôle essentiel dans l'identification d'un objet. Dans de nombreux domaines du traitement d'images, l'extraction de caractéristiques est largement utilisée. Des attributs tels que la couleur, la texture, la morphologie, les contours, etc., peuvent être exploités pour détecter les maladies des plantes. Dans notre méthode, nous nous concentrons particulièrement sur la couleur et la texture pour obtenir des caractéristiques distinctives de l'image. Pour ce faire, nous utilisons la conversion de l'image RVB en espace colorimétrique HSI (Hue, Saturation, Intensity) qui représente un modèle de couleur utilisé pour représenter les images.

La formule générale de HSI le plus utilisé est représentée par [26] :

$$\begin{cases} H = \begin{cases} \theta & \text{if } B < G \\ 360 - \theta & \text{if } B > G \end{cases} \\ S = 1 - \frac{3}{(R+G+B)} \min(R, G, B) \\ I = \frac{1}{3} (R + G + B) \end{cases} \quad (\text{III.1})$$

III.5.5. Classification:

La classification en traitement d'images est un processus essentiel qui consiste à attribuer des étiquettes ou des catégories prédéfinies à des images en fonction de leurs caractéristiques visuelles. Le processus de classification d'images commence généralement par l'extraction de caractéristiques pertinentes à partir des images. Les modèles de classification couramment utilisés en traitement d'images incluent les classifieurs linéaires tels que les SVM (Support Vector Machines), les classifieurs basés sur les arbres de décision tels que les Random Forests, ainsi que les réseaux de neurones profonds tels que les CNN (Convolutional Neural Networks).

Dans notre travail on a utilisé le CNN.

Une fois les caractéristiques extraites, les images de la base de données d'apprentissage sont classées à l'aide d'un CNN. Les vecteurs de caractéristiques extraits sont utilisés comme entrées pour les neurones du réseau. La sortie d'un neurone est calculée en utilisant une fonction de somme pondérée des entrées, suivie d'une fonction d'activation. Pour l'apprentissage, l'algorithme de rétropropagation du gradient est utilisé.

L'algorithme du réseau de neurones à rétropropagation (BPNN) est utilisé dans un réseau récurrent. Une fois que le réseau a été entraîné, les poids des connexions neuronales deviennent fixes et peuvent être utilisés pour calculer les valeurs de sortie pour de nouvelles images de requête qui ne sont pas présentes dans la base de données d'apprentissage. Cette utilisation des poids fixes permet au réseau neuronal d'effectuer des prédictions sur de nouvelles données en utilisant les connaissances acquises lors de l'apprentissage. Les valeurs de sortie calculées pour les nouvelles images de requête sont basées sur les patterns et les caractéristiques apprises par le réseau pendant la phase d'apprentissage. Ainsi, le réseau peut attribuer une classe ou une étiquette à chaque nouvelle image en se basant sur les similarités avec les exemples de

la base de données d'apprentissage. La figure III.14 représente les réseaux de Réseau de rétropropagation.




Figure III.14: Réseau de rétropropagation [19]

III.6. Base de données :

Notre ensemble de données se compose au total de 10 images couleur de dimensions $64 * 64$, réparties en deux catégories avec 5 images pour chaque catégorie. Pour l'apprentissage de notre modèle, nous avons utilisé un ensemble de 10 images, tandis que 4 autres images ont été réservées pour les tests. A cause des images avec un nombre de 10 on a procédé à augmenter le nombre des images (voir section III.7.3).

En résumé, la procédure d'augmentation d'images consiste à appliquer des transformations à une base de données d'images existante pour créer de nouvelles images et augmenter la taille de l'ensemble de données. Cela peut améliorer les performances du modèle en introduisant des variations et en aidant à prévenir le surajustement.

Le lot de test est composé de 4 images sélectionnées de manière aléatoire, comprenant 2 images de chaque catégorie. Ces images de test ont été choisies de manière aléatoire afin de représenter au mieux la diversité de notre ensemble de données. Elles nous permettent d'évaluer la capacité de notre modèle à généraliser sur de nouvelles images qu'il n'a pas encore vues.

Quant au lot d'entraînement, il est composé de 10 images également sélectionnées de manière aléatoire. L'ordre des images dans ce lot n'a pas d'importance, car notre modèle sera capable d'apprendre à partir de ces exemples, peu importe leur séquence. En résumé, notre ensemble de données comprend 10 images, réparties en 2 catégories avec 5 images pour chaque catégorie. Le lot d'entraînement contient 10 images dans

un ordre aléatoire, tandis que le lot de test comprend 4 images sélectionnées de manière aléatoire, avec 2 images de chaque catégorie.




