

République algérienne démocratique et populaire.
Ministère de L'enseignement Supérieure de la recherche scientifique.
Université 8 Mai 45 –Guelma-
Faculté des Mathématiques, d'informatique et des Sciences de la Matière
Département d'Informatique



Mémoire de Fin d'études Master

Filière : Informatique

Option : Science et technologie de l'information et de la communication.

Thème :

**Agriculture intelligente : Développement d'un système de détection automatique
des mauvaises herbes.**

Présenté par : *Moumene Hadil*

Membres du jury :

- **Président :** SERIDI Ali
- **Encadrant :** FAROU Brahim
- **Examineur :** BENCHERIET Chemesseennehar

Juin 2024

Dédicaces

À mes chers parents,
*dont l'amour et le soutien inconditionnels ont été ma source
d'inspiration.*

À mes frères,
pour leur fraternité et leur encouragement constants.

À toute ma famille,
pour leur affection et leur motivation précieuse.

À mes adorables chats,
*pour leur présence réconfortante et leur compagnie
apaisante.*

Hadil Moumene

Remerciements

Alhamdulillah, qui rend cela possible pour moi. Alhamdulillah, qui m'a donné la capacité de le faire. Ensuite, j'adresse mes plus hautes expressions de respect et d'appréciation à mon superviseur pour m'avoir guidé jusqu'ici, pour ses conseils et les informations qu'il a partagées avec nous. Merci à Dr Boughida Adel pour son aide et tout ce qu'il a fait pour moi.

Ma petite famille, aucun mot ne peut suffire pour vous dire merci pour tout le soutien, l'amour et la force que vous m'avez donnés pour poursuivre mon voyage jusqu'au bout. Père, Mère et Frères, merci. Ma deuxième famille qui a partagé mes moments de bonheur, de faiblesse et tous les moments de ce voyage, qui m'a soutenu, ri et pleuré avec moi, mes amis que j'ai rencontrés par hasard, et peut-être qu'une coïncidence vaut mieux que mille rendez-vous. Merci pour l'expérience incroyable que vous m'avez offerte.

Enfin, je tiens à remercier moi-même de ne pas avoir abandonné et d'être resté fort.

ملخص

تركز رسالة الماستر هذه على الكشف عن الحشائش باستخدام الذكاء الاصطناعي (AI) في مجال الزراعة. الهدف من هذه الدراسة هو تطوير نظام ذكي قادر على اكتشاف وتصنيف الحشائش الضارة تلقائياً في الحقول الزراعية اعتماداً على تحليل الصور. طرق الكشف اليدوية التقليدية تستغرق وقتاً طويلاً، ومكلفة، وعرضة للخطأ البشري. ومن خلال الاستفادة من التقدم في التعلم الآلي ومعالجة الصور وخوارزميات التعلم العميق، يمكن للنظام القائم على الذكاء الاصطناعي توفير معلومات دقيقة وفي الوقت الحقيقي عن وجود الأعشاب الضارة، مما يمكن المزارعين من تحسين إنتاجهم الزراعي. يجمع النظام المقترح بين تقنيات التعلم الآلي وتحليل الصور ومعالجة البيانات لمساعدة المزارعين على الحفاظ على صحة محاصيلهم وتقليل خسائر المحاصيل. تعرض هذه الأطروحة تصميم وتنفيذ وتقييم النظام، مما يدل على فعاليته في الكشف عن الحشائش. وتظهر النتائج أن نموذج YOLOv9 المستخدم للكشف يوفر دقة عالية ومتانة في ظل ظروف متنوعة، على الرغم من تحديد بعض القيود. تسلط هذه الدراسة الضوء على إمكانيات الذكاء الاصطناعي في إحداث تحول في إدارة الأعشاب الضارة، وتعزيز زراعة أكثر استدامة وكفاءة.

الكلمات المفتاحية: الذكاء الاصطناعي، كشف الأعشاب الضارة، YOLOv9، التعلم العميق، نقل التعلم، الزراعة المستدامة.

Resumé

Ce mémoire de master se concentre sur la détection des mauvaises herbes en utilisant l'intelligence artificielle (IA) dans le domaine de l'agriculture. L'objectif de cette étude est de développer un système intelligent capable de détecter et de classifier automatiquement les mauvaises herbes dans les champs agricoles à partir de l'analyse d'images. Les méthodes de détection manuelle traditionnelles sont longues, coûteuses et sujettes aux erreurs humaines. En exploitant les avancées de l'apprentissage automatique, du traitement d'image et des algorithmes d'apprentissage en profondeur, un système basé sur l'IA peut fournir des informations précises et en temps réel sur la présence de mauvaises herbes, permettant aux agriculteurs d'optimiser leur production agricole. Le système proposé combine des techniques d'apprentissage automatique avec l'analyse d'images et le traitement de données pour aider les agriculteurs à maintenir la santé de leurs cultures et à réduire les pertes de récoltes. Ce mémoire présente la conception, la mise en œuvre et l'évaluation du système, démontrant son efficacité dans la détection des mauvaises herbes. Les résultats montrent que le modèle YOLOv9 utilisé pour la détection offre une grande précision et robustesse dans des conditions variées, bien que certaines limitations aient été identifiées. Cette étude met en évidence le potentiel de l'IA pour transformer la gestion des mauvaises herbes, favorisant une agriculture plus durable et efficace.

Mots-clés : IA, Détection des Mauvaises Herbes, YOLOv9, Apprentissage en profondeur, Apprentissage par transfert, Agriculture Durable.

Abstract

This master's thesis focuses on weed detection using artificial intelligence (AI) in the field of agriculture. The aim of this study is to develop an intelligent system capable of automatically detecting and classifying weeds in agricultural fields through image analysis. Traditional manual detection methods are time-consuming, costly, and prone to human errors. By leveraging advances in machine learning, image processing, and deep learning algorithms, an AI-based system can provide accurate and real-time information on weed presence, enabling farmers to optimize their agricultural production. The proposed system combines machine learning techniques with image analysis and data processing to assist farmers in maintaining crop health and reducing crop losses. This thesis presents the design, implementation, and evaluation of the system, demonstrating its effectiveness in weed detection. The results show that the YOLOv9 model used for detection offers high precision and robustness in various conditions, although some limitations have been identified. This study highlights the potential of AI to transform weed management, promoting more sustainable and efficient agriculture.

Keywords : AI, Weed Detection, YOLOv9, Deep Learning, Transfer learning, Sustainable Agriculture.

Table des matières

Resume Arabe	ii
Resumé	iv
Abstract	v
Table des matières	vi
Liste des tableaux	x
Table des figures	xi
Introduction générale	1
1 Agriculture, économie et défi des mauvaises herbes	3
1.1 Introduction	3
1.2 L'agriculture dans l'économie mondiale	3
1.2.1 L'impact économique majeur de l'agriculture	3
1.2.2 L'agriculture et valeur ajoutée	4
1.3 L'agriculture et le marché algérien	5
1.3.1 Analyse du marché agricole en Algérie	5
1.3.2 La production agricole	7
1.4 Le problème des mauvaises herbes	8
1.4.1 Définitions	8
1.4.2 Caractéristiques	9
1.4.3 Classification	10
1.4.4 Propagation	11
1.4.5 Inconvénients des mauvaises herbes	11

1.4.6	Méthodes traditionnelles de lutte contre les mauvaises herbes	12
1.4.7	La détection précoce de mauvaises herbes	14
1.5	Conclusion	15
2	Intelligence Artificielle et Agriculture	16
2.1	Introduction	16
2.2	IA et les mauvaises herbes	16
2.3	Apprentissage automatique	17
2.3.1	Machines à Vecteurs de Support (SVM)	18
2.3.2	Méthodes de Régression Linéaire	19
2.3.3	Arbres de Décision	20
2.3.4	Forêts Aléatoires (Random Forests)	22
2.3.5	Méthodes de Classification Bayésienne	24
2.4	Apprentissage en profondeur	24
2.4.1	Réseaux de Neurones Convolutifs (CNN)	25
2.4.2	Réseaux de Neurones Générateurs Antagonistes (GAN)	27
2.4.3	Réseaux Neuronaux à Mémoire à Court Terme (LSTM)	28
2.4.4	Mask R-CNN et Faster R-CNN	29
2.4.5	You Only Look Once(YOLO)	30
2.5	Apprentissage automatique VS Apprentissage en profondeur	36
2.6	Travaux Connexes(Etude comparative)	37
2.7	Conclusion	44
3	Conception et mise en oeuvre du système	45
3.1	Introduction	45
3.2	Problématique	45
3.3	Architecture du système proposé	46
3.3.1	Acquisition d'images	48
3.3.2	Pré-traitement	48
3.3.3	Inférence avec YOLOv9	49
3.3.4	Facteurs influençant l'inférence	50

3.3.5	Suppression non-maxima (NMS)	50
3.3.6	Analyse et traitement des résultats de détection	52
3.4	L'architecture du modèle utilisé :YOLOv9	53
3.4.1	Backbone	54
3.4.2	Neck	55
3.4.3	Head	56
3.4.4	Auxiliairy	57
3.5	L'entraînement du modèle	59
3.5.1	Préparation des données	60
3.5.2	Définition du modèle	60
3.5.3	Fonction de perte et optimiseurs	60
3.5.4	Boucle d'époque	60
3.5.5	Boucle du lots	61
3.5.6	Évaluation de l'époque	61
3.5.7	Fin de l'entraînement	62
3.6	Conclusion	62
4	implémentation, Tests et Résultats	63
4.1	Introduction	63
4.2	Paramétrage	63
4.2.1	Arguments de ligne de commande	63
4.2.2	Hyperparamètres	65
4.3	Outils Matériels	65
4.4	Outils Logiciels	66
4.4.1	Environnement de développement	66
4.4.2	Langage de programmation	66
4.4.3	Description des bibliothèques utilisées	67
4.5	La base de données	68
4.6	Les métriques	73
4.6.1	Précision (Precision)	73
4.6.2	Rappel (Recall)	73
4.6.3	Mean Average Precision at IoU 0.5 (mAP@0.5)	73

4.6.4 Mean Average Precision at IoU [0.5 :0.95] (mAP@[50 :95])	73
4.7 Résultats Qualitatifs	74
4.8 Résultats Quantitatifs	75
4.9 Conclusion	78
Conclusion générale	79
Bibliographie	81
Annexe start-up	89
A Présentation du projet	89
A.1 Idée du projet	89
A.2 Les valeurs proposées	90
A.3 Équipe de travail	91
A.4 Objectifs du projet	92
A.5 Calendrier de mise en oeuvre du projet	92
B Aspects innovants	92
C Analyse stratégique du marché	92
C.1 Présentation du secteur de marché	92
C.2 Mesurer l'intensité de la concurrence	93
C.3 Stratégies marketing	94
C.4 Analyse des Clients	96
D Plan de production et d'organisation	97
D.1 Processus de production	97
D.2 Matières premières	98
D.3 Ressources humaines	98
E Étude financière	100
E.1 Capital estimé	100
E.2 Coûts d'exploitation mensuels	101
E.3 Projections financières sur trois ans	102
E.4 Analyse financière	103

Liste des tableaux

2.1	Tableau Comparatif entre les méthode de détection des mauvaises herbes	38
4.1	Les Hyperparamètres et leurs valeurs	65
4.2	Tableau des codes EPPO (European and Mediterranean Plant Protection Organization) et des noms botaniques	69
4.3	Exemple de chaque espèce végétale avec le code OEPP correspondant.	70
4.4	Nombre d'images du base de donnes par classes	71
4.5	Quelques résultats de la détection des mauvaises herbes. . .	74
4.6	Table du métrique du validation	76
4.7	Résultats de détection des mauvaises herbes par classe . . .	77
8	Capital estimé	100
9	Coûts d'exploitation mensuels	101
10	Projections financières sur trois ans	102
11	Analyse financière	103

Table des figures

1.1 Agriculture et valeur ajoutée (\$ US courants) d'après la Banque mondiale	5
1.2 Taille du marché agricole algérien (Estimation de Mordor Intelligence)	6
3.1 Schéma général du processus de détection des mauvaises herbes	47
3.2 Schéma général de l'architecture du modèle YOLOv9.	54
3.3 Schéma général d'entraînement du modèle.	59
4.1 Graphes de métriques d'entraînement et de validation.	75

Introduction générale

Contexte et problématique

L'agriculture est l'un des piliers fondamentaux de l'économie mondiale, jouant un rôle crucial dans la sécurité alimentaire et le développement économique. Cependant, la croissance démographique et les pressions environnementales ont intensifié les défis auxquels est confrontée l'agriculture moderne. Parmi ces défis, la gestion des mauvaises herbes reste un enjeu majeur. Les mauvaises herbes peuvent compromettre les rendements des cultures, augmenter les coûts de production et menacer la viabilité économique des exploitations agricoles.

La lutte contre les mauvaises herbes a traditionnellement reposé sur des méthodes manuelles ou chimiques, mais ces approches présentent des inconvénients majeurs, notamment en termes d'impact environnemental et de résistance croissante des mauvaises herbes aux herbicides. Face à cette problématique, l'intégration de technologies innovantes telles que l'intelligence artificielle offre de nouvelles perspectives pour une gestion plus efficace et durable des mauvaises herbes en agriculture.

Objectifs de l'étude

Dans ce contexte, cette étude vise à explorer le potentiel de l'intelligence artificielle dans la détection des mauvaises herbes en agriculture. Les objectifs spécifiques comprennent :

- Évaluer l'efficacité des modèles d'intelligence artificielle, en particulier le modèle YOLOv9, dans la détection précise des mauvaises herbes.
- Analyser les performances des systèmes de détection des mauvaises herbes basés sur l'IA dans des conditions réelles.
- Examiner les implications de l'utilisation de l'intelligence artificielle pour la gestion des mauvaises herbes en agriculture, en termes d'efficacité opérationnelle, de durabilité environnementale et de rentabilité économique.

Organisation du mémoire

Pour répondre à ces objectifs, ce mémoire est structuré de la manière suivante :

Chapitre 1 : Agriculture, économie et défi des mauvaises herbes : Ce chapitre propose une revue de la littérature sur le rôle crucial de l'agriculture dans l'économie mondiale, les défis posés par les mauvaises herbes et les méthodes traditionnelles de lutte contre celles-ci.

Chapitre 2 : Utilisation de l'IA dans l'Agriculture : Ce chapitre examine l'utilisation de l'IA dans le domaine agricole, en mettant particulièrement l'accent sur son application à la détection des mauvaises herbes.

Chapitre 3 : Conception et Mise en Œuvre du Système : Ce chapitre détaille la conception et la mise en œuvre d'un système de détection des mauvaises herbes basé sur l'IA, en fournissant des informations sur les méthodologies et les outils utilisés.

Chapitre 4 : Implémentations , Tests et Résultats : Ce dernier chapitre présente les résultats obtenus, discute de leur importance et de leurs implications.

Agriculture, économie et défi des mauvaises herbes

1.1 Introduction

L'agriculture est très importante depuis longtemps. Il ne s'agit pas seulement de cultiver des aliments pour les manger, l'agriculture a contribué à créer les civilisations telles que nous les connaissons, avoir suffisamment de nourriture pousse les gens à vivre ensemble dans de grands groupes sans se battre pour la nourriture. Lorsque les gens n'ont pas à se soucier de trouver quoi manger constamment, ils peuvent passer leur temps à apprendre des choses différentes et à travailler ensemble sur des projets plus grands.

L'agriculture donne du travail et de l'argent à de nombreuses personnes. C'est également une grande partie de l'économie mondiale, les mauvaises herbes sont toujours un très gros problème pour les agriculteurs.

1.2 L'agriculture dans l'économie mondiale

1.2.1 L'impact économique majeur de l'agriculture

La croissance de la productivité agricole sera le moteur de renforcer les systèmes agricoles du monde dans les dix prochaines années. Il augmente les bénéfices des producteurs, peut réduire les coûts des consommateurs et réduit l'impact environnemental de la production alimentaire et agricole. La productivité agricole, mesurée par le total factor productivité (TFP),

augmente lorsque les producteurs augmentent leur production de produits agricoles, de viandes ou d'aquaculture, en utilisant la même quantité ou moins de terre, de travail, de capital, de fertilisant, de nourriture et de viandes. En d'autres termes, TFP augmente lorsque les producteurs utilisent de nouvelles technologies agricoles pour augmenter leur production avec la même quantité ou moins de ressources. [PG09]

D'après la Banque mondiale, l'agriculture joue un rôle crucial dans la croissance économique. Sa part peut dépasser 25% du produit intérieur brut (PIB) dans certains pays en développement parmi les moins avancés, tandis qu'en 2018, elle représentait 4% du PIB mondial.

Il y a environ 4,74 milliards d'hectares de terres agricoles sur la planète, comprenant des prairies et des pâturages ainsi que des cultures. Ce chiffre a diminué de 3% par rapport à 2000, mais la superficie par habitant est six fois plus petite, avec l'Afrique en tête.

Les exportations alimentaires mondiales ont augmenté de 3.700 milliards de dollars depuis l'année 2000, atteignant ainsi un montant total de 1.420 milliards de dollars dans le même laps de temps. Les États-Unis, les Pays-Bas et la Chine sont les plus grands exportateurs de produits alimentaires en termes bruts au niveau mondial. [Nat22]

1.2.2 L'agriculture et valeur ajoutée

La Banque mondiale rapporte une augmentation constante de la valeur ajoutée de l'agriculture en dollars américains au fil des ans. De 1981 à 2022, cette valeur est passée d'environ 884.82 milliards à près de 3,34 billions de dollars US. Cette progression témoigne de la croissance continue du secteur agricole à l'échelle mondiale, stimulée par une demande croissante de production alimentaire pour répondre aux besoins d'une population mondiale en expansion.

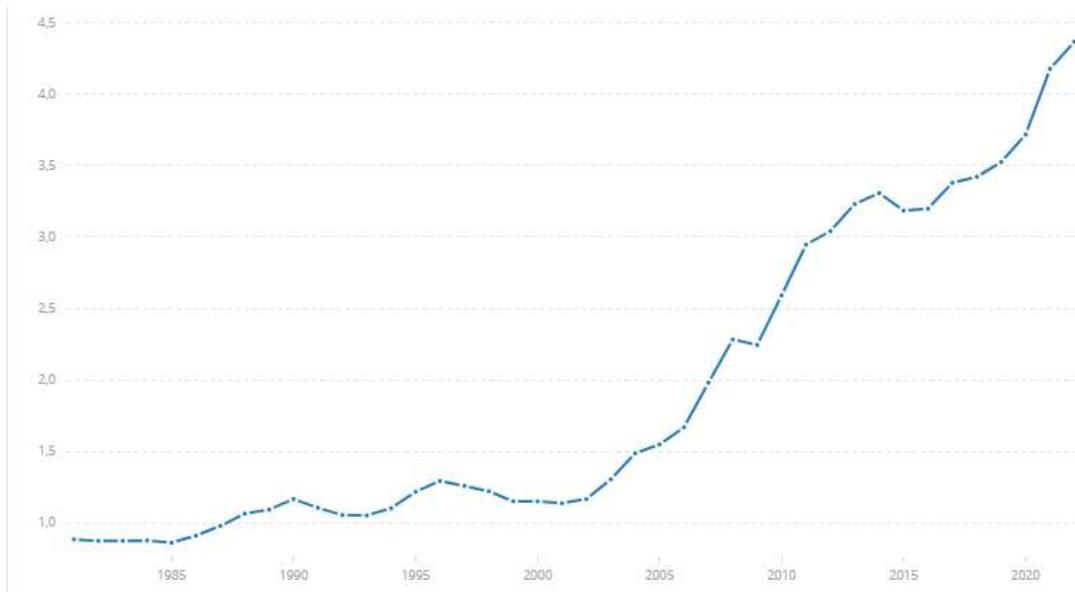


FIGURE 1.1 – Agriculture et valeur ajoutée (\$ US courants) d’après la Banque mondiale .
[Ban24]

L’importance de l’agriculture dans l’économie mondiale est indéniable, Cette augmentation significative de la valeur ajoutée agricole témoigne de la contribution majeure du secteur à l’économie mondiale. En effet, l’agriculture ne se limite pas seulement à la production alimentaire, mais joue également un rôle crucial dans la création d’emplois, la réduction de la pauvreté et le développement économique des pays. Ainsi, l’agriculture continue de jouer un rôle central dans la promotion d’une croissance économique inclusive et durable à l’échelle mondiale.

1.3 L’agriculture et le marché algérien

1.3.1 Analyse du marché agricole en Algérie

Le marché agricole algérien devrait atteindre 4,86 milliards USD en 2024 et 6,09 milliards USD d’ici 2029 avec un TCAC de 4,65 % sur la période prévisionnelle (2024-2029) Actuellement, l’Algérie est le plus grand pays d’Afrique et du monde arabe, ayant une superficie totale de 2,38 millions de kilomètres carrés.



FIGURE 1.2 – Taille du marché agricole algérien (Estimation de Mordor Intelligence) .
[Int24]

L'Algérie possède des ressources naturelles abondantes mais encore très peu connues. Malgré cela, l'Algérie a pour objectif de réduire sa dépendance envers les importations. Malgré de nombreux hauts et bas, le secteur agricole algérien a connu une croissance régulière. L'Algérie a la capacité technique de produire 30 millions de tonnes de céréales par an et d'en exporter 21 millions vers les pays voisins.