Figure III.15: Visualisation d'un exemple d'ensemble de données

➤ Propriétés de l'image :

Le tableau III.1 présente les propriétés des images.

Taille	2221 *1464
Largeur	2221 pixels
Hauteur	1464 pixels
Précision horizontale	96 points par pouce
Résolution verticale	96 points par pouce

Tableau III.1 :Propriétés de image

III.7. Mise en œuvre du système :

La mise en œuvre du système comprend plusieurs étapes essentielles pour entraîner un classificateur de réseau neuronal à l'aide des caractéristiques HOG et évaluer sa précision de classification. Les détails de chaque étape sont décrits ci-dessous :

III.7.1. Préparation des données :

➤ Définition des chemins d'accès pour l'entraînement et les tests :

Avant de commencer la mise en œuvre du système, nous avons défini les chemins d'accès pour les fichiers d'entraînement et de test. Le chemin d'accès pour les fichiers

d'entraînement est défini comme "C:\Users\LAPTA\Desktop\training", tandis que le chemin d'accès pour les fichiers de test est défini comme "C:\Users\LAPTA\Desktop\testing".

```
% Définir les chemins d'accès pour l'entraînement et les tests
trainPath = 'C:\Users\LAPTA\Desktop\estbellel413\training';
testPath = 'C:\Users\LAPTA\Desktop\estbellel413\testing';
```

Figure III.16: Définition des chemins d'accès pour l'entraînement et les tests

La Figure III.16 illustre la section du programme où les chemins d'accès des fichiers d'entraînement et de test sont définis.

➤ **Comptage des fichiers d'entraînement et de test, et définition de la taille de l'image :**

Dans cette section, nous avons effectué le comptage des fichiers d'entraînement et de test, ainsi que la définition de la taille de l'image. Le nombre total de fichiers d'entraînement s'élève à 10, tandis que le nombre total de fichiers de test est de 4. De plus, la taille de l'image a été fixée à 64 * 64 pixels pour assurer une standardisation des images utilisées dans le processus.

```
% Compter le nombre de fichiers d'entraînement
trainFiles = dir(fullfile(trainPath, '*.jpg'));
numTrainFiles = numel(trainFiles);

% Compter le nombre de fichiers de test
testFiles = dir(fullfile(testPath, '*.jpg'));
numTestFiles = numel(testFiles);

% Définir la taille de l'image
imageSize = [64, 64];
```

Figure III.17: Comptage des fichiers d'entraînement et de test, et définition de la taille de l'image

La figure III.17 présente les lignes de code du programme correspondantes à cette section. Elle montre comment les fichiers d'entraînement sont comptés à l'aide de la fonction "dir" et la variable "numTrainFiles", ainsi que le comptage des fichiers de test avec la fonction "dir" et la variable "numTestFiles". De plus, elle illustre la définition de la taille de l'image en utilisant la variable "imageSize" avec une valeur de 64×64 pixels.

III.7.2. Extraction des caractéristiques HOG pour les images d'entraînement :

Dans cette section, nous avons extrait les caractéristiques HOG (Histogram of Oriented Gradients) pour les images d'entraînement. Le processus comprend plusieurs

étapes, notamment le prétraitement des images, l'extraction des caractéristiques HOG et la gestion des étiquettes des images d'entraînement.

➤ ***Prétraitement des images d'entraînement :***

Avant d'extraire les caractéristiques HOG, nous avons effectué un prétraitement des images d'entraînement. Cela comprend le redimensionnement des images à la taille spécifiée, la conversion des images en niveaux de gris et l'ajustement du contraste des images.

➤ ***Extraction des caractéristiques HOG pour les images d'entraînement :***

Après le prétraitement des images, nous avons extrait les caractéristiques HOG pour chaque image d'entraînement. Les caractéristiques HOG sont calculées en utilisant une taille de cellule de [8, 8], une taille de bloc de [2, 2] et un nombre de compartiments d'histogramme de 9.

➤ ***Gestion des étiquettes des images d'entraînement :***

Nous avons également géré les étiquettes associées aux images d'entraînement. Chaque image d'entraînement est associée à une étiquette qui indique sa catégorie. Les étiquettes ont été extraites à partir des noms de fichiers en utilisant une convention de nommage spécifique (par exemple, "cat_01.jpg" est associé à l'étiquette "cat").