En 2021, le ministère de l'agriculture a annoncé son intention d'étendre la superficie en blé de l'Algérie à 3,5 millions d'hectares, tandis que 1,8 million d'hectares de terres agricoles étaient cultivés en blé. De plus, l'orge et les olives cultivaient respectivement 978 mille et 439 mille hectares la même année.

D'autres grandes surfaces étaient réservées à d'autres grandes cultures du pays, comme le blé, l'orge, les pommes de terre, l'avoine, les dattes et le raisin. Les palmiers ont une superficie de 72 000 acres. L'huile d'olive et le tabac sont également produits dans le pays.

Les femmes constituent 24,5 % de la population agricole. Près de 70 % des fermes du pays sont de petite taille, de 0,1 à près de 10 hectares. Le gouvernement algérien continue de développer et moderniser l'agriculture afin de diversifier l'économie et d'attirer les investissements étrangers et nationaux. Les principaux moteurs du marché sont les politiques et les programmes gouvernementaux visant à accroître la production nationale,

la privatisation du secteur semencier et les investissements dans les infrastructures agricoles. L'évolution vers une agriculture à grande échelle et un partenariat gagnant-gagnant avec des investisseurs étrangers chevronnés comme les Pays-Bas pourraient également contribuer à atteindre ces objectifs et augmenter la quantité de biens produits locaux à grande échelle, en faisant de l'Algérie un pays important.

La Zone de libre-échange continentale africaine (ZLECAf) est une porte d'entrée efficace pour vendre des biens et des produits sur un marché de 1,2 milliard d'habitants [Int24].

1.3.2 La production agricole

L'opinion publique, ainsi que les responsables du secteur agricole, sont d'accord sur le fait que l'Algérie possède de bonnes ressources naturelles. L'histoire de l'Afrique romaine, son rôle spécifique dans les approvisionnements en blé et en huile de la capitale de l'Empire, ainsi que l'histoire coloniale, sont souvent appelés à confirmer cette opinion, largement répandue, sur les supposées richesses naturelles de l'Algérie. [Bes04]

La production agricole en Algérie est influencée par deux éléments : l'un est lié aux conditions climatiques (climat, altitude, sécheresse, etc...), l'autre est lié au système de culture traditionnel qui repose sur une multitude de petites exploitations familiales. En règle générale, les céréales (33 %), l'arboriculture (6 %), les fourrages (6 %) et les cultures maraîchères (3 %). En moyenne, la production brute d'origine végétale représentait 70 à 75 % de la production brute agricole dans les années 1960. [AB19]

La culture des céréales, y compris la période de jachère, représente environ 80 % de la surface agricole utile (SAU) du pays. Le territoire cultivé en céréales est d'environ 3 à 3,5 million d'hectares par an. Les surfaces récoltées chaque année représentent 63% des surfaces emblavées. Ainsi, elle semble être une spéculation prédominante, La plupart des exploitations (60% de l'effectif total) ,L'investissement est présent dans tous les niveaux bioclimatiques, y compris dans les régions sahariennes, En ce qui concerne

l'emploi, le système céréalier offre plus de 500 000 emplois permanents et saisonniers.[Dje17]

En 2022, la production agricole en Algérie a connu une nette amélioration, représentant 11,6 % du PIB courant, avec une croissance de 5,8 % par rapport à l'année précédente qui avait enregistré une baisse de 1,9 %. Cette progression a été largement soutenue par des conditions météorologiques favorables, notamment pour la production céréalière qui a augmenté de manière significative de 51,4 %. Toutes les filières céréalières ont été concernées par cette hausse, avec des augmentations remarquables pour le blé dur et tendre, l'orge et l'avoine.

Après une baisse importante en 2021, la production oléicole a rebondi avec une hausse de 30,3 % en 2022, atteignant 9,2 millions de quintaux. Des tendances similaires ont été observées dans la viticulture et les agrumes, avec des rebonds respectifs de 7,5 % et de 9,3 %.

En revanche, la production maraîchère a connu une baisse significative de 7,3 % en volume, principalement en raison de la diminution de la production de pommes de terre et d'oignons, malgré une augmentation de la production d'ail. La production animale a également reculé, avec des baisses notables pour les viandes rouges, le lait, les œufs, la laine, le miel et les viandes blanches.

En résumé, la production agricole algérienne a affiché une reprise en 2022, portée par une forte croissance dans certaines filières, mais a connu des défis dans d'autres secteurs, notamment maraîchers et animaliers.[Alg23]

1.4 Le problème des mauvaises herbes

1.4.1 Définitions

Les mauvaises herbes ont de nombreuses définitions. Voici quelques définitions classiques :

- une plante déplacée et non intentionnellement semé.
- La plante pousse là où elle n'est pas recherchée ou accueillie.

- Une plante dont les propriétés ne sont pas encore établies.
- Une plante agressive, tenace, parasitaire et nuisible à l'activité humaine.

Les mauvaises herbes sont des plantes dont les qualités l'emportent sur leurs bons points, peu importe la définition utilisée. Les activités humaines causent des mauvaises herbes car aucune herbe n'est mauvaise dans la nature. Néanmoins, il est possible de manipuler la nature pour notre propre bien, mais elle persiste. Par la pratique, sur la maîtrise de certaines mauvaises herbes, alors que d'autres mauvaises herbes plus sévères peuvent se développer grâce à des conditions de croissance propices.

Les mauvaises herbes sont bien sûr de fortes rivales, et celles qui peuvent le mieux rivaliser ont toujours tendance à prendre le dessus. Les programmes de sélection végétale s'adressent aux humains et à la nature. Les plantes sont sélectionnées par les humains pour le rendement, tandis que la nature engendre des plantes pour survivre. C'est la principale différence entre les deux programmes.[Pen07]

1.4.2 Caractéristiques

Environ 250 000 espèces de plantes sont présentes dans le monde, mais environ 3 pour cent, soit 8 000 espèces, se comportent comme des mauvaises herbes. Seulement 200 à 250 de ces 8 000 posent des problèmes majeurs dans le monde des systèmes culturels. Une mauvaise herbe est une plante qui a certaines caractéristiques qui la distinguent des autres espèces végétales. Les mauvaises herbes ont un ou plusieurs des caractères qui leur permettent de survivre et de se développer dans la nature :

- Une production abondante de semences.
- Etablissement rapide de la population.
- La dormance des graines.
- Survie à long terme des graines enfouies.
- Adaptation à la propagation.

- Présence de reproduction végétative constructions.
- Capacité à occuper des sites perturbés par humains. [Pen07]

1.4.3 Classification

Les mauvaises herbes peuvent être classées selon plusieurs critères tels que le cycle de vie, l'habitat, la dépendance vis-à-vis d'autres hôtes, le type de sol et les familles de plantes.

On distingue les mauvaises herbes selon le cycle de vie annuel, saisonnier, bisannuel ou vivace. Les mauvaises herbes annuelles ont un cycle de vie d'une année, les mauvaises herbes saisonnières et les annuelles de mousson l'ont au cours de saisons particulières. Pendant la saison hivernale, les mauvaises herbes de la saison Rabi terminent leur cycle de vie en tant que mauvaises herbes annuelles. Les bisannuelles, qui ont besoin de deux ans pour finir leur cycle de vie, et les plantes vivaces, qui ont besoin de plusieurs années, sont les mauvaises herbes bi-saisonnières.

Les mauvaises herbes peuvent aussi être catégorisées selon l'habitat ou le lieu d'occurrence : terres cultivées, pâturages et pâturages, canaux d'eau, bord de route, friches, pelouses et vergers, terres forestières.

Une autre typologie repose sur la dépendance de la mauvaise herbe envers d'autres hôtes. Les tiges utilisent leurs plantes hôtes pour extraire de l'eau et des nutriments, tandis que les racines, telles que le Striga, s'attachent aux racines de la canne à sucre. Les parasites indépendants ne nécessitent pas d'hôtes.

Les mauvaises herbes peuvent être classées en fonction du type de sol dans lequel elles poussent, telles que les sols noirs, les sols limoneux sableux, les sols mal drainés et les mauvaises herbes en réservoir qui peuvent être submergées, immergées ou flottantes, comme la jacinthe d'eau et le calcium.

Enfin, les mauvaises herbes sont classées par familles de plantes, Graminae, Commelinaceae, Cyperaceae, Amaranthaceae, Euphorbiaceae, Composite, Leguminous, Malvaceae, Tiliaceae, Cruciferae, Chenopodia-

ceae, Solanaceae, Papaveraceae, Portulacaceae, Orobanchaceae et Cactaceae. Ce sont des plantes vasculaires qui réalisent la majeure partie de leur végétation sous la surface de l'eau et qui ont de véritables racines, tiges et feuilles.[Bat23]

1.4.4 Propagation

Les agents qui provoquent la dispersion, la dissémination et la propagation des mauvaises herbes sont nombreux. Ils comprennent :

- Les graines de mauvaises herbes qui ont un arrangement en parachute, plumes ou duvet peuvent être portées sur de longues distances par le vent.
- Les canaux d'irrigation, de drainage, de ruissellement de surface et d'eau de crue des rivières et des ruisseaux peuvent transporter les graines de mauvaises herbes.
- Les herbes malveillantes dotées de crochets, d'arêtes tordues et d'épines peuvent s'attacher aux animaux sauvages et domestiques, qui dispersent ensuite les graines. C'est courant chez les mauvaises herbes de la famille des Graminae.
- Les humains peuvent disperser indirectement les mauvaises herbes en utilisant un compost contenant des plantes adventices partiellement décomposées, en nourrissant le bétail avec du foin ou du fourrage contenant des plantes adventices, et en utilisant des machines agricoles non nettoyées telles que Ghaneri.
- Pendant la récolte, les grains de mauvaises herbes peuvent également être mélangés par inadvertance à des cultures, comme le blé.[Bat23]

1.4.5 Inconvénients des mauvaises herbes

Les mauvaises herbes sont gênantes de plusieurs façons. Ils réduisent principalement le rendement des cultures. en compétition pour :

- eau

- lumière
- nutriments du sol
- espace
- CO₂

Voici d'autres problèmes associés avec les mauvaises herbes :

- Contaminer la commodité réduit la qualité des récoltes.
- Causer des perturbations à la récolte.
- Fournir un abri aux insectes pour hiverner ou servir de maladies des cultures.
- Restreindre le choix des séquences de rotation et des pratiques culturales.
- Produire des produits chimiques qui peuvent être des allergènes ou toxines pour les humains, les animaux ou les plantes cultivées (allélopathie).
- En produisant des épines et des tiges ligneuses, il peut causer des irritations et des abrasions sur la peau, dans la bouche ou sur les sabots du bétail.
- être laid, autoritaire, hostile ou peu séduisant
- Obstruant la visibilité le long des routes, interférant avec la livraison des services publics (lignes électriques, fils téléphoniques), bloquant l'écoulement de l'eau dans les canaux et créant des risques d'incendie.
- Les activités récréatives dans les zones, parkings, bâtiments et l'équipement se détériorent rapidement.
- Des plantes exotiques envahissantes qui peuvent déplacer les espèces indigènes dans des environnements naturels stabilisés. [Pen07]

1.4.6 Méthodes traditionnelles de lutte contre les mauvaises herbes

Les méthodes de lutte contre les mauvaises herbes peuvent être globalement classées en deux groupes :

Les mesures de prévention ainsi que les mesures de guérison ou de contrôle. L'objectif des mesures préventives est d'interdire la propagation et l'invasion des mauvaises herbes en éliminant les bourgeons et en utilisant des semences propres, du fumier de ferme bien décomposé et du compost.

En outre, il est nécessaire de tailler les mauvaises herbes avant le semis, d'éliminer leur croissance et de veiller à ce que les canaux d'irrigation et de drainage restent libres de graines.

Il est essentiel de ne pas donner aux animaux des céréales broyées, du foin ou du fourrage contenant des graines de mauvaises herbes non détruites par le broyage ou la cuisson, ni d'utiliser du sable ou de la terre provenant de zones infestées pour nettoyer ou cultiver les champs.

Après avoir utilisé des outils et des machines agricoles dans des zones infestées, il est important de les nettoyer avant de les utiliser dans des zones propres. Il est également essentiel de maintenir les clôtures agricoles, les routes et les diguettes exempts de mauvaises herbes. De plus, surveiller attentivement.

Quant à elles, les mesures curatives visent à supprimer ou étouffer la croissance et la multiplication des mauvaises herbes. Cela inclut des techniques mécaniques telles que le désherbage manuel, l'arrachage manuel, le brûlage, l'inondation, le binage, le labour et les matériaux non vivants pour étouffer (paillage).

On donne le nom de "frottement" au processus de brûlage des lits de semences. Des méthodes de culture et de compétition (culturelles) sont aussi employées, impliquant des pratiques visant à favoriser l'établissement précoce et la croissance rapide des cultures par rapport aux mauvaises herbes.

En raison des changements de cultures d'une saison à l'autre, la rotation des cultures contrôle la croissance incontrôlée des mauvaises herbes, et l'utilisation de certaines cultures comme les légumineuses pour couvrir les arachides étouffe également la croissance des mauvaises herbes.

Aidera également les cultures à pousser plus rapidement en appliquant

des doses d'engrais optimales, et planter ou semer les cultures au bon moment avec un taux de semis optimal permettra à la culture de couvrir le sol et d'empêcher les mauvaises herbes de recevoir de la lumière.

L'utilisation d'organismes vivants tels que les plantes, les animaux ou les micro-organismes pour éliminer ou gérer les mauvaises herbes est impliquée dans les méthodes biologiques.

On peut utiliser des agents biologiques tels que la figue de Barbarie ou la mauvaise herbe Nagphana dans le sud de l'Inde, qui sont mangés seulement par les insectes cochenilles (*Dactlopius tomentosus*), afin qu'ils se nourrissent uniquement des mauvaises herbes et pas des plantes cultivées.

En Australie (îles Hawaï), on a utilisé plusieurs espèces de papillons nocturnes pour combattre le Lantana Camara, qui se nourrit des fleurs et des fruits. Pour être efficace et économique, il faut trouver et introduire le type approprié de prédateurs, parasites ou agents pathogènes qui n'attaqueront pas les cultures cultivées.

Si les produits chimiques utilisés pour combattre les mauvaises herbes sont bon marché, efficaces et facilement disponibles, alors les méthodes chimiques peuvent être efficaces dans certains cas et avoir une grande portée. Les produits chimiques qui sont utilisés pour combattre les mauvaises herbes sont connus sous le nom d'herbicides et peuvent soit aider à éliminer les mauvaises herbes, soit inhiber leur croissance, tels que le 2,4-D, l'atrazine et le glyphosate. [Bat23]

1.4.7 La détection précoce de mauvaises herbes

La détection précoce des mauvaises herbes est importante pour la santé des cultures et la qualité de l'alimentation, En repérant rapidement les mauvaises herbes, les agriculteurs peuvent les arrêter, Cela empêche les mauvaises herbes de prendre de la nourriture, de l'eau et du soleil aux plantes que nous voulons faire pousser.

L'élimination des mauvaises herbes contribue à une meilleure croissance des aliments, En outre, le fait d'arrêter les mauvaises herbes avant que leurs

graines ne se répandent permet d'éviter qu'elles ne poussent davantage par la suite, La détection précoce des mauvaises herbes coûte également moins d'argent.

Il est plus facile de se débarrasser des petites mauvaises herbes que des grosses, Passer du temps à trouver les mauvaises herbes tôt permet donc d'économiser du temps et de l'argent plus tard, Les agriculteurs devraient s'efforcer de trouver rapidement les mauvaises herbes.

1.5 Conclusion

Les mauvaises herbes constituent un problème majeur pour les agriculteurs, Elles diminuent le rendement des cultures et rendent difficile la production d'une quantité suffisante de nourriture, Ce chapitre explique ce que sont les mauvaises herbes, leurs caractéristiques et la manière dont elles sont regroupées.

Il aborde également les anciennes méthodes pour se débarrasser des mauvaises herbes, Le repérage précoce des mauvaises herbes permet de réduire leurs effets néfastes, Repérer rapidement les mauvaises herbes permet aux agriculteurs de cultiver davantage, Cela signifie également qu'ils n'ont pas besoin d'utiliser autant de désherbants chimiques, ce qui est meilleur pour l'environnement, En fin de compte, il est important de gérer les mauvaises herbes de plusieurs façons.

L'utilisation de nouvelles méthodes agricoles respectueuses de la planète y contribue également, En créant de nouvelles méthodes de détection et d'élimination des mauvaises herbes, les agriculteurs et d'autres personnes seront en mesure de mieux gérer les mauvaises herbes sans nuire à la nature.

Intelligence Artificielle et Agriculture

2.1 Introduction

L'importance de l'agriculture dans nos sociétés modernes ne fait aucun doute, car elle assure la sécurité alimentaire des peuples et des pays dans le temps. Cependant, elle n'est pas dénuée de problèmes et de défis, dont les plus importants sont les mauvaises herbes nuisibles qui causent de graves dommages à l'environnement. Les cultures agricoles et menacent ainsi la sécurité alimentaire. Dans ce chapitre, nous parlerons de l'utilisation de l'intelligence artificielle pour relever ces défis, car l'intelligence artificielle à notre époque nous apporte des solutions à la plupart de nos problèmes actuels et facilite nos tâches, nous devons l'exploiter dans tous les domaines.

Et comme c'est le cas dans le domaine de l'agriculture, où les chercheurs ont développé de nombreux moyens qui permettront de résoudre les problèmes rencontrés par les agriculteurs et de leur fournir de meilleurs résultats aux coûts les plus bas et dans des délais records. Ces méthodes dispensent les méthodes traditionnelles et permet d'offrir des rendements et une production plus élevés.

2.2 IA et les mauvaises herbes

Le problème des mauvaises herbes a toujours été une crise pour les agriculteurs causant de graves dommages en termes de coûts, de temps et d'efforts, ce qui a rendu nécessaire la recherche de solutions nouvelles et

innovantes à ces problèmes.

L'intelligence artificielle est en train de créer une révolution majeure dans la gestion des mauvaises herbes, car elle connaît des méthodes modernes pour identifier différents types de mauvaises herbes à l'aide d'algorithmes avancés et d'énormes données, ce qui aide les agriculteurs à les combattre de manière plus efficace et plus précise.

Dans ce chapitre, nous approfondirons ce sujet et les différentes applications pour l'intelligence artificielle dans la gestion des mauvaises herbes, nous explorons comment utiliser des technologies telles que la vision par ordinateur, l'apprentissage automatique et l'apprentissage profond pour identifier et cibler spécifiquement les mauvaises herbes, réduisant ainsi le recours aux herbicides et réduisant l'impact sur l'environnement.

2.3 Apprentissage automatique

L'apprentissage automatique est la première étape principale englobant les machines qui apprennent la signification d'un ensemble particulier de données afin qu'elles développent finalement ce que l'on appelle des résultats spécifiques et prédéterminés. Les algorithmes, l'ensemble de règles censées fournir un résultat, contiennent dans la machine ce qu'elle recherche ainsi que la manière dont elle doit interpréter les données[Gui20].

Pour illustrer ce qu'est l'apprentissage automatique, nous pouvons considérer un cas où la machine apprend à identifier les types courants de logiciels malveillants, même si les logiciels malveillants prennent une forme différente et de temps en temps. Les techniques d'obscurcissement du code utilisées dans de nombreux types de logiciels malveillants se distinguent par leur assez similaire. En conséquence, les ordinateurs apprennent à différencier les applications malveillantes des ensembles de données volumineux. Grâce au processus de création d'un malware, la cognition de la machine gagne en maturité[Gui20].

L'apprentissage automatique garantit que la machine peut auto-calibrer les variables dépendantes afin de pouvoir atteindre le résultat attendu. La

machine est intelligente et elle apprend mais sa seule finalité est spécifique et elle le fait dans le but d'un objectif particulier. Par exemple, un appareil peut être entraîné à reconnaître une orange ou une pomme. Pour atteindre cet objectif, la machine pourrait être programmée avec des informations sur des facteurs tels que le poids, la forme, la texture et la couleur de la peau jusqu'à ce qu'elle puisse les distinguer de manière fiable[Gui20].

2.3.1 Machines à Vecteurs de Support (SVM)

Les SVM, ou machines à vecteurs de support, sont des modèles d'apprentissage machine supervisés qui se concentrent sur la résolution de problèmes mathématiques en matière de discrimination et de régression. Elles ont été conceptualisées dans les années 1990 à partir d'une théorie d'apprentissage statistique développée par les informaticiens russes Vladimir Vapnik et Alexey Chervonenkis : La théorie de Vapnik-Chervonenkis est sur la liste des sujets. En raison de sa capacité à travailler avec des données de grandes dimensions, ses garanties théoriques et les bons résultats obtenus en pratique, ce modèle a été rapidement adopté. Les SVM sont appréciées pour leur simplicité d'utilisation car elles nécessitent seulement un petit nombre de paramètres. [dN22b]

Les SVM fonctionnent en ramenant un problème de classification ou de discrimination à un hyperplan (espace des caractéristiques) où les données sont séparées en plusieurs classes avec une frontière aussi éloignée que possible des points de données (ou "marge maximale"). D'où l'autre nom attribué aux SVM : Les séparateurs à marge large. Le concept de frontière suppose que les données soient séparables linéairement. Les support vector machines utilisent des noyaux, qui sont des fonctions mathématiques permettant de projeter et séparer les données dans l'espace vectoriel, pour atteindre cet objectif, avec les "vecteurs de support" étant les données les plus proches de la frontière. La frontière la plus éloignée de tous les points d'entraînement est optimale et offre donc la meilleure capacité de généralisation.