La figure III.18 présente les lignes de code du programme correspondantes à cette section. Elle montre comment les caractéristiques HOG sont extraites à l'aide de la fonction "*extractHOGFeatures*" en spécifiant les paramètres tels que la taille des cellules, la taille du bloc et le nombre de compartiments de l'histogramme. De plus, elle illustre le prétraitement des images d'entraînement, y compris le redimensionnement, la conversion en niveaux de gris et l'ajustement du contraste. Enfin, elle met en évidence la gestion des étiquettes des images d'entraînement en extrayant les informations à partir des noms de fichiers.

```

% Extraire les caractéristiques HOG pour les images d'entraînement
trainFeatures = [];
trainLabels = {};
for i = 1:numTrainFiles
    img = imread(fullfile(trainPath, trainFiles(i).name));
    img = imresize(img, imageSize); % Redimensionner l'image
    img = rgb2gray(img); % Convertir en niveaux de gris
    img = imadjust(img); % Ajuster le contraste de l'image
    cellSize = [8 8]; % Taille des cellules
    blockSize = [2 2]; % Taille du bloc
    numBins = 9; % Nombre de compartiments de l'histogramme
    % Extraire les caractéristiques HOG
    features = extractHOGFeatures(img, 'CellSize', cellSize, 'BlockSize', blockSize, 'NumBins', numBins);
    trainFeatures = [trainFeatures; features];

    [~, filename, ~] = fileparts(trainFiles(i).name);
    label = strtok(filename, '_');
    trainLabels{i} = label;
end

```

Figure III.18: Extraction des caractéristiques HOG pour les images d'entraînement

III.7.3. Augmentation des images d'entraînement :

Dans cette section, nous effectuons l'augmentation des images d'entraînement afin d'accroître la variabilité des données. L'augmentation des images consiste à appliquer diverses transformations aux images d'entraînement, ce qui permet d'augmenter la capacité du modèle à généraliser.

➤ Définition des paramètres pour l'augmentation des images :

Avant de procéder à l'augmentation des images, il est nécessaire de définir les paramètres d'augmentation. Ces paramètres comprennent une plage de rotation de $[-10, 10]$ degrés, une probabilité de basculement horizontal de l'image de 0.5, une plage d'échelle de $[0.8, 1.2]$ et un écart type du flou gaussien de 1.5.

➤ Application de l'augmentation d'images sur les images d'entraînement :

Pour chaque image d'entraînement, les étapes suivantes sont effectuées :

- Redimensionnement de l'image à la taille spécifiée.
- Conversion de l'image en niveaux de gris.
- Ajustement du contraste de l'image.
- Application de l'augmentation d'images en utilisant les paramètres définis précédemment.
- Redimensionnement de l'image augmentée à la taille spécifiée.
- Extraction des caractéristiques HOG pour l'image augmentée en utilisant une taille de cellule de $[8, 8]$, une taille de bloc de $[2, 2]$ et un nombre de compartiments d'histogramme de 9.

➤ ***Fusion des caractéristiques augmentées pour l'entraînement :***

Les caractéristiques HOG extraites des images augmentées sont fusionnées avec les caractéristiques HOG des images d'entraînement d'origine. Cela permet d'augmenter la variabilité des données d'entraînement.

➤ ***Fusion des étiquettes d'entraînement augmentées :***

Les étiquettes associées aux images d'entraînement augmentées sont fusionnées avec les étiquettes des images d'entraînement d'origine. Cela garantit que les étiquettes correspondent aux images correspondantes après l'augmentation.

La figure III.19 présente les lignes de code du programme correspondantes à cette section. Elle montre comment les paramètres d'augmentation sont définis, puis comment les images d'entraînement sont augmentées en appliquant les transformations spécifiées. Ensuite, les caractéristiques HOG sont extraites des images augmentées et fusionnées avec les caractéristiques HOG d'origine. De plus, elle met en évidence la fusion des étiquettes d'entraînement augmentées avec les étiquettes d'entraînement d'origine. L'augmentation des images d'entraînement contribue à améliorer la robustesse et les performances du modèle lors de la phase d'apprentissage.

Les dimensions de la matrice "trainFeatures" sont de 110 lignes et 1764 colonnes.