Les SVM peuvent servir à résoudre des problèmes de classification, en décidant quelle classe appartient un échantillon, ou de régression, pour prédire la valeur numérique d'une variable. La résolution de ces deux problèmes passe par la construction d'une fonction H qui à un vecteur d'entrée X fait correspondre une sortie Y : La résolution de ces deux problèmes passe par la construction d'une fonction H qui à un vecteur d'entrée X fait correspondre une sortie Y :

$$Y = H(X) \quad (2.1)$$

Pour le moment, nous nous limitons à aborder un problème de discrimination en deux classes (discrimination binaire), où $Y \in \{-1, 1\}$, et le vecteur d'entrée X est dans un espace X doté d'un produit scalaire. Par exemple, on peut prendre X égal à \mathbb{R}^N . [dN22b]

2.3.2 Méthodes de Régression Linéaire

On distingue deux types de régressions linéaires : On distingue deux types de régressions linéaires :

La relation entre deux variables X et Y , où Y est déduit de X , produit une droite et est appelée régression linéaire simple.

Une courbe est généralement produite par une fonction basée sur plusieurs variables X . La régression linéaire multiple est son nom.

1. Régression linéaire simple

La régression linéaire simple repose sur la formule suivante : La régression linéaire simple repose sur la formule suivante :

Y est égal à β_0 plus β_1 fois X plus ϵ .

La variable recherchée est Y . On l'appelle la « variable dépendante ».

Y a pour valeur β_0 lorsque X est égal à zéro.

Le β_1 représente le « coefficient de régression » et correspond à la pente de la ligne, c'est-à-dire à quel point Y change lorsque X augmente d'une unité.

La variable de base est X .

ϵ représente l'incertitude inévitable.

En résumé, notre objectif est d'estimer β_0 et β_1 afin de minimiser ϵ et d'obtenir la courbe la plus fiable possible à l'intersection de X et Y .

La formule est simple car elle repose sur la relation de deux variables. L'exemple donné par Francis Galton sur l'évaluation de la taille d'un enfant devenu adulte en fonction de la taille cumulée de ses parents serait bien adapté pour illustrer une régression linéaire. [Dat24]

2. Régression linéaire multiple

La formule de la régression linéaire multiple est une extension de sa forme simple : La formule de la régression linéaire multiple est une extension de sa forme simple :

$$Y = \beta_0 + \beta_1 \times X_1 + \beta_2 \times X_2 + \dots + \beta_n \times X_n + \epsilon \quad (2.2)$$

Une fois de plus, Y est la variable dépendante - celle que l'on essaie de prédire - et ϵ représente la marge d'erreur. Les couples $\beta_n \times X_n$ évoluent de la même manière que dans la régression simple, mais en version multiple. Trouver les coefficients β_n correspondant aux variables X_n qui, ensemble, minimiseront ϵ au mieux et produiront ainsi la meilleure prédiction possible est l'objectif cette fois-ci.

Par exemple, les données X comme la taille d'une maison, le nombre de pièces habitables, l'âge du bâtiment et la proximité des transports publics pourraient aider à prédire Y , qui est le prix de vente du bien. [Dat24]

2.3.3 Arbres de Décision

Un algorithme d'apprentissage supervisé non paramétrique utilisé pour les tâches de classification et régression est appelé arbre de décision. Il possède une hiérarchie structurée, une structure en arbre, qui est composée d'un noeud racine, de branches, de noeuds internes et de noeuds feuille.

Comme illustré dans le diagramme ci-dessus, un arbre de décision débute avec un nœud racine qui ne comporte pas de branches entrantes. Les branches qui sortent du nœud racine vont vers les nœuds internes, également appelés nœuds de décision. En fonction des caractéristiques disponibles, les deux types de nœuds effectuent des évaluations sur des sous-ensembles homogènes, ce qui les désigne comme nœuds feuille ou terminaux. Tous les résultats possibles au sein du fichier sont représentés par les nœuds feuille. [IBMb]

La stratégie utilisée par l'apprentissage par arbre de décision consiste à diviser et conquérir en réalisant une recherche gloutonne pour trouver les meilleurs points de fractionnement au sein d'un arbre. Ensuite, le processus de fractionnement est répété de manière descendante et récursive jusqu'à ce que la majorité des enregistrements soit classifiée sous des étiquettes de classe spécifiques. La classification de tous les points de données comme des ensembles homogènes dépend principalement de la complexité de l'arbre de décision. Les petits arbres peuvent atteindre plus facilement des nœuds feuille purs, qui sont des points de données dans une seule classe. Toutefois, lorsque l'arborescence devient plus grande, il est de plus en plus difficile de maintenir cette pureté et généralement peu de données sont pertinentes pour une sous-arborescence donnée.

Quand cela arrive, la fragmentation des données est mentionnée et peut souvent conduire à un surajustement. Ainsi, les arbres de décision préfèrent les petits arbres, ce qui est en accord avec le principe de parcimonie d'Occam's Razor ; cela signifie que « on ne doit pas multiplier les entités sans nécessité ». En d'autres termes, les arbres de décision ne doivent ajouter de la complexité que si c'est nécessaire car en général, l'explication la plus simple est la meilleure. L'élagage est fréquemment utilisé pour diminuer la complexité et prévenir le surajustement ; il consiste à supprimer les branches qui se divisent en éléments de faible importance. On peut évaluer l'ajustement du modèle en utilisant la validation croisée. Les arbres de décision peuvent maintenir leur exactitude en formant un ensemble à l'aide

d'un algorithme de forêt aléatoire, prédisant ainsi des résultats plus précis, surtout lorsque les arbres individuels ne sont pas corrélés. [IBMb]

L'algorithme de Hunt, qui a été développé dans les années 1960 pour devenir le modèle d'apprentissage humain en psychologie, forme la base de nombreux algorithmes d'arbre de décisions populaires, tels que les suivants : L'algorithme de Hunt, qui a été développé dans les années 1960 pour devenir le modèle d'apprentissage humain en psychologie, forme la base de nombreux algorithmes d'arbre de décisions populaires, tels que les suivants :

ID3 : Le développement d'ID3 est crédité à Ross Quinlan, dont l'abréviation signifie « Iterative Dichotomiser 3 ». Ce sont l'entropie et le gain d'informations que cet algorithme utilise pour évaluer les fractionnements candidats. Certains des recherches de Quinlan sur cet algorithme à partir de 1986 peuvent être consultées ici (PDF, 1,3 Mo) (le lien est externe au site d'IBM). com).

C4.5 : Quinlan a également développé cet algorithme considéré comme une itération ultérieure d'ID3. Il peut évaluer des points de fractionnement au sein des arbres de décisions en utilisant des informations sur les gains ou les ratios de gain.

CART : CART, une abréviation introduite par Leo Breiman, signifie "arbres de classification et de régression". L'impureté Gini est typiquement utilisée par cet algorithme pour identifier l'attribut idéal afin d'effectuer le fractionnement. La mesure de l'impureté Gini indique à quelle fréquence un attribut sélectionné au hasard est mal classé. Une valeur plus basse est idéale lors de l'évaluation avec l'impureté Gini. [IBMb]

2.3.4 Forêts Aléatoires (Random Forests)

Créé en 1995 par Ho et formellement proposé par les scientifiques Adele Cutler et Leo Breiman en 2001, le random forest ou forêt aléatoire est un

algorithme de prédiction utilisé en Apprentissage automatique. Comme on peut le constater, il associe les concepts de sous-espaces aléatoires et de bagging. Le random forest se compose de plusieurs arbres de décision, qui sont entraînés indépendamment sur des sous-ensembles du data set d'apprentissage (méthode de bagging). Chaque personne fait une estimation, et c'est en combinant les résultats que l'on obtient la prédiction finale avec une variance réduite. En résumé, l'idée est de tirer profit de divers avis abordant un même problème afin de le comprendre plus profondément. Les modèles sont répartis aléatoirement en sous-ensembles d'arbres de décision.[dN22a]

Avant l'entraînement, les algorithmes de forêt aléatoire n'ont pas besoin que trois hyperparamètres principaux soient définis. La taille des nœuds, le nombre d'arbres et le nombre de fonctions échantillonnées sont les paramètres. Depuis ce point, on peut utiliser le classificateur de forêt aléatoire pour résoudre des problèmes de régression ou de classification.

L'ensemble d'arbres de décision constitue l'algorithme de forêt aléatoire, et chaque arbre dans cet ensemble utilise un échantillon bootstrap tiré avec remplacement à partir de l'ensemble d'entraînement. Un tiers des données de cet échantillon d'entraînement est réservé comme données de test, appelées échantillon out-of-bag (oob), sur lesquelles nous reviendrons plus tard. Ensuite, on injecte une autre instance aléatoire via le feature bagging pour ajouter plus de diversité au jeu de données et réduire la corrélation entre les arbres de décision. La prédiction dépend du type de problème pour sa détermination. Lorsqu'il s'agit de régression, les arbres de décision individuels sont moyennés ; pour la classification, un vote majoritaire est utilisé, c'est-à-dire la variable la plus fréquente par catégorie, pour produire la classe prédite. Finalement, on utilise l'échantillon oob pour faire une validation croisée afin de finaliser cette prédiction. [IBMa]

2.3.5 Méthodes de Classification Bayésienne

De nombreux modèles ont émergé de la représentation des connaissances et du raisonnement basé sur ces représentations. Les réseaux bayésiens, initiés par Judea Pearl dans les années 1980, sont devenus des outils extrêmement utiles pour représenter des connaissances incertaines et raisonner à partir d'informations incomplètes.

Un réseau bayésien $B = (G, \theta)$ se compose de : - $G = (X, E)$, qui est un graphe dirigé acyclique dont les nœuds sont associés à un ensemble de variables aléatoires $X = \{X_1, \dots, X_n\}$, - et $\theta = \{P(X_i | Pa(X_i))\}$.

En outre, les probabilités sont utiles pour tenir compte de l'incertitude en quantifiant les relations entre les variables. Ainsi, ces deux caractéristiques ont été à la base des premières désignations des réseaux bayésiens comme "systèmes experts probabilistes", où le graphe était comparé à l'ensemble de règles d'un système expert classique et les probabilités conditionnelles étaient présentées comme une quantification de l'incertitude sur ces règles. Pearl et al. ont aussi montré que les réseaux bayésiens permettaient de représenter de manière compacte la distribution de probabilité jointe sur l'ensemble des variables [Ler10] :

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa(X_i)) \quad (2.3)$$

Grâce à l'augmentation des informations épidémiologiques et des métadonnées, nous comprenons de plus en plus les causes potentielles d'un événement et leur probabilité. Grâce à la puissance de calcul des ordinateurs modernes, l'approche bayésienne devient envisageable. [Bru17]

2.4 Apprentissage en profondeur

L'apprentissage profond se distingue comme le processus d'analyse de grandes quantités de données afin d'aligner des résultats, des modèles, des résultats ou des interprétations jusqu'ici inconnus et indéfinis. En fait, les modèles d'apprentissage profond ont une structure similaire au fonction-

nement du cerveau humain et, comme le cerveau humain, ils peuvent avoir des résultats inattendus. L'algorithme d'IA comporte ici plusieurs couches permettant à la machine de prendre ses propres décisions.

Ainsi, un scénario de photographies montrant des drapeaux et des défilés peut être réalisé avec des avions et des hélicoptères. Une technique d'apprentissage automatique à mettre en œuvre consiste à laisser la machine apprendre à distinguer chaque image comme étant un avion ou un hélicoptère. Par conséquent, de nombreux échantillons d'avions et d'hélicoptères sont nécessaires pour développer un vaste ensemble de points de données afin que la machine puisse les distinguer correctement des siens.

Pour l'apprentissage automatique, l'approche consiste à analyser les images avec des fonctionnalités spécifiques et à laisser la machine créer des clusters de données. Les données doivent être le double de la quantité pour que les réseaux de neurones profonds conduisent à des résultats corrects par rapport aux algorithmes d'apprentissage automatique. De cette façon, une fois la tâche complète d'apprentissage profond accomplie, nous n'obtiendrons pas seulement une règle simple pour les hélicoptères et une autre pour les avions, mais plutôt différents groupes pour différentes tailles de véhicules, couleurs, formes de carrosserie, nombres de fenêtres, etc[Gui20].

2.4.1 Réseaux de Neurones Convolutifs (CNN)

Les réseaux neuronaux convolutifs s'inspirent de la nature en imitant l'organisation du cortex visuel animal avec leur connectivité entre les neurones artificiels. La reconnaissance d'image est l'un des principaux cas d'usage. Les réseaux convolutifs ont un meilleur taux d'erreur et apprennent plus rapidement. On les utilise également pour l'analyse vidéo, mais dans une mesure moindre.

Le traitement naturel du langage utilise également ce type de réseau. L'efficacité des modèles CNN est très élevée pour l'analyse sémantique, la modélisation de phrase, la classification et la traduction.

Contrairement aux méthodes traditionnelles telles que les réseaux de

neurones récurrents, les réseaux de neurones à convolution peuvent capturer diverses réalités contextuelles du langage sans nécessiter une hypothèse de séquentialité.

Les réseaux de convolution ont également servi à la découverte de médicaments. En prédisant les interactions entre molécules et protéines biologiques, ils permettent d'identifier les traitements potentiels. Les CNN ont été utilisés principalement dans les logiciels de jeu tels que Go et échecs, où ils sont capables d'exceller. On peut aussi utiliser cette technologie pour repérer des anomalies sur une image donnée en entrée. [Dat20]

Les CNN sont une sous-catégorie de réseaux de neurones et ils comptent parmi les modèles les plus performants pour la classification d'images. Leur mode de fonctionnement est à première vue simple : L'image est donnée sous la forme d'une matrice de pixels par l'utilisateur en entrée :

- Une image en niveaux de gris a deux dimensions.
- Trois dimensions, avec une profondeur de 3 pour représenter les couleurs fondamentales (Rouge, Vert, Bleu).

Contrairement à un modèle MLP (Multi Layers Perceptron) classique qui ne contient qu'une partie classification, l'architecture du Convolutional Neural Network dispose en amont d'une partie convolutive et comporte par conséquent deux parties bien distinctes : Contrairement à un modèle MLP (Multi Layers Perceptron) classique qui ne contient qu'une partie classification, l'architecture du Convolutional Neural Network dispose en amont d'une partie convolutive et comporte par conséquent deux parties bien distinctes [Dat20] :

- Une partie convolutive : Il vise ultimement à extraire les caractéristiques de chaque image en les compressant pour diminuer leur taille initiale. Pour résumer, l'image d'entrée est soumise à une série de filtres, ce qui crée de nouvelles images appelées cartes de convolutions. Finalement, les cartes de convolutions obtenues sont regroupées dans un vecteur de caractéristiques appelé code CNN.
- Une partie classification : En entrée de la deuxième partie, le code

CNN obtenu en sortie de la partie convolutive est fourni, constitué de couches entièrement connectées appelées perceptron multicouche (MLP pour Multi Layers Perceptron). Cette partie a pour fonction de fusionner les caractéristiques du code CNN afin de classer l'image.

2.4.2 Réseaux de Neurones Générateurs Antagonistes (GAN)

Le but principal des GANs est de produire des données qui sont impossibles à distinguer des exemples réels. Ian Goodfellow et ses collaborateurs les ont introduits en 2014. Un GAN se compose de deux réseaux de neurones distincts, à savoir le générateur et le discriminateur. Le générateur produit de nouvelles données, tandis que le discriminateur les évalue pour en déterminer la qualité. Les deux réseaux s'améliorent continuellement en s'entraînant, ce qui améliore leurs performances respectives.

Depuis qu'ils ont été introduits en 2014, les GANs ont suscité un profond intérêt au sein de la communauté de l'intelligence artificielle en raison de leur aptitude à générer des données réalistes à partir d'exemples d'apprentissage. Plusieurs variantes et améliorations des GANs ont été proposées depuis lors, y compris des architectures conditionnelles et des méthodes d'optimisation avancées pour surmonter les nombreux défis liés à l'entraînement des GANs, tels que la convergence et la qualité des données générées. [Dat23]

Les GANs ont de nombreuses applications dans différents domaines, notamment :

- La production d'images et de vidéos de haute qualité .
- La colorisation des images en noir et blanc .
- Détecter et corriger les anomalies .
- La fabrication d'œuvres d'art .
- La synthèse de voix.

Les GANs ont aussi été appliqués dans le domaine de la médecine. Ils peuvent servir à créer des images médicales fictives pour former les réseaux

de neurones à détecter des maladies, par exemple. Les GANs peuvent aussi servir à générer des données de patients afin d'aider la recherche médicale.

En finance, ils sont performants pour repérer les fraudes en créant des données de transactions financières synthétiques. Ces réseaux servent aussi à la génération de données de marché synthétiques : Cela rend possible la création de prédictions et de tendances dans les marchés financiers. Les réseaux antagonistes génératifs contribuent enfin à la création de contenu pour les jeux vidéo, comme la génération de personnages, de mondes virtuels et de musique synthétique.

Il y a aussi des questions éthiques concernant l'application des réseaux antagonistes génératifs. C'est vrai, cette technologie est devenue célèbre auprès du grand public grâce à la génération de Deepfake. Ces images et vidéos montrent des personnalités publiques en train de dire des choses fausses qui n'ont jamais été dites par la personne concernée [Dat23].

Les GAN ont un rôle crucial dans la détection des anomalies. En matière de santé, ils permettent de détecter efficacement des pathologies en analysant des images médicales. Les entreprises de sécurité utilisent également cela pour détecter les intrusions à travers les systèmes de surveillance. Ils peuvent améliorer la précision de ces systèmes en générant des données synthétiques [Dig24].

La génération de données synthétiques des GAN renforce considérablement les performances des modèles d'apprentissage automatique. Elle leur donne plus d'exemples qualitatifs pour s'entraîner. De la vision par ordinateur à la reconnaissance de la parole, cette technique est largement utilisée dans divers domaines. Elle aide à améliorer la capacité des modèles pour effectuer de manière précise des tâches complexes [Dig24].

2.4.3 Réseaux Neuronaux à Mémoire à Court Terme (LSTM)

Les LSTM, également appelés Réseaux de Neurones à Mémoire à Long Terme, sont une forme spécialisée des RNN développée pour adresser l'apprentissage des dépendances sur le long terme dans les séquences. À la

différence des RNN traditionnels, qui peuvent rencontrer des difficultés à saisir les dépendances à long terme en raison du problème de disparition du gradient, les LSTM possèdent une architecture spécifique leur permettant de retenir et d'exploiter des informations sur de larges intervalles temporels.

Les LSTM sont extrêmement précieux dans des domaines comme le traitement du langage naturel, la traduction automatique et d'autres tâches impliquant des séquences complexes en raison de leur capacité à conserver une mémoire à long terme. Par exemple, pendant la modélisation du langage naturel, les LSTM peuvent apprendre des structures grammaticales et des relations entre les mots sur de longues distances, ce qui leur donne la capacité de produire un texte cohérent et d'estimer la probabilité de séquences de mots.

Les cellules spéciales, appelées "cellules", sont utilisées par les LSTM pour stocker et accéder à des informations sur de longues périodes.

Les LSTM peuvent décider quand mémoriser ou oublier des informations car ces cellules ont des portes qui contrôlent le flux d'informations dans et hors de la cellule. En raison de leur capacité à capturer les dépendances à long terme, on utilise fréquemment les LSTM dans des applications telles que la génération de texte, la prédiction de séquences, la reconnaissance vocale et d'autres tâches où une compréhension des contextes complexes est cruciale. Les LSTM sont des outils précieux pour résoudre divers problèmes de traitement des séquences en raison de leur architecture avancée et de leur capacité à gérer efficacement les séquences. [ECZ⁺19]

2.4.4 Mask R-CNN et Faster R-CNN

Mask R-CNN : il est conceptuellement simple contrairement au Faster R-CNN, il existe une étiquette de classe pour chaque objet candidat qui est une sortie supplémentaire en plus du décalage du cadre de délimitation ; la troisième branche détermine le masque d'objet. Un tel réseau basé sur le concept de masquage de la ROI (région d'intérêt) semble être une idée simple et juste. Cependant, dans la sortie du masque, la phase finale se

présente sous la forme de classes et de cases et l'algorithme utilisé est conçu pour des positions d'objet plus petites.

Faster R-CNN : L'architecture bien connue de Faster R-CNN contient deux étapes : les régions avec des objets candidats et le réseau neuronal pour la régression. La première étape de l'opération, connue sous le nom de réseau de proposition de région (RPN), place les cadres de délimitation des objets en tant qu'objets candidats. Le deuxième segment, appelé Fast R-CNN, implémente la recherche de victimes en appliquant RoIPool à chaque RoI pour collecter des cartes de fonctionnalités, puis en classant les fonctionnalités et en régressant le cadre de délimitation. Les fonctionnalités utilisées par l'étage le plus rapide, par exemple, peuvent être réutilisées dans l'étage le plus lent, tandis que le parallélisme des deux étages est le plus bénéfique pour l'amélioration des performances du système. Pour obtenir les dernières informations, ils peuvent se rendre sur [\[17\]](#), où nous effectuons une analyse comparative de Faster R-CNN et d'autres systèmes[[KGPR17](#)].