Cela signifie qu'il y a 110 images d'entraînement, et pour chaque image, 1764 caractéristiques HOG ont été extraites.

```

% Définition des paramètres pour augmenter les images
rotationRange = [-10, 10]; % Plage de rotation
flipProbability = 0.5; % Probabilité de basculement horizontal de l'image
scaleRange = [0.8, 1.2]; % Plage d'échelle
blurSigma = 1.5; % Écart type du flou gaussien
% Application de l'augmentation d'images sur les images d'entraînement
for Aug= 1:10
    augmentedTrainFeatures = [];
    for i = 1:numTrainFiles
        img = imread(fullfile(trainPath, trainFiles(i).name));
        img = imresize(img, imageSize); % Redimensionnement de l'image
        img = rgb2gray(img); % Conversion en niveaux de gris
        img = imadjust(img); % Ajustement du contraste de l'image

        % Application de l'augmentation d'images
        augmentedImg = augmentImage(img, rotationRange, flipProbability, scaleRange, blurSigma);
        augmentedImg = imresize(augmentedImg, imageSize); % Redimensionnement de l'image

        cellSize = [8 8]; % Taille des cellules
        blockSize = [2 2]; % Taille du bloc
        numBins = 9; % Nombre de compartiments de l'histogramme
        % Extraction des caractéristiques HOG
        features = extractHOGFeatures(augmentedImg, 'CellSize', cellSize, 'BlockSize', blockSize, 'NumBins', numBins);
        augmentedTrainFeatures = [augmentedTrainFeatures; features];

        [~, filename, ~] = fileparts(trainFiles(i).name);
        label = strtok(filename, '_');
        augmentedTrainLabels{i} = label;
    end
% Fusion des caractéristiques augmentées pour l'entraînement avec les caractéristiques d'origine
trainFeatures = [trainFeatures; augmentedTrainFeatures];
% Fusion des étiquettes d'entraînement augmentées avec les étiquettes d'entraînement d'origine
trainLabels = [trainLabels, augmentedTrainLabels];
%%
end

```

Figure III.19: Augmentation des images d'entraînement

III.7.4. Extraction des caractéristiques HOG pour les images de test :

La figure III.20 présente les lignes de code du programme correspondantes à cette section. Elle montre comment les caractéristiques HOG sont extraites pour les images de test. Tout d'abord, les images de test subissent un prétraitement similaire à celui des images d'entraînement, comprenant le redimensionnement, la conversion en niveaux de gris et l'ajustement du contraste. Ensuite, les caractéristiques HOG sont extraites pour chaque image de test en utilisant les mêmes paramètres que ceux utilisés pour les images d'entraînement. De plus, elle met en évidence la gestion des étiquettes associées aux images de test, qui est similaire à celle des images d'entraînement. Chaque image de test est associée à une étiquette indiquant sa catégorie.

Veuillez noter que l'extrait de code fourni extrait les caractéristiques HOG pour les images de test et les stocke dans la matrice "*testFeatures*". Les étiquettes associées aux images de test sont stockées dans la cellule "*testLabels*".

```

% Extraire les caractéristiques HOG pour les images de test
testFeatures = [];
testLabels = {};
for i = 1:numTestFiles
    img = imread(fullfile(testPath, testFiles(i).name));
    img = imresize(img, imageSize); % Redimensionner l'image
    img = rgb2gray(img); % Convertir en niveaux de gris
    img = imadjust(img); % Ajuster le contraste de l'image

    cellSize = [8 8]; % Taille des cellules
    blockSize = [2 2]; % Taille du bloc
    numBins = 9; % Nombre de compartiments de l'histogramme
    % Extraire les caractéristiques HOG
    features = extractHOGFeatures(img, 'CellSize', cellSize, 'BlockSize', blockSize, 'NumBins', numBins);
    testFeatures = [testFeatures; features];

    [~, filename, ~] = fileparts(testFiles(i).name);
    label = strtok(filename, '_');
    testLabels{i} = label;
end

```

Figure III.20:Extraction des caractéristiques HOG pour les images de test

III.7.5. Normalisation des caractéristiques :

La normalisation des caractéristiques d'entraînement est effectuée pour mettre à l'échelle les valeurs des caractéristiques dans une plage spécifique en utilisant la méthode "*mapminmax*". Les caractéristiques d'entraînement converties en valeurs numériques sont mises à l'échelle à l'aide de la fonction "*mapminmax*" en utilisant les paramètres déterminés à partir des caractéristiques d'entraînement. La normalisation des caractéristiques de test est réalisée de la même manière, en utilisant les mêmes paramètres de mise à l'échelle, garantissant ainsi une mise à l'échelle cohérente entre les caractéristiques d'entraînement et de test.

III.7.6. Entraînement du classificateur du réseau neuronal :

Le classificateur du réseau neuronal est entraîné à l'aide des caractéristiques d'entraînement normalisées et des étiquettes correspondantes. Dans cet exemple, un réseau neuronal feedforward est utilisé avec un nombre d'unités cachées défini à 200. Les étiquettes sont converties en valeurs numériques pour l'entraînement du réseau neuronal. La fonction d'entraînement utilisée est "*trainscg*", qui est une fonction de rétropropagation du gradient stochastique.

```
% Définir le nombre d'unités cachées pour le réseau neuronal
hiddenUnits = 200;
net = feedforwardnet(hiddenUnits);

% Entraîner le classificateur du réseau neuronal
% net = train(net, trainFeatures, trainLabelsNumeric,'useParallel','yes','showResources','yes');
net.trainFcn = 'trainscg';
net = train(net, trainFeatures, trainLabelsNumeric,'useParallel','yes','showResources','yes');
```

Figure III.21: Entraînement du classificateur du réseau neuronal avec rétropropagation du gradient stochastique.

Dans cette figure (Figure III.21), on présente le processus d'entraînement du classificateur du réseau neuronal en utilisant la technique "*trainscg*" qui se base sur l'algorithme de "rétropropagation du gradient stochastique". Le réseau neuronal est entraîné en utilisant les caractéristiques d'entraînement normalisées et les étiquettes correspondantes. Le réseau neuronal utilisé est de type *feedforwardnet* avec un nombre d'unités cachées défini à 200. Les étiquettes sont converties en valeurs numériques pour l'entraînement du réseau neuronal. L'entraînement est effectué en parallèle en utilisant les données des caractéristiques et des étiquettes numériques avec l'option "*useParallel*", et la progression de l'entraînement est affichée avec l'option "*showResources*".

III.7.7. Prédiction des étiquettes pour les images de test :

Une fois que le réseau neuronal est entraîné, les caractéristiques HOG sont à nouveau extraites pour les images de test. Les images de test sont prétraitées en les redimensionnant, en les convertissant en niveaux de gris et en ajustant leur contraste. Ensuite, les caractéristiques HOG sont extraites des images de test prétraitées. Les caractéristiques de test sont ensuite utilisées comme entrée pour le réseau neuronal entraîné afin de prédire les étiquettes correspondantes.

```
% Effectuer la classification à l'aide du réseau neuronal entraîné
predictedLabelsNumeric = round(net(testFeatures')); % Prédire les étiquettes pour testFeatures
predictedLabels = uniqueLabels(predictedLabelsNumeric);
```

Figure III.22: Prédiction des étiquettes pour les images de test à l'aide du réseau neuronal entraîné

Dans la Figure III.22, nous pouvons observer le processus de prédiction des étiquettes pour les images de test à l'aide du réseau neuronal entraîné. Les caractéristiques HOG sont à nouveau extraites pour les images de test, qui subissent également un

prétraitement comprenant le redimensionnement, la conversion en niveaux de gris et l'ajustement du contraste. Ensuite, les caractéristiques HOG des images de test prétraitées sont utilisées comme entrée pour le réseau neuronal entraîné afin de prédire les étiquettes correspondantes. Les étiquettes prédites sont arrondies et converties en valeurs uniques à l'aide de la variable "*uniqueLabels*".

III.7.8. Évaluation de la précision de la classification :

Pour évaluer la précision de la classification, les étiquettes prédites sont comparées aux étiquettes réelles des images de test. La précision est calculée en divisant le nombre d'étiquettes correctement prédites par le nombre total d'étiquettes dans l'ensemble de test. Le résultat est exprimé en pourcentage.

Le code fourni implémente ces étapes pour entraîner un classificateur de réseau neuronal à l'aide des caractéristiques HOG et évaluer sa précision de classification.

```
% Calculer la précision de la classification
accuracy = sum(strcmp(predictedLabels, testLabels)) / numel(testLabels);
disp(['Précision de la classification: ', num2str(accuracy * 100), '%']);
```

Figure III.23:Évaluation de la précision de la classification pour le réseau neuronal entraîné

Figure III.23 présente le code permettant de calculer la précision de la classification pour le réseau neuronal entraîné. Après avoir prédit les étiquettes pour les images de test, les étiquettes prédites sont comparées aux étiquettes réelles. La précision de la classification est ensuite calculée en divisant le nombre d'étiquettes correctement prédites par le nombre total d'étiquettes dans l'ensemble de test. Le résultat est affiché en pourcentage, ce qui permet d'évaluer l'efficacité du modèle de classification.

III.8.Résultats et discussion:

Les résultats obtenus dans le cadre de l'étude sont présentés dans les figures III.24, III.25, III.26 et III.27. Ces figures fournissent des informations essentielles sur l'entraînement du réseau neuronal, les performances de classification, la distribution des erreurs et la comparaison des performances.




Figure III.24: Entraînement du réseau neuronal et résultats

La Figure III.24 présente les détails de l'entraînement du réseau neuronal ainsi que les résultats obtenus. Les informations fournies comprennent les algorithmes utilisés, la division des données en ensembles d'entraînement et de validation, la méthode d'entraînement utilisée (Scaled Conjugate Gradient - trainscg), la mesure de performance (Mean Squared Error - mse), les calculs réalisés avec l'utilisation de MEX, et les indicateurs de progression tels que le nombre d'époques et le temps écoulé.

Les résultats spécifiques affichent la performance du réseau neuronal, mesurée par l'erreur quadratique moyenne (MSE). Le tableau présente également les valeurs de gradient, qui indiquent les changements dans les poids du réseau neuronal au cours de l'entraînement. De plus, il mentionne le nombre de vérifications de validation effectuées.