2.4.5 You Only Look Once(YOLO)

Il s'agit d'une famille populaire de modèles de reconnaissance d'objets appelée YOLO ou « You Only Look Once », décrite pour la première fois par Joseph Redmon et al. dans l'article de 2015 intitulé "You Only Look Once : Object Detection in Real-Time Unified. ". Ce modèle réalise une détection d'objets en temps réel : Il manipule les images à une fréquence de 30 images par seconde (IPS).

Le réseau de neurones impliqué met en série de nombreux neurones pour prendre une photo en entrée, prédire directement les cadres de délimitation (souvent appelés "bounding box") et attribuer des étiquettes de classe à chaque cadre.

Le modèle opère en premier lieu par la division de l'image d'entrée en une grille de cellules, où chaque cellule est chargée de prédire un cadre de délimitation. Chaque cellule contribue également à une prédiction de classe.

Par exemple, on peut diviser une image en grille 7×7 et supposons que chaque cellule de la grille puisse prédire 2 cadres de délimitation, cela donne ainsi 98 prédictions proposées pour les cadres de délimitation. Ensuite, les cadres de délimitation avec confiance et la carte des probabilités de classe sont combinés pour former un ensemble final de cadres de délimitation et d'étiquettes de classe [OCT21].

a) Principe de fonctionnement

1. **Prendre une photo** : En premier lieu, l'algorithme YOLO débute par une image, semblable à la prise d'une photo avec un appareil photo. Cela s'appelle la détection d'objets basée sur la classification d'images.
2. **Diviser l'image** : Ensuite, il découpe l'image donnée en petits carrés, comme un damier. Chaque carré sera inspecté pour déterminer s'il contient un objet (comme un chat, un chien ou une boîte de conserve).
3. **Chercher des indices** : YOLO recherche des indices ou des caractéristiques tels que les bords, formes ou textures pour chaque carré afin d'identifier l'objet présent. Il les encadre avec des boîtes englobantes. Pour bien comprendre un nouveau jeu de données et interpréter, YOLO a parfois reçu un jeu de données de référence (ou "vérité terrain") pour avoir des points de comparaison.
4. **Faire des prédictions** : L'algorithme fait une supposition pour chaque carré d'une image : Quel objet est-ce et où se trouve-t-il précisément dans le carré. Il assigne un score à chaque supposition pour indiquer son degré de certitude.
5. **Éliminer les excédents** : Certains carrés ont des conjectures sur différents objets qui se chevauchent, comme deux carrés devinant une partie de la même voiture. YOLO sélectionne la supposition optimale pour chaque objet en éliminant les suppositions inutiles.
6. **Exhiber ce qu'il a découvert** : YOLO vous montre à la fin où il pense que chaque objet se trouve en dessinant des boîtes autour d'eux et en les étiquetant, comme "voiture" ou "arbre". Si vous lui fournissez 1'000

images avec des chiens et des chats, puis demandez-lui d'identifier les chats, il enrichira les images de métadonnées pointant vers les chats.

YOLO examine tous les éléments d'une image (décomposés en "carrés") simultanément, ce qui est son principal atout. C'est pourquoi sa rapidité lui permet même de fonctionner en temps réel, ce qui est extrêmement utile pour des applications nécessitant une réactivité rapide, telles que les voitures autonomes ou la vidéo-surveillance[Inn24].

b) Evolution de YOLO

1. **YOLO V1** : Les capacités de détection d'objets en temps réel de la première version de YOLO ont révolutionné la communauté des chercheurs en IA / Vision par ordinateur, offrant des vitesses d'inférence bien plus rapides que les méthodes existantes telles que R-CNN. La v1 de YOLO divise l'image d'entrée en une grille et prédit plusieurs boîtes englobantes ainsi que les probabilités de classe pour chaque cellule de la grille. Toutefois, la précision était compromise avec cette première version. YOLO avait des difficultés avec les petits objets et faisait de nombreuses erreurs dans la localisation de ces objets.
2. **YOLO V2 et V3** : Des améliorations notables ont été introduites dans les versions suivantes, comme YOLO v2 et v3, y compris de nouvelles fonctionnalités telles que l'utilisation du clustering k-means pour prédire des coordonnées plus précises des boîtes d'ancrage. Les performances de détection ont été considérablement améliorées sur des benchmarks tels que les ensembles de données Pascal VOC et COCO grâce à la normalisation par lots, ainsi qu'à une gestion d'images d'entrée de plus haute résolution implémentée dans ces versions.
3. **YOLO V4 et V5** : YOLO v4 a introduit des fonctionnalités telles que le pooling pyramidal spatial et une architecture YOLO plus complexe basée sur des réseaux convolutionnels de pointe, avec pour but d'obtenir à la fois une grande vitesse et une haute précision. Quant à lui, YOLO v5 s'est concentré sur la simplification et l'optimisation, ce

qui lui permet de fonctionner très rapidement même sur du matériel moins puissant tout en conservant une haute précision.

4. **YOLO V6 a V8** : Les améliorations continues de YOLO sont introduites dans les versions récentes à partir de la version 6, en se concentrant sur des applications pratiques comme les véhicules autonomes ou la surveillance vidéo. A mesure que le temps passe, YOLO s'éloigne de plus en plus de la communauté des chercheurs pour toucher un public plus large et être appliqué dans des cas d'usage concrets. Les techniques de Apprentissage en profondeur ont été perfectionnées dans ces versions, y compris la diversification des formes d'augmentation des données et l'optimisation des algorithmes qui ont contribué à améliorer la précision moyenne et à détecter une gamme diversifiée de classes d'objets.
5. **YOLO V9** : Le 21 février 2024, Chien-Yao Wang, I-Hau Yeh et Hong-Yuan Mark Liao ont publié l'article "YOLOv9 : Vous pouvez apprendre ce que vous voulez en utilisant l'Information de Gradient Programmable, qui présente une nouvelle architecture de modèle de vision par ordinateur YOLOv9.

Le YOLOv9 marque une avancée importante dans la série des modèles YOLO, apportant des améliorations significatives en matière de précision et d'efficacité pour la détection en temps réel des objets. Il se différencie de ses prédécesseurs, comme YOLOv8, en réduisant le nombre de paramètres de 49% et la complexité computationnelle de 43%, tout en augmentant la précision moyenne sur les données MS COCO de 0,6%.

La série YOLOv9 comprend quatre modèles : YOLOv9-s (petit), YOLOv9-m (moyen), YOLOv9-c (compact) et YOLOv9-e (étendu) ont des variations en nombre de paramètres et performances. Ces modèles sont adaptés pour satisfaire différents besoins, depuis les applications simples jusqu'aux applications exigeantes en performances. YOLOv9 introduit deux innovations majeures :

- Les Informations de Gradient Programmables (PGI) : un mécanisme

de supervision auxiliaire comprenant trois composants principaux : une branche principale, une branche qui peut être inversée et une information auxiliaire à plusieurs niveaux

- Le réseau d'agrégation de couches efficace généralisée (GELAN).

Les réseaux de neurones profonds rencontrent souvent des goulets d'étranglement de l'information, mais cette structure contribue à atténuer la perte d'informations qui en résulte. Le GELAN fusionne CSPNet, réputé pour sa planification efficace du chemin de gradient, et ELAN, qui met l'accent sur la vitesse d'inférence. Cette combinaison crée une architecture polyvalente axée sur un design léger, une inférence rapide et une précision améliorée. De plus, YOLOv9 convient à diverses applications en vision par ordinateur, telles que la logistique et la distribution, les véhicules autonomes, le comptage de personnes dans le commerce de détail ou l'analyse sportive. Ces applications profitent de la capacité de YOLOv9 à détecter des objets en temps réel avec une grande précision et efficacité [Inn24].

c) Comparaison avec d'autres systèmes en temps réel : Outre la recherche traditionnelle sur la détection d'objets, de nombreux efforts sont déployés pour accélérer les pipelines typiques. De l'autre côté, Sadeghi et al. proposé un véritable système invariant dans le temps (> 30 images par seconde). Avec cela, nous comparons YOLO pour leur lecture GPU de la version DPM qui fonctionne à 30 Hz ou 100 Hz. Outre le reste des efforts et n'atteignant pas le jalon en temps réel, nous comparons également leur mAP et leur vitesse relatives pour souligner les compromis précision-performance qu'un système de détection d'objets peut fournir. Fast YOLO s'impose comme le guépard dans la catégorie détection d'objets sur PASCAL; nous savons qu'il s'agit actuellement de l'algorithme de détection d'objets le plus rapide, ce qui le rend inégalé par rapport aux autres. Avec 52. Quant au mAP 7%, il est 2 fois supérieur à celui de la détection rapide en temps réel utilisant les articles précédents. YOLO conserve une énorme percée vers mAP sur le territoire 63. Les vidéos en streaming n'utiliseront

que 4% de la bande passante tout en conservant une qualité acceptable et des interactions en temps réel. Au-delà de cela, YOLO est également formé au VGG-16. La méthode mentionnée ci-dessus offre plus de précision mais prend évidemment beaucoup plus de temps que YOLO. Pour mieux mettre les choses en perspective, le résultat de notre système est différent des modèles de détection qui utilisent VGG-16, mais il est plus lent que le temps réel, par conséquent, le reste du document se concentrera sur nos modèles individuels plus rapides. Le DPM le plus rapide montre une exécution plus notable du DPM par rapport aux autres méthodes, mais il réduit de moitié le nombre d'instructions exécutées. Cependant, il y a aussi le fait que le TPM a un taux de détection comparativement plus faible, ce qui le rend moins précis que les méthodes basées sur les réseaux neuronaux. R-CNN Normalise représente la recherche sélective avec une proposition de boîte statique. Bien que sa vitesse de fonctionnement puisse être bien meilleure que celle de R-CNN, elle n'est pas tout à fait en temps réel et il est clair que la précision est médiocre en l'absence de bonnes propositions[[JSRA16](#)].

Accélération le classificateur R-CNN, Fast-R-CNN reste toujours dépendant de la recherche sélective - une procédure qui prend environ 2 secondes par image pour la génération de propositions de boîtes englobantes. Par conséquent, sa mAP atteint un pic à 0. À 5 ips, une telle vidéo reste encore loin du temps réel. La technologie R-CNN plus rapide supprime l'étape de recherche sélective avec un réseau neuronal pour les boîtes proposant, comme dans les travaux de Szegedy et al. Dans nos tests, un R-CNN plus rapide avec une exécution à 7 ips crée des résultats plus précis par rapport à des performances plus lentes de 18 ips. Le 10 mAP de la version VGG-16 de Faster R-CNN est supérieur à celui de YOLO mais il est également 6 fois plus lent que cela. ZeilerFergus Faster R-CNN seulement est 2.2. Cependant, POSIA fonctionne 5 fois plus lentement que YOLO et il est également moins précis [[JSRA16](#)].

2.5 Apprentissage automatique VS Apprentissage en profondeur

L'apprentissage automatique, ou Apprentissage automatique, est la technologie la plus ancienne et la plus simple. Elle utilise un algorithme qui ajuste le système automatiquement en fonction des retours de l'humain. Pour mettre en place cette technologie, il faut disposer de données bien organisées. Ensuite, des données structurées et catégorisées sont utilisées pour alimenter le système afin qu'il puisse comprendre comment classer de nouvelles données similaires. Le système exécute ensuite les actions programmées en fonction de ce classement. Par exemple, il est capable d'identifier si une photo représente un chien ou un chat et de classer le document dans le dossier approprié.

Une fois utilisé initialement, l'algorithme est amélioré en fonction des retours du développeur, qui signalent au système les classifications incorrectes et lui fournissent les bonnes catégories.

Les données structurées ne sont pas nécessaires pour le Apprentissage en profondeur (apprentissage profond). Plusieurs couches de réseaux neuronaux sont utilisées par le système, combinant différents algorithmes inspirés du cerveau humain. De cette manière, le système peut fonctionner avec des données non structurées.

Ce moyen est spécialement approprié pour les tâches compliquées, lorsque tous les caractéristiques des objets à traiter ne peuvent pas être classifiés à l'avance. Le Apprentissage en profondeur identifie automatiquement les caractéristiques discriminantes. Il cherche un nouveau critère spécifique de l'objet dans chaque couche, qui servira de base pour décider de la classification finale de l'objet à la fin du processus.

Important : Le Apprentissage en profondeur permet au système d'identifier automatiquement les caractéristiques discriminantes des données sans nécessiter de catégorisation préalable. Il n'est pas nécessaire qu'un développeur entraîne le système. Il détermine lui-même s'il est nécessaire de

modifier le classement ou de créer de nouvelles catégories en fonction des nouvelles données.

Le Apprentissage automatique fonctionne à partir d'une base de données contrôlable, tandis que le Apprentissage en profondeur nécessite un volume de données beaucoup plus important. Il est nécessaire que le système dispose de plus de 100 millions d'entrées pour fournir des résultats fiables.

En outre, la technologie requise pour le Apprentissage en profondeur est plus avancée. Elle exige plus de ressources IT et s'avère nettement plus coûteuse que le Apprentissage automatique : Elle n'est pas intéressante pour une utilisation de masse par les entreprises, du moins à l'heure actuelle.

[Gui20]

2.6 Travaux Connexes(Etude comparative)

En agriculture de précision, il est crucial pour les agriculteurs de combattre les mauvaises herbes, car elles peuvent causer une diminution significative des rendements des cultures. Afin de faire face à cette difficulté, de nombreuses études récentes ont porté sur l'utilisation de méthodes d'intelligence artificielle (IA) et d'apprentissage automatique afin de détecter et de gérer les personnes indésirables. Dans toutes ces recherches, il est essentiel d'utiliser des réseaux de neurones profonds tels que les réseaux de neurones convolutifs (CNN) ainsi que des architectures avancées telles que Faster R-CNN et YOLO afin de repérer les mauvaises herbes dans divers habitats de culture.

Certains travaux se sont également penchés sur la prédiction des rendements des cultures en utilisant des réseaux de neurones profonds, ce qui permet aux agriculteurs de prendre des décisions plus éclairées en matière de gestion des cultures. De plus, des efforts ont été déployés pour créer des ensembles de données spécialisés, tels que Weed25 et The CropAndWeed Dataset, pour faciliter la recherche.

Cette comparaisons fournissent des informations cruciales sur l'effica-

cit  et la pertinence des m thodes d'IA pour la gestion des cultures et la d tection des mauvaises herbes. En examinant ces travaux connexes, il devient possible de mieux comprendre les progr s r cents et les d fis restants dans ce domaine en pleine expansion.

TABLE 2.1: Tableau Comparatif entre les m thode de d tection des mauvaises herbes

Articles	Techniques	Base de donn�es	R�sultats
Article 01 : CNN Based Automated Weed Detection System Using UAV Imagery [HM21]	Convolutional Neural Networks (CNNs)	Le syst�me a �t� d�velopp� en utilisant un ensemble de donn�es r�el de 4400 images de v�hicules a�riens sans pilote (UAV) avec 15336 segments. Les classes identifi�es par le mod�le sont le sol, le soja, l'herbe et les feuilles larges.	Le mod�le CNN LVQ propos� a atteint une pr�cision utilisateur de 100% pour la classe du sol, suivi par le soja (99,79%), l'herbe (98,58%) et les feuilles larges (98,32%)et une pr�cision globale de 99,44%.
Article 02 : Crop Yield Prediction Using Deep Neural Networks [Rus19]	Deep Neural Networks (DNN)	Le syst�me a �t� d�velopp� en utilisant un ensemble de donn�es de Syngenta qui enregistre le g�notype et les performances de rendement de 2,267 hybrides de ma�s plant�s dans 2,247 lieux entre 2008 et 2016(Syngenta Crop Challenge dataset).	Le mod�le DNN a montr� une pr�cision de pr�diction sup�rieure, avec une erreur quadratique moyenne (RMSE) repr�sentant 12% du rendement moyen et 50% de l'�cart type pour l'ensemble de donn�es de validation en utilisant des donn�es m�t�orologiques pr�dites. Avec des donn�es m�t�orologiques parfaites, le RMSE serait r�duit � 11% du rendement moyen et 46% de l'�cart type.
La suite dans la page suivante			

Articles	Techniques	Base de données	Résultats
<p>Article 03 : Performance Evaluation of Semi-supervised Learning Frameworks for Multi-Class Weed Detection [JDZ24]</p>	<p>Semi-supervised Learning, FCOS and Faster-RCNN</p>	<p>Deux ensembles de données publiques ont été utilisés pour évaluer les performances du cadre d'apprentissage semi-supervisé : CottonWeedDet : Comprend 848 images haute résolution (4442 × 4335 pixels) annotées avec 1532 boîtes englobantes. CottonWeedDet12 : Contient 5648 images de 12 classes de mauvaises herbes, annotées avec un total de 9370 boîtes englobantes.</p>	<p>Les résultats expérimentaux montrent que l'approche proposée est capable d'atteindre environ 76% et 96% de précision de détection comme les méthodes supervisées avec seulement 10% de données étiquetées dans CottenWeedDet et CottonWeedDet12, respectivement.</p>
<p>Article 04 :Weed Detection in Pea Cultivation with the Faster RCNN ResNet 50 Convolutional Neural Network [HAY22]</p>	<p>Faster RCNN ResNet</p>	<p>L'ensemble de données original contenait 1156 images. Pour enrichir l'ensemble de données, des méthodes de traitement d'image ont été appliquées à l'aide de la bibliothèque Python OpenCV. Avec les méthodes d'augmentation, l'ensemble de données a été étendu à un total de 9248 images.(Les mauvaises herbes dans la culture des pois)</p>	<p>Prédiction jusqu'à 100% pour la détection et l'ultralocalisation des cultures de pois.</p>
<p>La suite dans la page suivante</p>			

Articles	Techniques	Base de données	Résultats
<p>Article 05 :Weed Identification in Maize Fields Based on Improved Swin-Unet [ZGZ⁺23]</p>	<p>-Utilisation d'une variante améliorée de Swin-Unet pour la segmentation d'images. -Prétraitement des images pour améliorer la qualité et la netteté.</p>	<p>- Une base de données composée d'images de champs de maïs contenant des mauvaises herbes. - Les images sont annotées pour indiquer l'emplacement et le type de mauvaises herbes présentes. -Les classes de mauvaises herbes peuvent inclure différentes espèces communes trouvées dans les champs de maïs, telles que le chiendent, l'amarante, le liseron, etc.</p>	<p>Le modèle Swin-Unet proposé surpasse les autres, atteignant une intersection moyenne sur l'union de 92,75%, une précision de pixel moyenne de 95,57%, et une vitesse d'inférence de 15.1 FPS</p>
<p>Article 06 : The power of transfer learning in agricultural applications : AgriNet [AA22]</p>	<p>- -Un ensemble de modèles pré-entraînés sur cinq architectures ImageNet : VGG16, VGG19, Inception-v3, InceptionResNet-v2 et Xception. -Ces modèles utilisent le transfer learning, une technique puissante qui permet de réduire le temps d'apprentissage et d'améliorer les performances d'un modèle de deep learning.</p>	<p>La base de données AgriNet, une collection de 160k images agricoles provenant de plus de 19 emplacements géographiques, plusieurs dispositifs d'images, et plus de 423 classes d'espèces de plantes et mauvaise herbes .</p>	<p>AgriNet-VGG19 a obtenu la plus haute précision de classification de 94% et le plus haut score F1 de 92%. Tous les modèles proposés ont été trouvés pour classer avec précision les 423 classes d'espèces de plantes et de mauvaises herbes avec une précision minimale de 87% pour le modèle Inception-v3</p>

La suite dans la page suivante

Articles	Techniques	Base de données	Résultats
<p>Article 07 : Weed25 : A deep learning dataset for weed identification [WTL+22]</p>	<p>YOLOv3, YOLOv5, and Faster-RCNN</p>	<p>-L'étude a utilisé l'ensemble de données Weed25, qui contient 14,035 images de 25 différentes espèces de mauvaises herbes</p>	<p>Les résultats montrent que la précision moyenne de détection sous les mêmes paramètres de formation était de 91.8% pour YOLOv3, 92.4% pour YOLOv5, et 92.15% pour Faster R-CNN.</p> <p>-Il est présenté que Weed25 pourrait être une ressource de formation efficace pour le développement ultérieur de modèles d'identification de mauvaises herbes en temps réel sur le terrain</p>
<p>La suite dans la page suivante</p>			

Articles	Techniques	Base de données	Résultats
<p>Article 08 : The CropAndWeed Dataset : a Multi-Modal Learning Approach for Efficient Crop andWeed Manipulation [SCSW23]</p>	<p>YOLOv5</p>	<p>Base de données : L'article propose un nouvel ensemble de données d'images à grande échelle spécialisé dans l'identification fine de 74 espèces de cultures et de mauvaises herbes pertinentes. Les annotations de boîtes englobantes étiquetées, de masques sémantiques et de positions de tiges sont fournies pour environ 112k instances dans plus de 8k images haute résolution de sites agricoles du monde réel et de parcelles extérieures spécifiquement cultivées de types de mauvaises herbes rares. De plus, chaque échantillon est enrichi d'un ensemble étendu de méta-annotations concernant les conditions environnementales et les paramètres d'enregistrement</p>	<ul style="list-style-type: none"> - Les résultats montrent une variabilité significative dans les performances entre les différentes classes, ce qui pourrait indiquer que certaines espèces de cultures et de mauvaises herbes sont plus difficiles à identifier que d'autres. - Il est également intéressant de noter que certaines classes ont des performances exceptionnellement élevées, ce qui suggère que l'approche d'apprentissage multimodal est particulièrement efficace pour ces types spécifiques de cultures et de mauvaises herbes. - Cependant, il y a aussi des cas où les performances sont relativement faibles, ce qui pourrait indiquer la nécessité d'améliorer le modèle ou d'ajuster les paramètres pour ces classes spécifiques.
<p>La suite dans la page suivante</p>			

Articles	Techniques	Base de données	Résultats
<p>Article 09 :TIA-YOLOv5 : An improved YOLOv5 network for real-time detection of crop and weed in the field [WPC⁺22]</p>	<p>TIA-YOLOv5</p>	<p>Dans cette étude, 4500 images de betteraves sucrières et de mauvaises herbes ont été utilisées. Une méthode d'augmentation de données a été appliquée pour équilibrer le nombre d'échantillons, portant le total à 5536 images. Ces images ont été divisées en ensembles d'entraînement, de validation et de test dans un ratio de 8 :1 :1. Les images synthétiques et leurs originales correspondantes ont été utilisées uniquement pour l'entraînement du modèle.</p>	<p>Les résultats des tests avec l'ensemble de données de betterave sucrière ont montré que le réseau TIA-YOLOv5 proposé a obtenu un F1-score de 70.0%, un AP de 80.8% et un mAP@0.5 de 90.0%. Ces résultats étaient respectivement de 11.8%, 11.3% et 5.9% supérieurs à ceux du modèle YOLOv5 de base. De plus, la vitesse de détection a atteint 20.8 FPS.</p>
<p>Article 10 : Deep Object Detection of Crop Weeds : Performance of YOLOv7 on a Real Case Dataset from UAV Images [GRD⁺23]</p>	<p>YOLOv7</p>	<p>Ils ont construit un ensemble de données complet de plantes de chicorée (CPs) et l'ont rendu public, composé de 3373 images RGB basées sur des UAV acquises à partir de multi-vols et de différentes conditions de terrain étiquetées pour fournir des données d'entraînement essentielles pour la détection des mauvaises herbes.</p>	<p>Les résultats obtenus pour l'ensemble de données CP avec YOLOv7 étaient encourageants, surpassant les autres variantes de YOLO en produisant des métriques de valeur de 56,6%, 62,1% et 61,3% pour les scores mAP@0.5, le rappel et la précision, respectivement.</p>

2.7 Conclusion

Après avoir examiné une série d'articles de recherche dans le domaine de la gestion des cultures et de la détection des mauvaises herbes en utilisant des techniques d'intelligence artificielle (IA) et d'apprentissage automatique, il est évident que l'utilisation de méthodes basées sur l'apprentissage en profondeur, notamment les réseaux de neurones convolutifs (CNN) et les architectures plus récentes comme Faster R-CNN et YOLO, présente des avantages importants par rapport aux méthodes classiques.

D'après les recherches étudiées, il est démontré que les modèles de deep learning peuvent offrir des performances de détection et de classification des mauvaises herbes plus précises et plus efficaces dans différentes conditions et cultures. De plus, la mise en place de jeux de données spécifiques à l'agriculture, comme Weed25 et The CropAndWeed Dataset, ainsi que l'utilisation de techniques de transfert d'apprentissage comme AgriNet, ont prouvé leur capacité à améliorer les résultats et à faciliter la généralisation des modèles.

Toutefois, même si l'apprentissage en profondeur présente des bénéfices évidents, des difficultés demeurent, notamment en ce qui concerne la disponibilité et la qualité des données, ainsi que la nécessité de s'assurer de la robustesse des modèles dans des environnements réels et variables.

Conception et mise en oeuvre du système

3.1 Introduction

Afin de mettre en œuvre un système de gestion des cultures et de détection des mauvaises herbes réussi et efficace, une approche précise et multidisciplinaire doit être suivie qui combine les sciences agricoles, l'apprentissage automatique et la vision par ordinateur.

Ce chapitre traite de la conception et de la mise en œuvre de notre système. Nous commençons par exposer les défis actuels dans le domaine agricole, mettant en évidence les difficultés spécifiques liées à la culture des plantes et à la lutte contre les mauvaises herbes. Par la suite, nous examinerons en détail la structure du système proposé, en mettant l'accent sur les composants essentiels et leur fonctionnement.

Pour finir, nous discuterons des perspectives et des avantages potentiels de notre approche pour les agriculteurs et l'industrie agricole dans sa totalité.

3.2 Problématique

La problématique au cœur de notre travail réside dans la nécessité de développer un système de gestion des cultures et de détection des mauvaises herbes qui soit à la fois précis, efficace et adaptable aux différents environnements agricoles. Plus spécifiquement, nous sommes confrontés aux défis suivants :

Détection précise et précoce des mauvaises herbes : Le système doit être capable de distinguer efficacement les mauvaises herbes des cultures et d'autres éléments présents dans le champ, même dans des conditions d'éclairage et d'environnement variables.

Robustesse face à la diversité des mauvaises herbes : Le système doit s'adapter à une large variété de types de mauvaises herbes, en tenant compte de leurs caractéristiques morphologiques et de leurs stades de développement.

Gestion efficace des mauvaises herbes : Le système doit proposer des solutions de gestion adaptées aux différentes situations rencontrées, en intégrant des techniques de lutte contre les mauvaises herbes précises et durables.

Validation et évaluation rigoureuses : Le système doit être soumis à des tests et à des évaluations rigoureuses dans des conditions agricoles réelles pour garantir sa performance, son efficacité et sa fiabilité.

En abordant ces défis, notre objectif est de développer un système qui contribue à améliorer l'efficacité et la durabilité de l'agriculture, tout en réduisant les coûts et l'impact environnemental associés à la gestion des cultures et à la lutte contre les mauvaises herbes.

3.3 Architecture du système proposé

Le processus est basé sur le schéma RDF standard, à savoir : acquisition, Pré-traitement et extraction des informations pertinentes et détection.

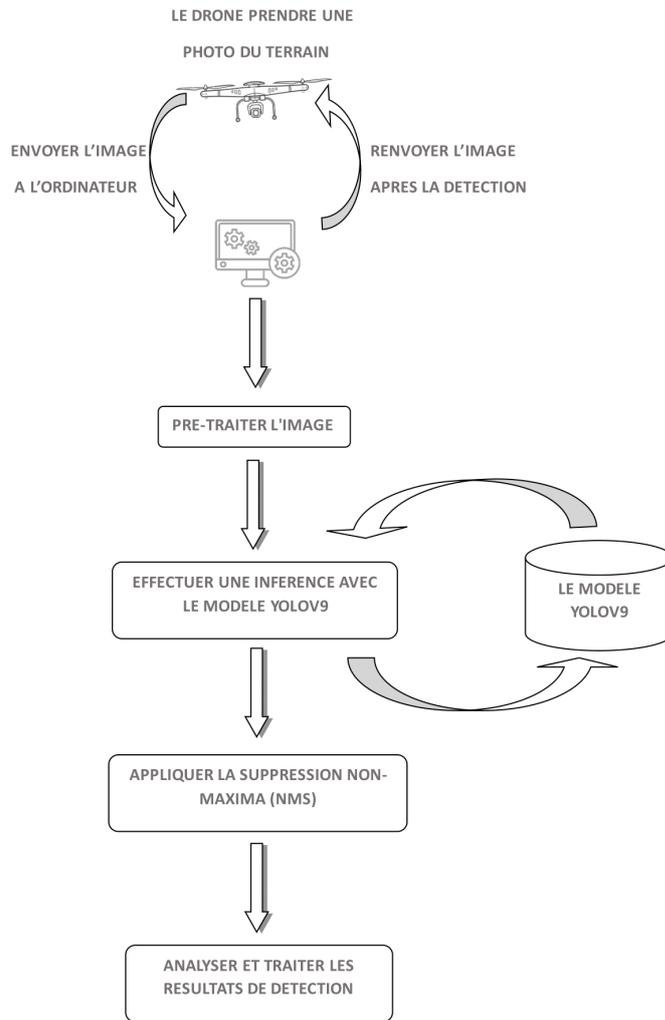


FIGURE 3.1 – Schéma général du processus de détection des mauvaises herbes .

Une fois que le drone a reçu l'image traitée, il pulvérise des herbicides uniquement dans les endroits contenant des mauvaises herbes.

3.3.1 Acquisition d'images

L'étape d'acquisition d'images avec le drone est une phase cruciale du processus global de détection et de traitement des mauvaises herbes. Tout d'abord, le drone est équipé d'une caméra haute résolution qui capture des images du terrain en survolant la zone cible. Cette caméra peut être montée de manière stabilisée pour garantir des images nettes même en cas de mouvements du drone.

Une fois en vol, le drone est programmé pour suivre un plan de vol préalablement défini ou pour être piloté manuellement vers les zones d'intérêt. Lorsqu'il atteint la position désirée, le drone déclenche la prise de vue en utilisant des capteurs de déclenchement ou une commande à distance. La fréquence des prises de vue peut être ajustée en fonction de la densité des mauvaises herbes, de la vitesse de déplacement du drone et des besoins spécifiques de l'opération.

Après chaque prise de vue, l'image capturée est immédiatement traitée pour vérifier sa qualité et sa netteté. Si nécessaire, des ajustements sont effectués pour garantir que les détails importants du terrain, y compris les mauvaises herbes, sont clairement visibles. Ensuite, l'image est stockée temporairement dans la mémoire interne du drone en attendant d'être transmise à l'ordinateur au sol pour une analyse plus approfondie.

3.3.2 Pré-traitement

L'étape de prétraitement de l'image joue un rôle crucial dans la préparation de l'image pour l'inférence avec le modèle YOLOv9. Cette étape implique plusieurs transformations essentielles pour garantir que l'image est compatible avec les exigences du modèle et pour optimiser les performances de détection.

A) Redimensionnement (Resize) : L'image d'entrée est redimensionnée à une taille spécifique définie par le paramètre `imgsz`. Cette étape est nécessaire car le modèle YOLOv9 a été entraîné sur des images d'une taille

particulière. Le redimensionnement garantit que l'image a les dimensions attendues par le modèle pour une analyse correcte.

B) Conversion en tenseur (Tensor Conversion) : L'image pré-traitée est convertie en un tenseur PyTorch. Si l'image est à trois dimensions (trois canaux de couleur), une dimension supplémentaire est ajoutée pour représenter le lot (batch). Cette conversion est essentielle car le modèle YOLOv9 attend des données d'entrée sous forme de tenseurs PyTorch pour le calcul et l'inférence.

3.3.3 Inférence avec YOLOv9

L'étape d'inférence est au cœur du processus de détection d'objets avec YOLOv9. C'est à cette étape que le modèle YOLOv9 utilise les données d'image prétraitées pour identifier et localiser les objets présents dans l'image. Les étapes sont résumées dans les points suivants :

1. **Chargement de l'image prétraitée :** Le modèle YOLOv9 reçoit l'image prétraitée en tant que tenseur PyTorch.
2. **Passage de l'image dans le réseau neuronal :** L'image prétraitée est ensuite passée à travers le réseau neuronal convolutif de YOLOv9. Ce réseau neuronal est composé de plusieurs couches convolutives, de regroupement et de mise en forme entièrement connectées. Chaque couche effectue des calculs complexes pour extraire des caractéristiques importantes de l'image.
3. **Extraction des caractéristiques :** Au fur et à mesure que l'image traverse le réseau neuronal, des caractéristiques de plus en plus abstraites sont extraites. Ces caractéristiques représentent les motifs et les formes présents dans l'image.
4. **Prédiction des boîtes englobantes et des degrés de confiances :** Les couches finales du réseau neuronal prédisent un ensemble de boîtes englobantes et leurs confiances associées pour chaque objet détecté

dans l'image. Les boîtes englobantes représentent l'emplacement approximatif de l'objet, tandis que les confiances indiquent la probabilité que l'objet soit réellement présent.

3.3.4 Facteurs influençant l'inférence

1. **Taille du modèle** : Un modèle plus grand peut extraire des caractéristiques plus complexes et obtenir des détections plus précises, mais il peut également être plus lent à inférer.
2. **Résolution d'image** : Une résolution d'image plus élevée permet de capturer plus de détails, ce qui peut améliorer la précision de la détection, mais peut également augmenter le temps d'inférence.
3. **Matériel** : L'utilisation d'un GPU peut considérablement accélérer l'inférence par rapport à un CPU.

3.3.5 Suppression non-maxima (NMS)

A) Objectifs : L'étape de suppression non-maxima (NMS) est une étape post-traitement essentielle dans le processus de détection d'objets avec YOLOv9. Son objectif est d'éliminer les détections redondantes et d'affiner les résultats finaux en conservant uniquement les boîtes englobantes les plus pertinentes pour chaque objet détecté.

B) Fonctionnement :

1. **Tri par score de confiance** : Les prédictions issues de l'étape d'inférence sont d'abord triées par ordre décroissant de score de confiance. Cela signifie que les détections avec les scores de confiance les plus élevés sont classées en premier.
2. **Parcours des détections** : Le NMS parcourt ensuite la liste des détections triées. Pour chaque détection courante ($det1$), les étapes suivantes sont effectuées :
 - **Calcul de l'intersection sur union (IoU)** : L'IoU est calculée entre la boîte englobante de la détection courante ($det1$) et les

boîtes englobantes des détections restantes (det2). L'IoU mesure le chevauchement entre les deux boîtes.

- **Comparaison des IoU** : Si l'IoU entre det1 et det2 est supérieure à un seuil prédéfini (iou-thres), det2 est considérée comme une détection redondante et est supprimée de la liste.
- **Répétition** : Le processus est répété pour toutes les détections restantes, en utilisant det1 comme référence.

3. Résultats finaux :

Après le parcours complet de la liste, les détections restantes représentent les détections finales, avec les boîtes englobantes les plus pertinentes pour chaque objet détecté.

C) Avantages :

- **Réduction des détections redondantes** : Le NMS élimine les détections qui se chevauchent fortement et qui représentent probablement le même objet.
- **Amélioration de la précision** : En supprimant les détections redondantes, le NMS permet de se concentrer sur les détections les plus précises et réduit le nombre de faux positifs.
- **Meilleure lisibilité des résultats** : Les résultats finaux après NMS sont plus faciles à interpréter et à analyser, car chaque objet détecté est représenté par une seule boîte englobante.

D) Paramètres : Le NMS prend deux paramètres principaux :

- **Seuil de confiance (conf-thres)** : Ce paramètre définit le score de confiance minimum requis pour qu'une détection soit conservée. Les détections avec des scores de confiance inférieurs au seuil sont supprimées.
- **Seuil d'IoU (iou-thres)** : Ce paramètre définit le chevauchement maximal autorisé entre deux boîtes englobantes pour qu'elles soient

considérées comme redondantes. Les détections avec un IoU supérieur au seuil sont supprimées.

3.3.6 Analyse et traitement des résultats de détection

L'étape d'analyse et de traitement des résultats de détection est la dernière étape du processus de détection d'objets avec YOLOv9. Son objectif est de transformer les détections finales obtenues après l'étape de suppression non-maxima (NMS) en informations utiles et interprétables pour l'utilisateur. Voici une description détaillée de cette étape :

1. **Initialisation et Configuration** : Tout d'abord, des chemins et configurations nécessaires sont initialisés. Par exemple, les chemins pour sauvegarder les images et les labels sont configurés. Chaque image est associée à un chemin de sauvegarde spécifique pour enregistrer les résultats.
2. **Vérification des Détections** : Ensuite, le système vérifie s'il y a des objets détectés dans l'image. Si des objets sont détectés, les coordonnées des boîtes de détection sont rescalées de la taille de l'image redimensionnée (utilisée pour l'inférence) à la taille originale de l'image. Cela permet de maintenir la précision et la pertinence des détections par rapport aux dimensions originales de l'image.
3. **Comptage et Enregistrement des Détections** : Pour chaque détection, le système compte le nombre d'objets détectés par classe. Par exemple, s'il détecte plusieurs objets de la même classe (comme des personnes, des voitures, etc.), il enregistre combien d'objets de chaque classe ont été détectés. Ces informations sont ajoutées à une chaîne de logs pour un suivi facile. Si la fonctionnalité de sauvegarde des résultats en fichier texte est activée, les coordonnées des boîtes de détection et les classes sont enregistrées dans un fichier texte au format approprié (xywh normalisé).
4. **Annotation des Images** : Les images sont annotées avec des boîtes de détection et des labels pour chaque objet détecté. Les boîtes de

détection sont dessinées sur l'image avec des couleurs spécifiques (par exemple, vert pour une classe particulière et rouge pour les autres). Les labels incluent le nom de la classe et, si souhaité, le score de confiance associé à la détection. Cela permet de visualiser facilement les résultats de détection directement sur l'image.

3.4 L'architecture du modèle utilisé :YOLOv9

L'évolution de YOLOv9 est une avancée significative dans la technologie de détection d'objets en direct. YOLOv9 est la version la plus récente de YOLO, sorti en février 2024, il intègre le principe du goulot d'étranglement de l'information et les fonctions réversibles pour préserver les données cruciales à travers les couches du réseau. En utilisant l'information de gradient programmable (PGI), YOLOv9 garantit une génération de gradient plus fiable, permettant une meilleure convergence du modèle. De plus, son architecture inclut le réseau d'agrégation de couches efficace généralisé (GELAN), ce qui lui confère une utilisation efficace des paramètres et une efficacité de calcul supérieure sans compromettre la vitesse ou la précision. Ces avancées font de YOLOv9 un choix puissant pour la détection d'objets, même dans des modèles légers où la préservation des informations est particulièrement critique. [PBL⁺24]

J'ai choisi d'utiliser le modèle YOLOv9 pour la détection des mauvaises herbes en raison de ses améliorations significatives par rapport aux versions précédentes et autres modèles. En effet, YOLOv9 représente une avancée technologique notable dans divers domaines de la vision par ordinateur, surpassant ses prédécesseurs en termes de précision et d'efficacité. De plus, ce modèle n'a pas encore été testé dans le domaine spécifique de la détection des mauvaises herbes, ce qui offre une opportunité unique d'explorer son potentiel dans cette application. Pour maximiser ses performances, j'ai effectué un apprentissage par transfert en utilisant un modèle YOLOv9 préentraîné sur le dataset COCO [RM24], garantissant ainsi une base solide pour la détection précise des mauvaises herbes.

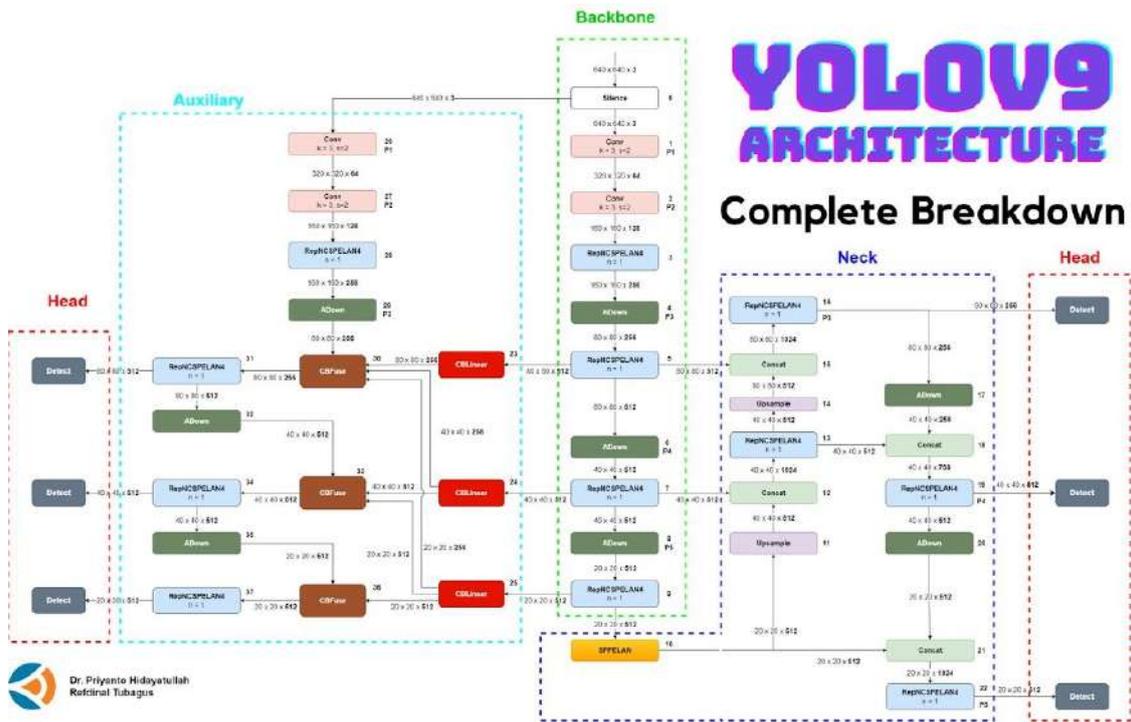


FIGURE 3.2 – Schéma général de l’architecture du modèle YOLOv9. [Hid24]

L’architecture est divisée en quatre parties principales : le Backbone, le Neck, le Head et le Auxiliary.

3.4.1 Backbone

Le Backbone est la première partie du réseau, responsable de l’extraction des caractéristiques de base de l’image d’entrée. Le Backbone sert à extraire des caractéristiques de base de l’image d’entrée. Il convertit l’image en une série de cartes de caractéristiques à différentes résolutions, capturant des informations essentielles telles que les contours, les textures et les formes. Voici les composants spécifiques :

1. **Conv (P1)** : Convolution avec un noyau de taille 3, stride de 2, et 64 canaux de sortie. Il permet de Réduire la taille de l’image de $640 \times 640 \times 3$ à $320 \times 320 \times 64$.
2. **Conv (P2)** : Convolution avec un noyau de taille 3, stride de 2, et 128 canaux de sortie. Il permet de Réduire la taille de l’image de $320 \times 320 \times 64$ à $160 \times 160 \times 128$.