Results			
	Samples	MSE	R
Training:	76	2.68345e-5	9.99946e-1
Validation:	17	3.55693e-2	9.37690e-1
Testing:	17	4.34825e-2	9.20945e-1

Figure III.25: Résultats de l'évaluation du modèle de réseau neuronal

La Figure III.25 présente les résultats de l'évaluation du modèle de réseau neuronal. Les données affichées comprennent le nombre d'échantillons évalués, l'erreur

quadratique moyenne (MSE) et le coefficient de corrélation R pour chaque ensemble de données (entraînement, validation et test).

Pour l'ensemble d'entraînement, le modèle a été évalué sur 76 échantillons, avec une MSE de 2.68345e-5 et un coefficient de corrélation R de 9.99946e-1. Ces résultats indiquent une excellente performance du modèle sur les données d'entraînement, avec une faible erreur et une corrélation proche de 1.

Pour l'ensemble de validation, le modèle a été évalué sur 17 échantillons, avec une MSE de 3.55693e-2 et un coefficient de corrélation R de 9.37690e-1. Ces résultats témoignent d'une performance légèrement inférieure par rapport à l'ensemble d'entraînement, mais restent significatifs, avec une erreur et une corrélation acceptables.

Enfin, pour l'ensemble de test, le modèle a été évalué sur 17 échantillons, avec une MSE de 4.34825e-2 et un coefficient de corrélation R de 9.20945e-1. Ces résultats confirment la capacité du modèle à généraliser ses prédictions sur de nouvelles données, bien que l'erreur soit légèrement plus élevée par rapport aux ensembles d'entraînement et de validation.




Figure III.26: Histogramme des erreurs

La Figure III.26 représente un histogramme des erreurs pour le modèle de réseau neuronal. Les données affichées illustrent la distribution des erreurs entre les valeurs cibles et les valeurs de sortie du modèle. L'histogramme des erreurs est divisé en 20

intervalles (bins), permettant de visualiser la répartition des erreurs selon leur magnitude. Les trois séries présentées dans l'histogramme correspondent aux ensembles d'entraînement, de validation et de test.

L'axe vertical de l'histogramme indique le nombre d'occurrences d'erreurs, tandis que l'axe horizontal représente les valeurs d'erreur. Les barres de l'histogramme montrent la fréquence des erreurs dans chaque intervalle. L'histogramme des erreurs permet d'analyser la performance du modèle en mettant en évidence les erreurs les plus fréquentes et leur répartition. Cela permet de comprendre les tendances et les patterns des erreurs, ce qui peut aider à améliorer le modèle en identifiant les zones où il peut présenter des difficultés.




Figure III.27 : Comparaison des performances du modèle de réseau neuronal

La Figure III.27 présente une comparaison des performances du modèle de réseau neuronal pour les ensembles d'entraînement, de validation et de test. Les performances sont évaluées à l'aide du coefficient de corrélation R, qui mesure la corrélation entre les valeurs prédites et les valeurs cibles.

Pour l'ensemble d'entraînement, le coefficient de corrélation R est de 0.99995, ce qui indique une excellente corrélation entre les valeurs prédites et les valeurs cibles. Le modèle a été ajusté pour obtenir une relation linéaire avec une équation de la forme :

$$\text{Output} = 1 * \text{Target} + 0.00062.$$

Pour l'ensemble de validation, le coefficient de corrélation R est de 0.93769, ce qui indique une corrélation légèrement moins forte mais encore significative. Le modèle a été ajusté avec une équation de la forme :

$$\text{Output} = 0.82 * \text{Target} + 0.19.$$


Pour l'ensemble de test, le coefficient de corrélation R est de 0.92095, montrant que le modèle est capable de généraliser et de prédire avec précision les valeurs cibles pour de nouvelles données. L'équation utilisée pour ajuster le modèle est :

$$\text{Output} = 0.85 * \text{Target} + 0.15.$$

Enfin, pour l'ensemble "All" (composé des données d'entraînement, de validation et de test), le coefficient de corrélation R est de 0.97626. Cela indique une forte corrélation entre les valeurs prédites et les valeurs cibles sur l'ensemble complet des données. L'équation utilisée pour ajuster le modèle est :

$$\text{Output} = 0.95 * \text{Target} + 0.046.$$

La Figure III.27 permet de comparer les performances du modèle de réseau neuronal en termes de corrélation entre les valeurs prédites et les valeurs cibles pour les ensembles d'entraînement, de validation et de test, ainsi que pour l'ensemble complet des données. Ces résultats fournissent des informations importantes sur la qualité et la fiabilité du modèle dans sa capacité à prédire les valeurs cibles.



```
Command Window

Computing Resources:
Parallel Workers:
  Worker 1 on DESKTOP-LPD6580, MEX on PCWIN64
  Worker 2 on DESKTOP-LPD6580, MEX on PCWIN64
  Worker 3 on DESKTOP-LPD6580, MEX on PCWIN64
  Worker 4 on DESKTOP-LPD6580, MEX on PCWIN64

Précision de la classification: 75%
fx >>
```