3. **RepNCSP** : Bloc résiduel utilisant des convolutions séparables et normales, augmente les canaux à 256.
4. **ADown** : Downsampling pour réduire la taille spatiale tout en augmentant la profondeur des caractéristiques. Il permet de Réduire la taille à $80 \times 80 \times 256$.

Le processus du Backbone passe par trois étapes :

- **Convolutions Initiales (Conv P1 et P2)** : Ces couches réduisent la taille de l'image tout en augmentant le nombre de canaux de caractéristiques, ce qui permet de compresser l'information visuelle et de la rendre plus gérable pour les couches suivantes.
- **Blocs Résiduels (RepNCSP)** : Ils permettent d'extraire des caractéristiques plus profondes et plus complexes en utilisant des connexions résiduelles pour éviter le problème de gradient évanescent.
- **Downsampling (ADown)** : Réduit la résolution spatiale des cartes de caractéristiques tout en augmentant la profondeur des caractéristiques, ce qui permet de capturer des informations à une échelle plus globale.

3.4.2 Neck

Le Neck fusionne les caractéristiques extraites par le Backbone et prépare les cartes de caractéristiques pour le Head. Le Neck agit comme un pont entre le Backbone et le Head, combinant et raffinant les caractéristiques extraites par le Backbone. Il permet de fusionner des informations provenant de différentes échelles, améliorant ainsi la capacité du modèle à détecter des objets de différentes tailles. Voici ses composants :

- **RepNCSP** : Blocs résiduels ajoutant de la profondeur aux caractéristiques.
- **ADown** : Réduction de la résolution spatiale et augmentation de la profondeur.
- **Concat** : Concaténation des caractéristiques provenant de différentes résolutions.

- **Upsample** : Augmentation de la résolution spatiale des caractéristiques pour les fusionner avec les caractéristiques à plus haute résolution.
- **SPPELAN** : Blocs de pooling pyramidaux spatiaux pour capturer des caractéristiques à différentes échelles.

Le processus du Neck passe par quatre étapes :

- **Blocs Résiduels (RepNCSP)** : Affinent encore les caractéristiques en utilisant des connexions résiduelles, augmentant ainsi la robustesse et la profondeur des caractéristiques.
- **Concaténation (Concat)** : Combine des cartes de caractéristiques de différentes résolutions, ce qui permet de fusionner des informations détaillées et globales.
- **Upsampling (Upsample)** : Augmente la résolution des cartes de caractéristiques pour les fusionner avec des caractéristiques à haute résolution, ce qui est crucial pour détecter de petits objets.
- **Pooling Pyramidal Spatial (SPPELAN)** : Capture des informations à différentes échelles de manière plus efficace en utilisant plusieurs niveaux de pooling.

3.4.3 Head

Le Head est responsable des prédictions finales, y compris les boîtes englobantes, les classes d'objets et les scores de confiance. Il utilise les cartes de caractéristiques fournies par le Neck pour faire ces prédictions. Il effectue des prédictions à différentes échelles de résolution (par exemple, 80x80, 40x40, 20x20). Chaque couche de détection est conçue pour capturer des objets de tailles spécifiques, améliorant ainsi la précision de la détection d'objets variés. Il est structuré en trois niveaux de couches de détection principaux : 80 × 80, 40 × 40, 20 × 20 placées à différentes résolutions pour permettre la détection d'objets de différentes tailles.

3.4.4 Auxiliary

La branche auxiliaire aide à améliorer les performances globales du modèle en fournissant des sorties intermédiaires. Cela permet au modèle d'apprendre des caractéristiques plus riches et plus robustes en ajoutant des gradients supplémentaires lors de l'entraînement. Voici les composants :

- **Conv (P1)** : Convolution avec un noyau de taille 3, stride de 2, et 64 canaux de sortie. Elle permet de réduire la taille de l'image de $640 \times 640 \times 3$ à $320 \times 320 \times 64$.
- **Conv (P2)** : Convolution avec un noyau de taille 3, stride de 2, et 128 canaux de sortie. Elle permet de réduire la taille de l'image de $320 \times 320 \times 64$ à $160 \times 160 \times 128$.
- **RepNCSP** : Bloc résiduel, augmente les canaux à 256.
- **ADown** Downsampling pour réduire la taille spatiale tout en augmentant la profondeur des caractéristiques. Elle permet de réduire la taille à $80 \times 80 \times 256$.
- **CBFuse** : Fusion des caractéristiques de différentes résolutions.
- **CBLinear** : Convolutions linéaires pour ajuster les dimensions des caractéristiques.

Le processus d'Auxiliary passe par cinq étapes :

1. **Convolutions Initiales (Conv P1 et P2)** : Comme dans le Backbone, elles réduisent la taille de l'image et augmentent les canaux de caractéristiques.
2. **Blocs Résiduels (RepNCSP)** : Aident à affiner les caractéristiques intermédiaires.
3. **Downsampling (ADown)** : Réduit la résolution des cartes de caractéristiques tout en augmentant leur profondeur.
4. **Fusion des Caractéristiques (CBFuse)** : Combine des caractéristiques provenant de différentes couches pour enrichir la représentation des caractéristiques.

5. **Convolutions Linéaires (CBLinear)** : Ajustent les dimensions des caractéristiques pour les rendre compatibles avec les autres parties du réseau.

3.5 L'entraînement du modèle

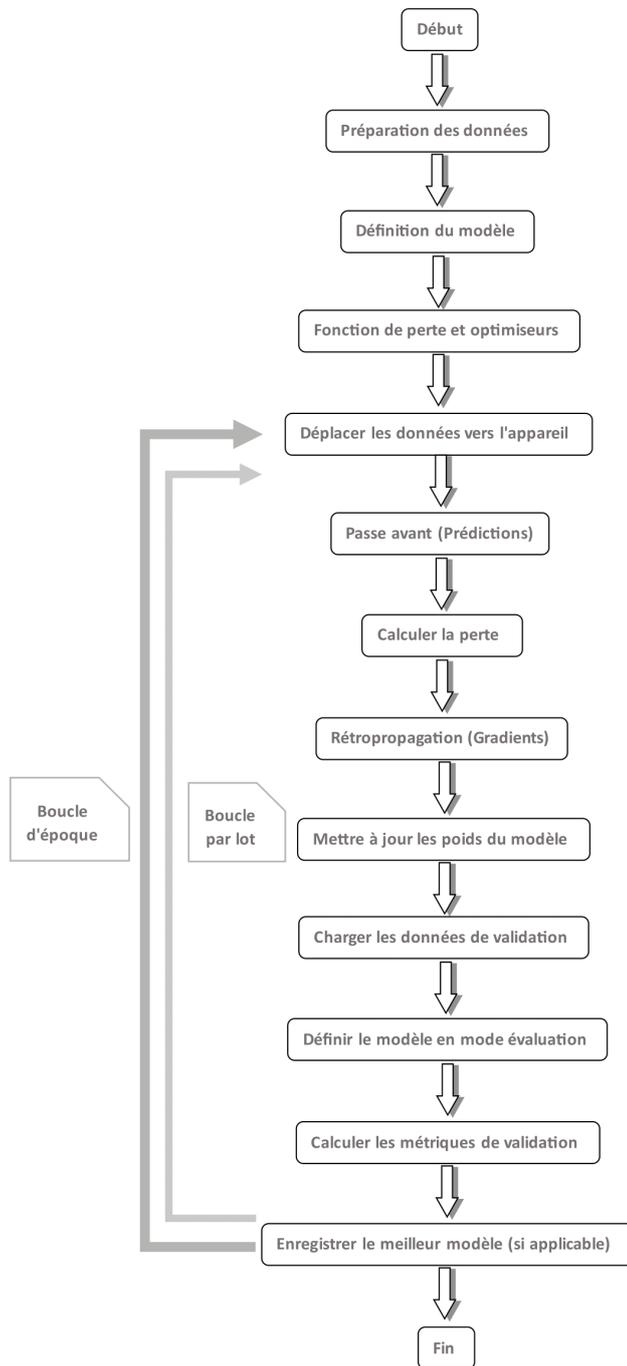


FIGURE 3.3 – Schéma général d'entraînement du modèle.

3.5.1 Préparation des données

- Chargez le jeu de données d'entraînement (un jeu de données personnalisé au format YAML).
- Prétraitez les images et les étiquettes en fonction des paramètres d'augmentation de données spécifiés.
- Créez un chargeur de données pour récupérer efficacement les lots de données pendant l'entraînement.

3.5.2 Définition du modèle

- Chargez l'architecture du modèle YOLOv9 à partir d'un fichier des poids fournis (weights/gelan-c.pt).
- Gelez des couches spécifiques du modèle pour l'apprentissage par transfert.
- Définissez la taille de les images d'entraînement et nombre des époques et lots.

3.5.3 Fonction de perte et optimiseurs

- Définissez la fonction de perte YOLOv9, qui comprend généralement des composants pour les coordonnées de la boîte englobante, l'objectivité et les probabilités de classe.
- Choisissez un optimiseur pour mettre à jour les poids du modèle (SGD : Stochastic Gradient Descent).

3.5.4 Boucle d'époque

Pour chaque époque :

- Initialisez le chargeur de données pour itérer sur les données d'entraînement.
- Définissez le modèle en mode entraînement (activation de la normalisation par lots et du décrochage).

- Initialisez une variable de perte en cours d'exécution pour suivre la perte moyenne par lot.

3.5.5 Boucle du lots

Pour chaque lot d'entraînement :

- Déplacez les images d'entrée et les étiquettes cibles vers le périphérique actif (CPU ou GPU).
- Transmettez les images via le modèle pour obtenir des prédictions.
- Calculez la perte en utilisant la fonction de perte définie et les prédictions.
- Accumulez la perte sur les lots en utilisant la variable de perte en cours d'exécution.
- Effectuez une propagation arrière pour calculer les gradients pour tous les paramètres entraînaibles.
- Mettez à jour les poids du modèle en utilisant l'optimiseur et les gradients accumulés.
- Réinitialisez la variable de perte en cours d'exécution pour le prochain lot.

3.5.6 Évaluation de l'époque

- Chargez le jeu de données de validation et préparez les lots.
- Définissez le modèle en mode évaluation (désactivation de la normalisation par lots et du décrochage).
- Initialisez des métriques comme la précision, le rappel et le mAP (Mean Average Precision).
- Pour chaque lot de validation :
 - Déplacez les images d'entrée et les étiquettes cibles vers le périphérique actif.
 - Transmettez les images via le modèle pour obtenir des prédictions.

- Calculez les métriques en fonction des prédictions et des étiquettes réelles.
- Mettez à jour les métriques de validation globales.

3.5.7 Fin de l'entraînement

- Après avoir terminé le nombre d'époques spécifié, le processus d'entraînement se termine.
- Enregistrez les poids du modèle entraîné finalement dans un fichier ou un répertoire spécifié.

3.6 Conclusion

Dans ce chapitre, nous avons proposé une approche pour la détection des mauvaises herbes en utilisant des techniques d'apprentissage profond et des drones. Nous avons commencé par l'étape de prétraitement, qui joue un rôle crucial dans la préparation des images pour l'inférence avec le modèle. Ensuite, l'étape d'inférence constitue le cœur du processus de détection d'objets. Après cela, l'étape de suppression non-maxima (NMS) intervient comme un post-traitement essentiel dans le processus de détection. Enfin, l'étape d'analyse et de traitement des résultats de détection clôture le processus de détection d'objets.

implémentation, Tests et Résultats

4.1 Introduction

Ce chapitre se concentre sur l'implémentation, les tests et les résultats du système de détection des mauvaises herbes en utilisant le modèle YOLOv9. Nous décrivons les configurations matérielles et logicielles, la préparation des données, et les métriques d'évaluation. Les performances du modèle sont analysées à travers des résultats qualitatifs et quantitatifs, montrant son efficacité et ses limitations dans des conditions réelles.

4.2 Paramétrage

Le paramétrage joue un rôle essentiel dans la configuration d'un système ou d'un logiciel. Dans le contexte de l'apprentissage en profondeur et l'entraînement du modèle YOLOv9, il est crucial de définir des valeurs appropriées pour les paramètres afin d'optimiser les performances du modèle. Examinons plus en détail les deux aspects du paramétrage : les arguments de ligne de commande et les hyperparamètres.

4.2.1 Arguments de ligne de commande

1. **-batch** : Cette option définit la taille du lot (batch size) utilisée pour l'entraînement. Dans cet exemple, la taille de lot est définie sur 16, ce qui signifie que le modèle sera entraîné sur 16 images à la fois avant de mettre à jour les poids du modèle.

2. **-epochs** : Cette option spécifie le nombre d'époques (epochs) pour l'entraînement. Une époque correspond à une itération complète sur l'ensemble des données d'entraînement. Dans cet exemple, le modèle sera entraîné pendant 25 époques.
3. **-img** : Cette option définit la taille des images d'entraînement et de validation en pixels. Ici, la taille est définie sur 640 pixels, ce qui signifie que toutes les images seront redimensionnées à 640x640 pixels avant d'être utilisées pour l'entraînement.
4. **-device** : Cette option spécifie l'appareil utilisé pour l'entraînement. Dans cet exemple, la valeur 0 correspond au premier GPU disponible sur la machine.
5. **-min-items** : Cette option détermine le nombre minimum d'objets (ou "items") requis dans une mosaïque (une composition d'images) pour qu'elle soit utilisée lors de l'entraînement. Ici, la valeur est définie sur 0, ce qui signifie qu'aucun minimum n'est requis et que toutes les mosaïques seront utilisées.
6. **-close-mosaic** : Cette option désactive l'augmentation des données de la mosaïque dans les dernières époques (N dernières époques) de l'entraînement. Dans cet exemple, la valeur est définie sur 0, ce qui signifie que l'augmentation des données de la mosaïque sera appliquée pendant toutes les époques.
7. **-data** : Cette option spécifie le chemin vers le fichier YAML du jeu de données. Ici, le chemin est défini sur /data/weed.yaml, qui contient les informations sur le jeu de données utilisé pour l'entraînement.
8. **-weights** : Cette option définit le chemin vers les poids initiaux pour l'entraînement. Dans cet exemple, le chemin est défini sur /weights/gelan-c.pt, qui contient les poids pré-entraînés utilisés comme point de départ pour l'entraînement.
9. **-cfg** : Cette option spécifie le chemin vers le fichier YAML du modèle. Ici, le chemin est défini sur models/detect/gelan-c.yaml, qui contient la configuration du modèle de détection d'objets.

10. **-hyp** : Cette option définit le chemin vers le fichier YAML des hyperparamètres. Dans cet exemple, le chemin est défini sur `hyp.scratch-high.yaml`, qui contient les valeurs des hyperparamètres utilisées pour l'entraînement.

4.2.2 Hyperparamètres

Paramètre	Description	Valeur
{lr0}	Taux d'apprentissage initial	0.001
{lrf}	Taux d'apprentissage final du scheduler OneCycleLR	0.01
{momentum}	Momentum pour l'optimiseur SGD	0.937
{weight-decay}	Décroissance des poids pour l'optimiseur	0.0005
{warmup-epochs}	Nombre d'époques de warmup	3.0
{warmup-momentum}	Momentum initial pendant le warmup	0.8
{warmup-bias-lr}	Taux d'apprentissage initial pour le biais pendant le warmup	0.1
{box}	Gain pour la perte des boîtes englobantes	8
{cls}	Gain pour la perte de la classification	0.5
{cls-pw}	Poids positif pour la perte de la classification (BCELoss)	1.0
{df1}	Gain pour la perte des objets	0.7
{obj-pw}	Poids positif pour la perte des objets	1.0
{df1}	Gain pour la perte DFL	1.5
{iou-t}	Seuil IoU pour l'entraînement	0.20
{anchor-t}	Seuil pour les multiples d'ancre	5.0
{fl-gamma}	Gamma pour la perte focalisée (focal loss)	0.0
{hsv-h}	Augmentation de la teinte (Hue) HSV de l'image	0.015
{hsv-s}	Augmentation de la saturation (Saturation) HSV de l'image	0.7
{hsv-v}	Augmentation de la valeur (Value) HSV de l'image	0.4
{degrees}	Rotation de l'image	0.0
{translate}	Translation de l'image	0.1
{scale}	Échelle de l'image	0.8
{shear}	Cisaillement de l'image	0.0
{perspective}	Perspective de l'image	0.0
{flipud}	Probabilité de retournement vertical de l'image	0.0.
{fliplr}	Probabilité de retournement horizontal de l'image	0.5
{mosaic}	Probabilité d'utilisation de la technique de mosaïque	1.0
{mixup}	Probabilité d'utilisation de la technique mixup	0.15
{copy-paste}	Probabilité d'utilisation du copier-coller pour les segments	0.3

TABLE 4.1 – Les Hyperparamètres et leurs valeurs

4.3 Outils Matériels

Les tests ont été réalisés sur un ordinateur portable utilisant Windows 10. Un processeur 11th Gen Intel(R) Core(TM) i3-1115G4 @ 3.00GHz

3.00GHz est utilisé dans cet ordinateur, ainsi que 12 Go de mémoire RAM et un système d'exploitation 64 bits, processeur x64. Nous avons employé le langage Python pour mettre en place les algorithmes dans l'environnement de développement Jupiter et Google Colab.

4.4 Outils Logiciels

4.4.1 Environnement de développement

Jupyter : Il s'agit d'un environnement interactif de développement web pour les notebooks, le code et les informations. Son interface flexible facilite la mise en place et l'utilisation des flux de travail dans les domaines de la science des données, du calcul scientifique, du journalisme computationnel et du machine learning. Grâce à sa structure modulaire, il est possible d'ajouter des extensions qui améliorent ses fonctionnalités. [[Jup](#)]

Google Colab : est un service cloud gratuit proposé par Google, qui repose sur Jupyter Notebook et est conçu pour la formation et la recherche dans le domaine de l'apprentissage automatique. Cette plateforme offre la possibilité de former des modèles de Machine Learning en utilisant le cloud. Ainsi, il n'est pas nécessaire d'installer quoi que ce soit sur notre ordinateur, à l'exception d'un navigateur.[[Le](#)]

4.4.2 Langage de programmation

Python : Python est un langage de programmation interprété, orienté objet et de haut niveau, doté de semantics dynamiques. Grâce à ses structures de data à haut niveau, avec une typographie dynamique et une connexion dynamique, il est extrêmement attrayant pour le développement rapide d'applications, ainsi que pour l'utilisation comme langage de script ou de connexion pour relier des composants existants. La syntaxe simple et facile à apprendre de Python met l'accent sur la lecture et donc réduit les coûts de maintenance du programme. Python admet des modules et des packages, ce qui favorise la modularité des programmes et la réutilisation du code.

L'interprète Python et la vaste bibliothèque standard sont disponibles en source ou en binaire gratuitement pour toutes les principales plateformes, et peuvent être partagés gratuitement. [\[Gui\]](#)

4.4.3 Description des bibliothèques utilisées

Matplotlib : Matplotlib, une bibliothèque de dessin utilisée pour les graphiques en 2D dans le langage de programmation Python. On peut l'utiliser dans des scripts Python, des serveurs web d'applications et d'autres outils d'interface graphique.

Il existe plusieurs boites a outils disponibles qui étendent la fonctionnalité de Python Matplotlib. Il y en a qui sont des téléchargements séparés, d'autres peuvent être livrés avec le code source matplotlib, mais ils ont des dépendances externes. [\[Edu19\]](#)

Numpy : est un acronyme de "Python en ligne". C'est une bibliothèque open source dans Python. Elle est employée dans le domaine de la programmation scientifique en Python, comme la Data Science, le génie, les mathématiques ou la science. [\[Dat\]](#)

Opencv-python : est une bibliothèque de vision par ordinateur qui est accessible en tant que bibliothèque open source. La bibliothèque est écrite en C et C++ et fonctionne sous Linux, Windows et Mac OS X. [\[BK08\]](#)

Pillow : est une bibliothèque d'imagerie Python qui ajoute des capacités de traitement d'images à votre interpréteur Python. C'est une branche du projet original Python Imaging Library (PIL) et est largement utilisée pour ouvrir, manipuler et sauvegarder différents formats d'image. [\[Pi123\]](#)

PyYAML : est une bibliothèque Python qui permet de lire et de générer des données YAML (YAML Ain't Markup Language). YAML est un format de sérialisation de données lisible par l'homme, souvent utilisé pour la configuration, la persistance des données et les échanges de données structurées. PyYAML fournit des fonctionnalités pour analyser des documents

YAML en structures de données Python (comme des dictionnaires et des listes) et pour convertir des structures de données Python en documents YAML.[PyY24]

Torch : est une bibliothèque open source de machine learning et d'apprentissage profond. Initialement développée par Facebook's AI Research lab (FAIR), elle est devenue un écosystème riche pour la recherche en intelligence artificielle. Torch fournit des modules et des outils pour construire et entraîner des réseaux de neurones profonds.[PyT]

scipy : SciPy est une bibliothèque Python qui étend les fonctionnalités de base de NumPy en fournissant un ensemble de modules dédiés à diverses tâches scientifiques et d'ingénierie. [Sci]

4.5 La base de données

Nous avons utilisé le dataset MFWD [MDR+24] pour détecter les mauvaises herbes. Ce dataset contient des images de différentes espèces de mauvaises herbes cultivées dans des champs de maïs et de sorghum en Allemagne. Les images sont annotées manuellement et divisées en micro-plots pour faciliter l'apprentissage automatique. Le dataset est disponible sur le Digital Library de la Technical University of Munich et comprend des images en format PNG et , ainsi que des fichiers CSV pour les bounding boxes et les informations de suivi JPEG[Tec].

EPPO Code	Nom botanique
ZEAMX	Lidea Palladium (Type de maïs)
ACHMI	Achillea millefolium
SOLNI	Solanum nigrum
AGRRE	Elymus repens
PLAMA	Plantago major
STEME	Stellaria media
ALOMY	Alopecurus myosuroides
ARTVU	Artemisia vulgaris
THLAR	Thlaspi arvense
CHEAL	Chenopodium album
SSYOF	Sisymbrium officinale
CIRAR	Cirsium arvense
MATCH	Matricaria chamomilla
GALAP	Galium aparine
CONAR	Convolvulus arvensis
GASPA	Galinsoga parviflora
ECHCG	Echinochloa crus-galli
PULDY	Pulicaria dysenterica
LAMAL	Lamium album
POAAN	Poa annua
POLCO	Fallopia convolvulus
POROL	Portulaca oleracea
SORVU	KWS Sammos
VIOAR	Viola arvensis
VEROF	Veronica officinalis

TABLE 4.2 – Tableau des codes EPPO (European and Mediterranean Plant Protection Organization) et des noms botaniques

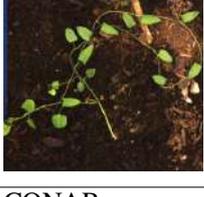


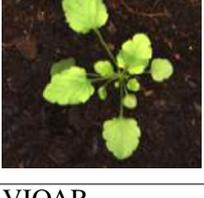
				
ACHMI	AGRRE	ALOMY	ARTVU	CHEAL
				
CIRAR	CONAR	ECHCG	GALAP	GASPA
				
LAMAL	MATCH	PLAMA	POAAN	POLCO
				
POROL	PULDY	SOLNI	SORVU	SSYOF
				
STEME	THLAR	VEROF	VIOAR	ZEAMX

TABLE 4.3 – Exemple de chaque espèce végétale avec le code OEPP correspondant.

Nous avons remarqué une grande différence entre le nombre d'images dans cette base de données, pour garantir la performance et la généralisation du modèle de détection basé sur cette base de données, nous avons entrepris d'équilibrer le nombre d'images pour chaque classe. L'équilibrage des données implique de s'assurer que chaque classe possède un nombre similaire d'exemples dans la base de données. Cela permet d'éviter un biais dans l'apprentissage du modèle, où des classes sur-représentées pourraient dominer l'apprentissage par rapport à des classes sous-représentées.

Class	Nombre d'images d'entraînement	Nombre d'images de test	Total
STEME	655	152	807
CONAR	660	150	810
THLAR	660	152	812
POROL	591	114	705
ACHMI	603	150	753
ALOMY	648	150	798
SSYOF	660	150	810
VEROF	621	139	760
GASPA	601	149	750
ECHCG	650	123	773
POAAN	604	150	754
ZEAMX	793	150	943
AGRRE	589	128	717
CHEAL	638	112	750
VIOAR	598	150	748
LAMAL	667	146	813
ARTVU	718	154	872
POLCO	258	63	321
SOLNI	635	135	770
MATCH	614	152	766
PLAMA	640	153	793
CIRAR	660	150	810
GALAP	653	150	803
SORVU	660	146	706
PULDY	663	152	815
Totale	15690	3630	19320

TABLE 4.4 – Nombre d'images du base de donnes par classes .

Pour la base de données Dataset (MFWD), les annotations sont stockées dans un fichier CSV, ce qui facilite leur manipulation et leur traitement. Ce fichier CSV contient les informations essentielles pour chaque annotation, telles que l'identifiant de la piste (`track_id`), l'identifiant de l'étiquette (`label_id`), l'identifiant de la boîte englobante (`bbox_id`), ainsi que les coordonnées `xmin`, `ymin`, `xmax` et `ymax` de chaque boîte englobante. De plus, il contient le nom du fichier correspondant à l'image annotée et l'identifiant du plateau (`tray_id`) auquel l'image appartient.

Pour préparer ces annotations dans un format compatible avec le modèle YOLO, nous avons suivi les étapes suivantes :

1. **Extraction des données d'annotation :** Nous avons extrait les informations nécessaires pour chaque annotation à partir du fichier CSV, notamment les coordonnées `xmin`, `ymin`, `xmax` et `ymax` des boîtes englobantes ainsi que les dimensions de l'image correspondante.
2. **Calcul des coordonnées du centre :** Nous avons calculé les coordonnées du centre de chaque boîte en utilisant les formules suivantes :

$$x_{\text{center}} = \frac{x_{\text{min}} + x_{\text{max}}}{2}, y_{\text{center}} = \frac{y_{\text{min}} + y_{\text{max}}}{2} \quad (4.1)$$

3. **Calcul des dimensions normalisées :** Nous avons calculé les dimensions de chaque boîte normalisées par rapport à la taille de l'image en utilisant les formules suivantes :

$$\text{width} = \frac{x_{\text{max}} - x_{\text{min}}}{\text{largeur de l'image}}, \text{height} = \frac{y_{\text{max}} - y_{\text{min}}}{\text{hauteur de l'image}} \quad (4.2)$$

4. **Enregistrement des annotations au format YOLO :** Enfin, les annotations de chaque image a été enregistrée dans un fichier texte avec le format YOLO. Chaque ligne de ce fichier comprend l'identifiant de classe de l'objet, les coordonnées normalisées du centre et les dimensions normalisées de la boîte.

4.6 Les métriques

4.6.1 Précision (Precision)

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

$$\text{Précision} = \frac{\text{Vrai Positifs (VP)}}{\text{Vrai Positifs (VP)} + \text{Faux Positifs (FP)}} \quad (4.3)$$

4.6.2 Rappel (Recall)

Le rappel est la proportion des prédictions positives correctes parmi toutes les instances positives réelles.

$$\text{Rappel} = \frac{\text{Vrai Positifs (VP)}}{\text{Vrai Positifs (VP)} + \text{Faux Négatifs (FN)}} \quad (4.4)$$

4.6.3 Mean Average Precision at IoU 0.5 (mAP@0.5)

mAP@0.5 est la moyenne de la précision moyenne (AP) calculée à un seuil d'Intersection over Union (IoU) de 0.5.

$$\text{mAP@0.5} = \frac{1}{N} \sum_{i=1}^N AP_{i,\text{IoU}=0.5} \quad (4.5)$$

où N est le nombre total de classes.

4.6.4 Mean Average Precision at IoU [0.5 :0.95] (mAP@[50 :95])

mAP@[50 :95] est la moyenne de la précision moyenne (AP) calculée sur plusieurs seuils d'IoU allant de 0.5 à 0.95 par pas de 0.05.

$$\text{mAP@[50 :95]} = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{10} \sum_{t=0.5}^{0.95} AP_{i,\text{IoU}=t} \right) \quad (4.6)$$

où N est le nombre total de classes, et t est chaque seuil d'IoU.

4.7 Résultats Qualitatifs

Pour évaluer la performance de notre modèle de détection des mauvaises herbes, nous l'avons testé sur une base de données provenant d'un champ de maïs contenant des mauvaises herbes [OSD⁺22], capturées par un drone. Ces images ont été sélectionnées pour représenter des scènes réalistes et variées, reflétant les conditions du monde réel auxquelles le modèle pourrait être confronté lors de son déploiement sur le terrain.

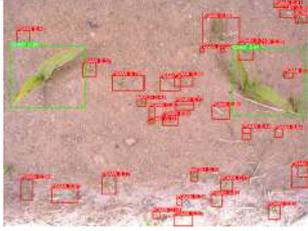
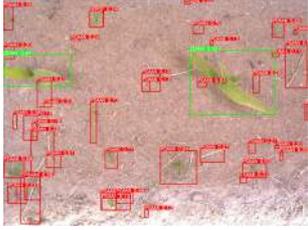
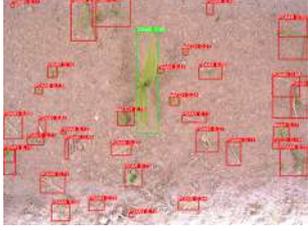
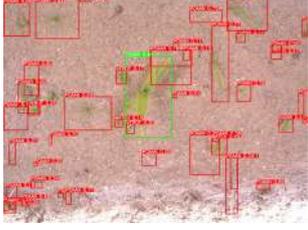
#	Image originale	Résultats de détection	Classes détectées
1			ZEAMX :2, ALOMY :2, MATCH :4, POAAN :11 .
2			ZEAMX :2, POAAN :10 , VIOAR :1, VERO :1 .
3			ZEAMX :1, MATCH :3, POAAN :17, VIOAR :2 .
4			ZEAMX :2, MATCH :5, ECHCG :1, POAAN :15, VIOAR :1, VERO :1 .
5			ZEAMX :1, MATCH :3, POAAN :17, VIOAR :3, VERO :3 .

TABLE 4.5 – Quelques résultats de la détection des mauvaises herbes.

4.8 Résultats Quantitatifs

Les résultats quantitatifs obtenus à partir du modèle YOLOv9 pour la détection des mauvaises herbes ont démontré une bonne précision, avec un taux de rappel élevé et des scores mAP-0.5 et mAP50-95 significatifs. Ces indicateurs témoignent de l'efficacité du modèle dans l'identification précise des mauvaises herbes, offrant ainsi une solution robuste et fiable pour la gestion agricole et la préservation des cultures.

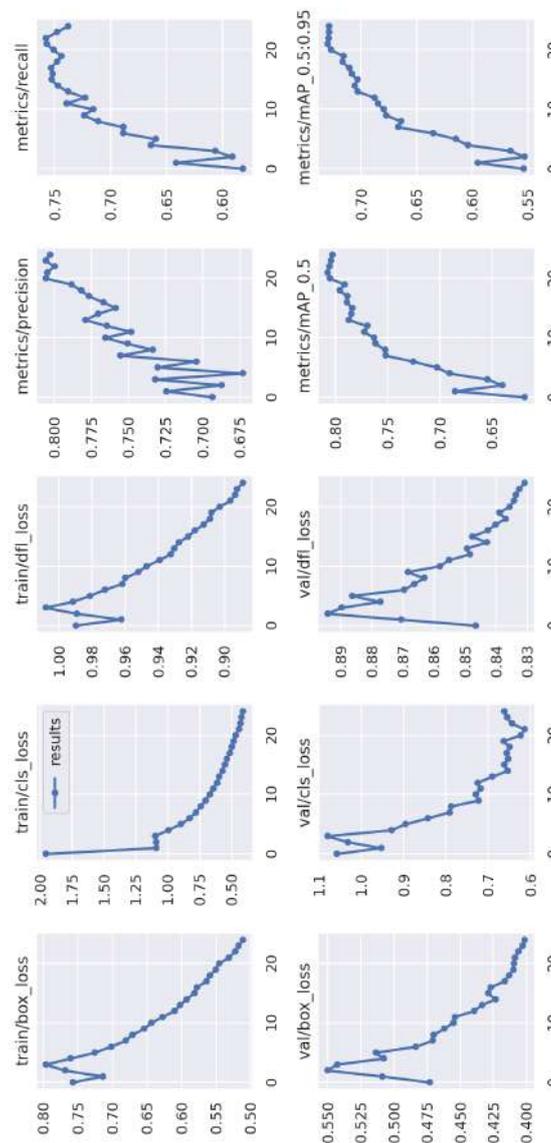


FIGURE 4.1 – Graphes du métrique entraînement et de validation.

Epoch	Precision	Rappel	mAP_0.5	mAP50-95
0	0.69339	0.58154	0.61874	0.55351
1	0.72446	0.64162	0.68586	0.595
2	0.68739	0.59134	0.64017	0.55274
3	0.73203	0.60617	0.65447	0.56548
4	0.67293	0.66402	0.69093	0.60394
5	0.73038	0.65955	0.70263	0.61481
6	0.70441	0.68885	0.72549	0.63532
7	0.75554	0.68876	0.75186	0.66664
8	0.73368	0.71127	0.75258	0.66401
9	0.75064	0.7239	0.76162	0.67727
10	0.76559	0.7153	0.76325	0.67946
11	0.74813	0.73915	0.77231	0.68468
12	0.76444	0.72285	0.76974	0.68776
13	0.77889	0.73814	0.78708	0.70324
14	0.7705	0.74709	0.78476	0.70553
15	0.7586	0.75291	0.78419	0.70314
16	0.76694	0.75168	0.78891	0.70828
17	0.77648	0.75306	0.78876	0.71048
18	0.78181	0.74809	0.79605	0.71656
19	0.78838	0.74388	0.79143	0.71564
20	0.80563	0.7509	0.80538	0.72715
21	0.81652	0.7746	0.8258	0.74712
22	0.79989	0.75793	0.80599	0.72934
23	0.80561	0.7478	0.80446	0.72865
24	0.80284	0.7382	0.8028	0.72869

TABLE 4.6 – Table du métrique du validation

l'évaluation a révélé que l'époque 21 se distinguait comme la plus performante. Cette époque a généré de très bon résultats, dépassant les attentes en termes de précision, de rappel, et de scores mAP-0.5 et mAP50-95 voici les résultats par classes :

Class	Précision	Rappel	mAP50	mAP50-95
all	0.816	0.774	0.825	0.747
ZEAMX	0.976	0.971	0.979	0.964
ACHMI	0.977	0.499	0.751	0.695
SOLNI	0.518	0.85	0.658	0.612
AGRRE	0.86	0.745	0.818	0.624
PLAMA	0.989	0.881	0.936	0.887
STEME	0.58	0.565	0.609	0.517
ALOMY	0.816	0.713	0.78	0.66
ARTVU	0.903	0.627	0.802	0.705
THLAR	0.811	0.585	0.703	0.656
CHEAL	0.463	0.634	0.598	0.532
SSYOF	0.982	0.978	0.995	0.992
CIRAR	0.877	0.856	0.883	0.766
MATCH	0.755	0.525	0.747	0.653
GALAP	0.465	0.892	0.714	0.65
CONAR	0.952	0.917	0.966	0.868
GASPA	0.827	0.697	0.754	0.706
ECHCG	0.951	0.961	0.976	0.813
PULDY	0.567	0.933	0.885	0.83
LAMAL	0.932	0.912	0.953	0.932
POAAN	0.894	0.809	0.883	0.68
POLCO	0.655	0.905	0.882	0.804
POROL	0.957	0.732	0.886	0.785
SORVU	0.994	0.947	0.983	0.918
VIOAR	0.91	0.771	0.928	0.866
VEROF	0.75	0.696	0.769	0.745

TABLE 4.7 – Résultats de détection des mauvaises herbes par classe

4.9 Conclusion

Les résultats montrent que l'utilisation de l'intelligence artificielle, en particulier le modèle YOLOv9, est efficace pour la détection des mauvaises herbes. Le système a démontré une grande précision, malgré certaines limitations. Ces résultats prometteurs indiquent que l'IA peut améliorer la gestion des mauvaises herbes, offrant des perspectives pour une agriculture plus efficace et durable.

Conclusion générale

Cette étude a exploré l'application de l'intelligence artificielle pour la détection et la gestion des mauvaises herbes en agriculture, avec une mise en œuvre spécifique du modèle YOLOv9. Les résultats obtenus montrent que le modèle est capable de détecter et de classer efficacement les mauvaises herbes, même dans des environnements variés. Les performances du système ont été évaluées à l'aide de diverses métriques, démontrant une précision élevée et une robustesse dans les conditions de test. Les résultats positifs de cette étude mettent en lumière le potentiel considérable de l'IA pour révolutionner la gestion des mauvaises herbes. En permettant une détection plus rapide et plus précise, l'utilisation de systèmes basés sur l'IA peut réduire la dépendance aux herbicides chimiques, favorisant ainsi une agriculture plus durable et respectueuse de l'environnement. De plus, cette technologie offre aux agriculteurs un outil puissant pour optimiser les rendements et améliorer la qualité des cultures.

Malgré les résultats prometteurs, certaines limitations ont été identifiées, notamment la performance du modèle dans des conditions de luminosité changeante et sur des cultures très denses. Pour surmonter ces défis, des recherches futures pourraient se concentrer sur l'intégration de techniques d'augmentation des données, l'amélioration des algorithmes de détection et l'utilisation de capteurs complémentaires. De plus, l'exploration de modèles hybrides combinant plusieurs approches d'IA pourrait offrir des solutions encore plus robustes.

L'adoption de l'IA pour la gestion des mauvaises herbes a le potentiel d'avoir un impact significatif sur les pratiques agricoles, en réduisant les coûts et les impacts environnementaux associés aux méthodes traditionnelles. En favorisant des pratiques agricoles plus durables, cette technologie peut contribuer à la sécurité alimentaire mondiale et à la protection des ressources naturelles. En conclusion, cette étude montre que l'intelligence artificielle est une voie prometteuse pour améliorer la gestion des mauvaises herbes et soutenir le développement d'une agriculture plus efficace et durable.

Bibliographie

- [AA22] Sahili Z. Al and M. Awad. The power of transfer learning in agricultural applications : Agrinet. *Front. Plant Sci.*, 13, 2022.
- [AB19] Hanane Abdelmalek and Kamel Boussafi. La contribution du secteur agricole à la diversification des exportations en algérie : Cas de la filière des dattes (1995-2017). [*In French*], 06 2019.
- [Alg23] Bank Of Algeria. Rapport annuel 20/22 evolution economique et onetaire. Technical report, Bank Of Algeria, 2023.
- [Ban24] World Bank. Agriculture, value added (% of gdp), 01 2024. <https://donnees.banquemondiale.org/indicateur/NV.AGR.TOTL.CD>, Dernier accès au site :06/06/2024.
- [Bat23] Eria Bataire. Weed control in agriculture : Classifications, downsides, and benefits. *Bivatec Blog*, 2023. <https://www.bivatec.com/blog/weed-control-and-management-in-agriculture>, Dernier accès au site : 03/05/2024.
- [Bes04] Omar Bessaoud. L'agriculture et la paysannerie en algerie. *Communication au Symposium*, septembre 2004.
- [BK08] Gary Bradski and Adrian Kaehler. Learning opencv, 2008. <https://www.bogotobogo.com/cplusplus/files/OReilly%20Learning%20openCV.pdf>, Dernier accès :

28/05/2024.

[Bru17] Donatini Bruno. La méthode bayésienne pour aider à évaluer l'efficacité des thérapies personnalisées. *Revue Hegel*, 18, February 2017.

[Dat] DataScientest. Numpy : The python library in data science. <https://datascientest.com/en/numpy-the-python-library-in-data-science>, Dernier accès : 28/05/2024.

[Dat20] DataScientest. Convolutional neural network. *DataScientest*, Juin 2020. <https://datascientest.com/convolutional-neural-network>.

[Dat23] DataScientest. Generative adversarial network. *DataScientest*, May 2023. <https://datascientest.com/generative-adversarial-network-tout-savoir> Dernier accès au site : 06/06/2024.

[Dat24] DataScientest. Régression linéaire. *DataScientest*, March 2024. <https://datascientest.com/regression-lineaire-tout-savoir>, Dernier accès au site = 06/06/2024.

[Dig24] Le Digitaliseur. Le futur de l'ia : Les réseaux antagonistes génératifs. *Le Digitaliseur*, February 2024. <https://ledigitaliseur.fr/ia/reseaux-antagonistes-generatifs/>, Dernier accès au site : 06/06/2024.

[Dje17] Abdelkader Djermoun. La production céréalière en algérie : les principales caractéristiques. *ResearchGate*, March 2017.

[dN22a] Journal du Net. Le random forest ou forêt aléa-

toire . *Journal du Net*, May 2022. <https://www.journaldunet.fr/intelligence-artificielle/guide-de-l-intelligence-artificielle/1501905-random-forest-ou-foret-aleatoire/>, Dernier accès au site :06/06/2024.

[dN22b] Journal du Net. Machine à vecteurs de support (svm) : définition et cas d'usage. *Journal du Net*, January 2022. <https://www.journaldunet.fr/intelligence-artificielle/guide-de-l-intelligence-artificielle/1501879-machine-a-vecteurs-de-support-svm-definition-et-cas-> Dernier accès au site :06/06/2024.

[ECZ⁺19] J Eshraghian, H Cho, R Zheng, O Kavehei, S.K Kang, D Abbott, and J.S Seo. A survey on lstm memristive neural network architectures and applications. *ResearchGate*, 14, May 2019.

[Edu19] Edureka. Python matplotlib tutorial, June 2019. <https://medium.com/edureka/python-matplotlib-tutorial-15d148a7bfee>, Dernier accès : 28/05/2024.

[GRD⁺23] Ignazio Gallo, Anwar Ur Rehman, Ramin Heidarian Dehkordi, Nicola Landro, Riccardo La Grassa, and Mirco Boschetti. Deep object detection of crop weeds : Performance of yolov7 on a real case dataset from uav images. *Remote Sensing*, 15 :539, 2023.

[Gui] Guido van Rossum. Python : Programming for the future. <https://www.python.org/doc/essays/blurb/>, Dernier accès : 28/05/2024.