Figure III.28: Précision de la classification du modèle de réseau neuronal et ressources de calcul

La Figure III.28 présente des informations sur la précision de la classification du modèle de réseau neuronal, qui atteint 75%. Cette précision a été évaluée en comparant les étiquettes prédites par le classificateur avec les étiquettes réelles des images de test.

L'affichage dans la fenêtre de commande fournit également des informations détaillées sur les ressources de calcul utilisées. Le modèle a été exécuté en utilisant quatre travailleurs parallèles, chacun étant assigné à une machine spécifique (DESKTOP-LPD6580), et l'environnement MEX sur PCWIN64 a été utilisé. Ceci met en évidence l'importance des ressources de calcul utilisées, notamment les travailleurs parallèles et l'environnement MEX, pour améliorer la vitesse de traitement.

La précision de la classification mesure l'efficacité du modèle dans la tâche de classification, en indiquant le pourcentage d'étiquettes correctement prédites par rapport au nombre total d'étiquettes dans l'ensemble de test. Une précision de 75% indique que le modèle a réussi à classer correctement 75% des échantillons.

La Figure III.28 présente à la fois la précision de la classification du modèle de réseau neuronal et les informations sur les ressources de calcul utilisées, soulignant l'efficacité du modèle dans la tâche de classification et l'impact des ressources de calcul sur le processus d'évaluation de la précision

III.9. Conclusion

En conclusion, ce chapitre a présenté les résultats et les discussions concernant le modèle de réseau neuronal utilisé dans le système automatisé de détection de l'infestation des palmiers par l'Oryctes Agamemnon Burmeister. Les résultats ont démontré une précision de classification de 75%, ce qui témoigne de l'efficacité du modèle dans la tâche de classification des données.

Les différentes figures ont fourni des informations détaillées sur l'entraînement du réseau, les résultats d'évaluation, la corrélation entre les valeurs prédites et les valeurs cibles, ainsi que la répartition des erreurs. De plus, les mesures de corrélation ont été fournies pour les ensembles d'entraînement, de validation et de test, permettant ainsi une évaluation approfondie de la performance du modèle.

En résumé, ce chapitre a mis en évidence la performance du modèle de réseau neuronal dans la détection de l'infestation des palmiers. Les résultats obtenus offrent une base solide pour la suite de l'étude et ouvrent des perspectives prometteuses pour l'amélioration et l'optimisation du modèle, notamment en explorant d'autres techniques d'apprentissage automatique et en intégrant des données supplémentaires telles que des données météorologiques et des informations sur les pratiques de gestion des palmiers.

Conclusion Générale

Conclusion Générale

L'objectif de ce mémoire est de réduire et de limiter la propagation de l'Oryctes agamemnon Burmeister (coléoptère scarabaeidae), un insecte qui entrave la croissance et la production des palmiers. Pour atteindre cet objectif, nous avons développé un système automatisé qui utilise des drones pour capturer des images des palmiers infestés, et qui les intègre ensuite dans un processus d'identification des zones touchées par cet insecte.


Le système automatisé que nous avons mis en place permet une détection rapide et précise des lieux d'infestation des palmiers en utilisant des techniques d'analyse d'images. En prenant des photos aériennes à l'aide de drones, nous obtenons une vue d'ensemble des palmiers, ce qui facilite l'identification des zones affectées.

En intégrant ces images dans notre système, nous utilisons des algorithmes d'apprentissage automatique pour analyser les caractéristiques visuelles et identifier les lieux d'infestation. Cette approche permet de gagner du temps et des ressources par rapport à une évaluation manuelle qui serait fastidieuse et moins précise.

En réduisant et en limitant la propagation de l'Oryctes agamemnon Burmeister, notre système contribue à préserver la santé des palmiers et à maintenir leur production. Il offre également une solution efficace pour les gestionnaires de palmiers, leur permettant de prendre des mesures préventives et de contrôle ciblées.

En conclusion, notre système automatisé basé sur l'imagerie par drone et l'analyse d'images constitue une solution innovante et efficace pour la détection des lieux d'infestation des palmiers par l'Oryctes agamemnon Burmeister. Il offre un potentiel prometteur pour la protection des palmiers et la préservation des écosystèmes agricoles.

Dans une perspective future, il est envisagé d'étendre le système à d'autres espèces de palmiers et à d'autres types d'infestations, ce qui nécessitera une adaptation de l'algorithme et la collecte d'un ensemble de données plus diversifié. Cette expansion pourrait contribuer à la lutte contre les infestations et à la préservation des écosystèmes de palmiers, bénéficiant ainsi aux chercheurs, aux agriculteurs et aux gestionnaires de palmiers.



Bibliographie

Bibliographie

- [1] Conception et commande d'un quadrotor UAV à base d'Arduino. SEDINI Chahrazed et CHERIGUI Nasre-Eddine. 2018 – 2019.
- [2] L. Laib and D.E. Maamria, "Commande d'un Quadrirotor". Mémoire d'ingénieur. École Nationale Polytechnique, Alger. 2011.
- [3] X. Li and L. Yang, "Design and implementation of uav intelligent aerial photograph system," in 2012 4th International Conference on Intelligent Human-Machine Systems and Cybernetics, vol. 2. IEEE, 2012, pp. 200–203.
- [4] Unmanned Aerial Vehicles in Agriculture: A Review of Perspective of Platform, Control, and Applications. JEONGEUN KIM, SEUNGWON KIM, CHANYOUNGJU, AND HYOUNGIL SON, (Senior Member, IEEE).
- [5] Y. Pederi and H. Cheporniuk, "Unmanned aerial vehicles and new technological methods of monitoring and crop protection in precision agriculture," in 2015 IEEE International Conference Actual Problems of Unmanned Aerial Vehicles Developments (APUAVD). IEEE, 2015, pp. 298–301.
- [6] J. Torres-Sánchez, J. M. Peña, A. I. de Castro, and F. López-Granados, "Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV," *Computers and Electronics in Agriculture*, vol. 103, pp. 104–113, 2014.
- [7] A. M. Samad, N. Kamarulzaman, M. A. Hamdani, T. A. Mastor, and K. A. Hashim, "The potential of unmanned aerial vehicle (uav) for civilian and mapping application," in 2013 IEEE 3rd International Conference on System Engineering and Technology. IEEE, 2013, pp. 313–318.
- [8] J. Luck, S. Pitla, S. Shearer, T. Mueller, C. Dillon, J. Fulton, and S. Higgins, "Potential for pesticide and nutrient savings via map-based automatic boom section control of spray nozzles," *Computers and Electronics in Agriculture*, vol. 70, no. 1, pp. 19–26, 2010.

[9] S. Pyo, "Actual state of pesticide management and rate of complaints of prevalence subjective symptom in some farmer," Master Diss. Yonsei Univ. Seoul, 2006.

[10] Z. Pan, D. Lie, L. Qiang, H. Shaolan, Y. Shilai, L. Yande, Y. Yongxu, and P. Haiyang, "Effects of citrus tree-shape and spraying height of small unmanned aerial vehicle on droplet distribution," International Journal of Agricultural and Biological Engineering, vol. 9, no. 4, pp. 45–52, 2016.

[11] <https://www.educba.com/types-of-artificial-intelligence/?source=leftnav>
consulté le 20/05/2023.

[12] <https://thaqafati.com> consulté Le 19/05/2023

[13] <https://insights-daffodilsw-com> consulté le 21/05/2023

[14] https://fr.m.wikiversity.org/wiki/Réseaux_de_neurones/Qu'est-ce_qu'un_neurone
consulté le 30/05/2023_

[15] LES RESEAUX DE NEURONES ARTIFICIELS, INTRODUCTION AU CONNEXIONNISME. Submitted on 27 Jun 2016

[16] <https://arabicprogrammer.com/article/453798181> consulté Le 22/05/2023

[17] Machine Learning and Deep Learning Methods for Cybersecurity Corresponding author: Zhi Liu (liuzhi@sdu.edu.cn) VOLUME 6 2018 IEEE ACCESS Open Access Journal,, Digital Object Identifier 10.1109/ACCESS.2018.2836950 PDF

[18] http://www.igli5.com/2018/06/blog-post_70.html?m=1

[19] Plant Disease Detection Using Image Processing Sachin D. Khirade A. B. Patil 2015

Bibliographie en Arabe

[20] الذكاء الاصطناعي والنظم الخبيرة في المكتبات زين عبد الهادي

[21] التعلم العميق، ميلاد وزان

[22] عبد الله علي المسلاتي أحمد عبد القادر جحا، استخدام الشبكات العصبية للتنبؤ في السلاسل الزمنية باستخدام طريقة التدريب ذات الانتشار الخلفي

[23] مدخل الى الذكاء الاصطناعي و تعلم الآلة ، محمد لحج