[Gui20] IONOS Digital Guide. Les différences entre le deep learning et le machine learning. *IONOS Digital Guide*,

- May 2020. <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/deep-learning-vs-machine-learning/>, Dernier accès au site :06/06/2024.
- [HAY22] Mohammed Habib, Tannouche Adil, and Ounejjar Youssef. Weed detection in pea cultivation with the faster rcnn resnet 50 convolutional neural network. *Revue d'Intelligence Artificielle*, 36, 2022.
- [Hid24] Priyanto Hidayatullah. Image de youtube, 2024. <https://i.ytimg.com/vi/oZ6I1VHpil0/maxresdefault.jpg>, Dernier accès : 28/05/2024.
- [HM21] Anul Haq Mohd. Cnn based automated weed detection system using uav imagery. *Computer Systems Science and Engineering*, 13, 2021.
- [IBMa] IBM. Qu'est-ce que l'algorithme de forêt aléatoire (random forest)? *IBM*. <https://www.ibm.com/fr-fr/topics/random-forest>, Dernier accès au site :06/06/2024.
- [IBMb] IBM. Qu'est-ce qu'un arbre de décisions ibm. *IBM*. <https://www.ibm.com/fr-fr/topics/decision-trees>, Dernier accès au site :06/06/2024.
- [Inn24] Innovatiana. Yolo : un véritable détecteur d'objets en temps réel. *Innovatiana*, Mars 2024. <https://www.innovatiana.com/post/what-is-yolo-in-ai>, Dernier accès au site :06/06/2024.
- [Int24] Mordor Intelligence. Analyse de la taille et de la part du marché agricole algérien - rapport de recherche de l'industrie - tendances de croissance. *Mordor Intelligence*, April 2024. <https://www.mordorintelligence.com/>

<fr/industry-reports/agriculture-in-algerie>, Dernier accès au site : 01/05/2024.

[JDXZ24] Li Jiajia, Chen Dong, Yin Xiang, and Li Zhen. Performance evaluation of semi-supervised learning frameworks for multi-class weed detection. *arXiv preprint arXiv :2403.03390*, 2024.

[JSRA16] Redmon Joseph, Divvala Santosh, Girshick Ross, and Farhadi Ali. You only look once : Unified, real-time object detection. *arXiv preprint arXiv :1506.02640*, May 2016. <http://pjreddie.com/yolo/>, Dernier accès au site :06/06/2024.

[Jup] Jupyter Project. Jupyter. <https://jupyter.org/>, Dernier accès : 28/05/2024.

[KGPR17] He Kaiming, Gkioxari Georgia, Dollar Piotr, and Girshick Ross. Mask r-cnn. *arXiv preprint arXiv :1703.06870*, 2017.

[Le] Le Data Scientist. Google colab : Le guide ultime. <https://ledatascientist.com/google-colab-le-guide-ultime/#:~:text=C'est%20quoi%20Google%20Colab,Learning%20directement%20dans%20le%20cloud>, Dernier accès : 28/05/2024.

[Ler10] Ph. Leray. Réseaux bayésiens : Apprentissage et diagnostic de systèmes complexes. *Modélisation et simulation*, 96, May 2010.

[MDR⁺24] Slukova Marketa, Karhade Daniel, Sanders Robert, Teixeira-Poit Stephanie, Toombs Austin, and Bruff Derek. Efficient methodology for constructing a sustainable learning analytics ecosystem in higher education. *Scientific Data*, 11(1) :1–13, 2024.

[Nat22] United Nations. Développement économique. *FAO*, 2022.

<https://news.un.org/fr/story/2022/12/1130532>,
Dernier accès au site :06/06/2024.

[OCT21] OCTO. You only look once - un réseau de neurones pour la détection d'objets. *OCTO Talks*, August 2021. <https://blog.octo.com/you-only-look-once-un-reseau-de-neurones-pour-la-detection->
Dernier accès au site :06/06/2024.

[OSD⁺22] Olayemi Olaniyi, Muhammadu Salaudeen, Emmanuel Daniya, Ibrahim Mohammed Abdullahi, Taliha Abiodun Folorunso, Jibril Bala, Nuhu Bello Kontagora, Adeyinka Adedigba, Blessing Oluwole, Odunayo Macarthy, and Abdullah Bankole. Maize-weed image dataset, 2022. <https://data.mendeley.com/datasets/jjbfckrsp/2>,
Dernier accès au site :06/06/2024.

[PBL⁺24] Xuangbin Peng, Shuo Bai, Yifei Liu, Kai Zou, and Xiaolin Tang. Yolov9 : Learning what you want to learn using programmable gradient information. *arXiv preprint arXiv :2402.13616*, 02 2024.

[Pen07] PennStat. Introduction to weeds and herbicides. Technical report, PennStat, 2007.

[PG09] Rick Peterson and Stephen Green. Keys to successful family functioning : Family roles. *Virginia Cooperative Extension*, May 2009.

[Pil23] Pillow Development Team. Pillow documentation, 2023. <https://pillow.readthedocs.io/en/stable/>,
Dernier accès : 28/05/2024.

[PyT] PyTorch Team. Pytorch. <https://pytorch.org/>,
Dernier accès : 28/05/2024.

- [PyY24] PyYAML Development Team. Pyyaml, Dernier accès : 28/05/2024. <https://pyyaml.org/wiki/PyYAML>.
- [RM24] Roboflow and Microsoft. Coco dataset. *Roboflow Universe*, June 2024. <https://universe.roboflow.com/microsoft/coco/dataset/18/download/yolov9>, Dernier accès : 28/05/2024.
- [Rus19] H. Russello. Crop yield prediction using deep neural networks. *Frontiers in Plant Science*, 10 :621, 2019.
- [Sci] SciPy Developers. Scipy. <https://scipy.org/>, Dernier accès : 28/05/2024.
- [SCSW23] Daniel Steininger, Gerardus Croonen, Julia Simon, and Verena Widhalm. The cropandweed dataset : a multi-modal learning approach for efficient crop and weed manipulation. In *2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2023.
- [Tec] Technical University of Munich. Technical university of munich data service. <https://dataserv.ub.tum.de/index.php/s/m1717366/>, Dernier accès : 28/05/2024.
- [WPC⁺22] Aichen Wang, Tao Peng, Huadong Cao, Yifei Xu, Xinhua Wei, and Bingbo Cui. Tia-yolov5 : An improved yolov5 network for real-time detection of crop and weed in the field. *Frontiers in Plant Science*, 13, 2022.
- [WTL⁺22] Pei Wang, Yin Tang, Fan Luo, Lihong Wang, Chengsong Li, Qi Niu, and Hui Li. Weed25 : A deep learning dataset for weed identification. *Frontiers in Plant Science*, 13, 2022.
- [ZGZ⁺23] J. Zhang, J. Gong, Y. Zhang, K. Mostafa, and G. Yuan. Weed identification in maize fields based on improved swin-unet.

Agronomy, 13(7) :1846, 2023.

Annexe start-up

A Présentation du projet

A.1 Idée du projet

Le projet s'inscrit dans le domaine agricole, avec une application moderne combinant les technologies de l'intelligence artificielle et des drones. Ce système innovant vise à améliorer les pratiques agricoles en automatisant la détection et le traitement des mauvaises herbes.

L'idée a germé en observant les défis auxquels sont confrontés les agriculteurs dans la gestion des mauvaises herbes, qui sont souvent traitées de manière inefficace et coûteuse. La volonté de réduire l'utilisation excessive d'herbicides et d'augmenter les rendements agricoles a conduit au développement de ce projet.

Pour cela, nous allons créer un système de détection précoce des mauvaises herbes utilisant des drones équipés de caméras haute résolution. Ces drones survoleront les champs et collecteront des données visuelles qui seront analysées par un algorithme d'intelligence artificielle capable d'identifier les mauvaises herbes avec une grande précision. Une fois les mauvaises herbes détectées, les drones pulvériseront de manière ciblée des herbicides appropriés sur les zones concernées.

L'équipe du projet comprendra des ingénieurs spécialisés en drones, des experts en intelligence artificielle, ainsi que des agronomes. Chaque membre de l'équipe jouera un rôle crucial dans le développement, la mise en œuvre et le perfectionnement du système.

A.2 Les valeurs proposées

Modernité Notre système de détection précoce des mauvaises herbes représente une solution novatrice qui n'existait pas auparavant dans le domaine agricole. En utilisant des drones et l'intelligence artificielle, nous offrons une approche entièrement nouvelle pour la gestion des mauvaises herbes, remplaçant les méthodes traditionnelles et inefficaces.

Performance Le système offre une performance supérieure en détectant et en traitant les mauvaises herbes avec une précision inégalée. Les drones équipés de capteurs avancés et les algorithmes d'IA assurent une identification rapide et exacte des zones infestées, surpassant les attentes des clients en termes d'efficacité et de résultats.

Flexibilité Notre solution est hautement flexible, permettant des ajustements en fonction des besoins spécifiques des clients. Que ce soit pour différents types de cultures, de terrains, ou de conditions climatiques, le système peut être adapté pour répondre aux exigences variées des agriculteurs.

Accomplissement de Tâches Le système aide les agriculteurs à accomplir des tâches spécifiques telles que la surveillance continue des champs, l'identification des mauvaises herbes et l'application précise d'herbicides. Cela permet aux agriculteurs de se concentrer sur d'autres aspects importants de la gestion de leurs exploitations.

Conception La conception du système est pensée pour être intuitive et adaptée au contexte des utilisateurs finaux. Les drones et les interfaces de contrôle sont faciles à utiliser, même pour ceux qui n'ont pas une expertise technique poussée, répondant ainsi aux attentes des agriculteurs en termes de simplicité et de convivialité.

Réduction des Coûts En optimisant l'utilisation des herbicides et en réduisant les interventions manuelles, le système permet de diminuer significativement les coûts de production. Cela se traduit par une réduction des prix de vente des produits agricoles, offrant ainsi une valeur économique substantielle aux clients.

Réduction des Risques Le système réduit l'exposition aux risques liés à l'utilisation excessive de produits chimiques. En appliquant les herbicides de manière ciblée et contrôlée, il minimise les impacts environnementaux et sanitaires, sécurisant ainsi les clients et leurs cultures.

Accessibilité En mettant à disposition cette technologie avancée, nous rendons des solutions de gestion des mauvaises herbes accessibles à des agriculteurs qui n'y avaient pas accès auparavant. Cela inclut des petites exploitations et des zones rurales éloignées, démocratisant ainsi l'accès à l'innovation technologique.

Facilité d'Utilisation Le système est conçu pour être simple et pratique à utiliser. Les interfaces utilisateur sont conviviales et les drones fonctionnent de manière autonome après une programmation initiale. Cela permet aux agriculteurs de bénéficier de la technologie sans nécessiter de formation complexe, rendant l'expérience plus agréable et efficace.

A.3 Équipe de travail

- **Moumene Hadil** : Responsable du développement et de l'implémentation du système de détection des mauvaises herbes par drone.
- **Pr. Farou Brahim** : Responsable de la gestion de projet et de la coordination globale. Supervise l'ensemble du projet, assure la liaison avec les parties prenantes, gère les ressources et veille au respect des délais et des objectifs du projet.
- **Mr. Boudjelida Hamoud** : Directeur de l'institut de technologies agricoles de Guelma, partenaire socio-économique et expert dans

l'agriculture.

A.4 Objectifs du projet

Notre objectif est de devenir le leader dans le domaine des systèmes de détection précoce des mauvaises herbes utilisant l'intelligence artificielle et les drones dans les cinq premières années.

A.5 Calendrier de mise en oeuvre du projet

Étape	1m	2m	3m	4m	5m	6m	7m	8m
Études préliminaires	✓	✓						
Développement de l'algorithme		✓	✓					
Développement du logiciel			✓	✓				
Intégration et tests sur le terrain					✓			
Phase pilote					✓	✓		
Déploiement						✓	✓	
Marketing et promotion							✓	✓

B Aspects innovants

L'intégration de l'intelligence artificielle et des drones pour la gestion des mauvaises herbes représente une rupture radicale avec les pratiques agricoles conventionnelles, qui reposent sur des méthodes manuelles ou des traitements généralisés. Ainsi, ce projet crée un nouveau segment de marché pour les technologies agricoles de précision. Le projet adopte une approche progressive, avec des améliorations continues basées sur les retours des utilisateurs et les avancées technologiques. Les mises à jour régulières du logiciel et du matériel permettent de maintenir la pertinence et l'efficacité du système.

C Analyse stratégique du marché

C.1 Présentation du secteur de marché

Dans l'Algérie le secteur agricole occupe la troisième place parmi les secteurs économiques en Algérie, il contribue à hauteur de 12,4% au produit

intérieur brut, avec une valeur de 25 milliards de dollars par an, il a pu réaliser une croissance moyenne au cours de la dernière décennie qui a atteint 2,7%, tout en couvrant les besoins alimentaires du pays à 73%.

L'agriculture intelligente est en plein essor, principalement en raison de la nécessité croissante de solutions innovantes pour améliorer l'efficacité des cultures et réduire les coûts. Les technologies de détection et de gestion des mauvaises herbes, en particulier, jouent un rôle crucial dans cette dynamique, offrant des avantages significatifs en termes de durabilité et de rentabilité pour les agriculteurs.

Caractéristiques du marché :

- **Croissance rapide :** Le marché de l'agriculture intelligente connaît une expansion rapide grâce à l'adoption croissante de technologies avancées.
- **Demande accrue :** Les agriculteurs cherchent des solutions pour améliorer la gestion des mauvaises herbes, réduire l'utilisation des herbicides, et minimiser l'impact environnemental.
- **Technologies émergentes :** Les drones et les systèmes d'intelligence artificielle deviennent des outils essentiels pour l'agriculture moderne.

Segments de marché clés :

- **Petits agriculteurs :** Intéressés par des solutions abordables et efficaces pour leurs petites parcelles.
- **Moyennes exploitations :** Recherchent des technologies qui offrent une bonne couverture et des services supplémentaires.
- **Grandes exploitations et coopératives :** Nécessitent des solutions complètes pour la gestion de vastes terrains agricoles.

C.2 Mesurer l'intensité de la concurrence

Le marché de la détection des mauvaises herbes par drone est marqué par une concurrence modérée à élevée, avec plusieurs entreprises offrant

des solutions similaires.

Principaux concurrents :

- **Solutions manuelles et semi-automatisées :** Bien qu'abordables, elles nécessitent plus de main-d'œuvre et sont moins précises.
- **Technologies de capteurs au sol :** Efficaces mais manquant de mobilité comparé aux drones.
- **Autres systèmes de drones :** Bien que compétitifs, certains n'offrent pas l'intégration complète de la détection et de la pulvérisation.

Analyse des forces concurrentielles :

- **Barrières à l'entrée :** Les coûts de développement et la complexité technologique peuvent dissuader de nouveaux entrants.
- **Pouvoir de négociation des clients :** Les clients peuvent exiger des solutions à la fois efficaces et économiques.
- **Rivalité entre les entreprises existantes :** Les entreprises innovent continuellement pour se démarquer sur le marché.

C.3 Stratégies marketing

Pour maximiser notre pénétration de marché et attirer notre public cible, nous mettrons en œuvre une stratégie d'abonnement saisonnier avec des offres adaptées à différents besoins et budgets.

Offres d'abonnement :

- **Offre de Base :**
 - **Prix :** Faible
 - **Nombre d'applications :** 1 application par saison
 - **Caractéristiques :** Convient aux petits agriculteurs, offrant une détection et pulvérisation basiques.
- **Offre Standard :**

- **Prix** : Moyen
- **Nombre d'applications** : 3 applications par saison
- **Caractéristiques** : Adaptée aux exploitations de taille moyenne, incluant support technique et rapports détaillés.
- **Offre Premium** :
 - **Prix** : Élevé
 - **Nombre d'applications** : Applications illimitées par saison
 - **Caractéristiques** : Idéale pour les grandes exploitations, avec support technique prioritaire et analyses avancées.

Stratégies de communication :

1. Marketing digital :

- Développer un site web informatif avec des détails sur les offres, études de cas et témoignages clients.
- Utiliser SEO et SEM pour attirer du trafic qualifié.
- Utiliser les réseaux sociaux pour engager la communauté agricole et partager des démonstrations et offres.

2. Événements et salons agricoles :

- Participer à des foires agricoles pour présenter notre technologie.
- Organiser des démonstrations en direct pour montrer l'efficacité de notre système.

3. Partenariats stratégiques :

- Collaborer avec des coopératives et distributeurs d'équipements agricoles.
- Offrir des commissions ou des remises pour les références.

Stratégies de vente :

1. Offres promotionnelles :

- Proposer des essais gratuits ou à prix réduit.
- Offrir des remises pour les abonnements à long terme ou en groupe.

2. Développement d'un réseau de distribution :

- Établir des partenariats avec des distributeurs locaux et revendeurs spécialisés.

3. Service après-vente et support technique :

- Offrir un support technique réactif et de qualité.
- Fournir des formations et ressources en ligne.
- Mettre en place des enquêtes de satisfaction pour améliorer continuellement notre service.

C.4 Analyse des Clients

Nos clients potentiels comprennent :

- **Agriculteurs individuels** : Recherchent des moyens efficaces de gérer les mauvaises herbes pour augmenter leurs rendements.
- **Coopératives agricoles** : Visent à offrir des solutions rentables et efficaces à leurs membres.
- **Entreprises de gestion agricole** : Besoin de technologies de précision pour fournir des services de gestion des cultures de haute qualité.
- **Organisations gouvernementales et ONG** : Promouvoir des pratiques agricoles durables et soutenir les innovations technologiques.

D Plan de production et d'organisation

D.1 Processus de production

Le processus de production de notre système de détection des mauvaises herbes par drone, basé sur l'acquisition de drones existants et l'intégration de notre système de détection, comprend les étapes suivantes :

Acquisition de drones :

- **Sélection des fournisseurs :** Identification et sélection des fournisseurs de drones équipés de systèmes de pulvérisation fine.
- **Achat des drones :** Négociation des contrats et achat des drones.

Développement logiciel :

- **Programmation :** Développement du logiciel de traitement d'image pour la détection des mauvaises herbes.
- **Intégration :** Intégration du logiciel avec les systèmes de contrôle du drone et les applications utilisateur.

Installation du système :

- **Montage du système de détection :** Installation de notre système de détection sur les drones achetés.
- **Configuration logicielle :** Installation et configuration des logiciels de détection et de contrôle sur les drones.

Tests et validation :

- **Tests en laboratoire :** Test des drones et des logiciels dans des conditions contrôlées pour s'assurer de leur précision et de leur fiabilité.
- **Tests sur le terrain :** Essais sur le terrain pour évaluer les performances en conditions réelles et effectuer des ajustements nécessaires.

Mise en service et support :

- **Formation des utilisateurs :** Formation des agriculteurs à l'utilisation des drones et des logiciels.
- **Support technique :** Offre de support technique continu pour résoudre les problèmes et optimiser l'utilisation du système.

D.2 Matières premières

Les matières premières et composants nécessaires pour l'intégration de notre système de détection sur les drones achetés comprennent :

Composants électroniques :

- **Capteurs d'image :** Capteurs haute résolution pour la capture précise d'images aériennes.
- **Modules de communication :** Dispositifs pour la transmission des données entre le drone et l'ordinateur de traitement.

Logiciels :

- **Algorithmes de détection :** Développement de logiciels spécialisés pour l'analyse des images et la détection des mauvaises herbes.
- **Systèmes de contrôle :** Logiciels pour la navigation et le contrôle des drones.

D.3 Ressources humaines

Notre équipe pluridisciplinaire comprend des professionnels qualifiés dans divers domaines pour assurer le succès de notre projet :

Équipe de développement :

- **Ingénieurs en systèmes embarqués :** Spécialisés dans l'intégration des capteurs et des logiciels sur les drones.

- **Développeurs logiciels** : Experts en programmation et en développement d'algorithmes de détection.

Équipe de production :

- **Techniciens d'intégration** : Responsables de l'installation et de la configuration des systèmes de détection sur les drones.
- **Spécialistes en contrôle de qualité** : Chargés d'effectuer des tests et des inspections pour garantir la qualité des produits.

Équipe de support technique :

- **Techniciens de support** : Offrant une assistance technique aux utilisateurs finaux.
- **Formateurs** : Fournissant des formations aux agriculteurs sur l'utilisation des drones et des logiciels.

Équipe de gestion de projet :

- **Chefs de projet** : Coordonnant les différentes étapes du projet pour assurer sa réalisation dans les délais et les budgets impartis.
- **Responsables de la logistique** : Gérant la chaîne d'approvisionnement et la distribution des drones.

E Étude financière

E.1 Capital estimé

Poste de dépense	Coût estimé en USD	Coût estimé en DZD (1 USD ≈ 140 DZD)
Achat de drones Coût par drone (10 unités)	30 000 USD	4 200 000 DZD
Développement logiciel Coût de développement initial Licences de logiciels et outils	15 000 USD 5 000 USD	2 100 000 DZD 700 000 DZD
Capteurs et équipements Capteurs d'image (10 unités)	5 000 USD	700 000 DZD
Infrastructure informatique Serveurs et stockage Infrastructure de communication	10 000 USD 5 000 USD	1 400 000 DZD 700 000 DZD
Formation et support Formation initiale Support technique initial	3 000 USD 2 000 USD	420 000 DZD 280 000 DZD
Marketing et lancement Campagne de lancement Publicité et promotion	10 000 USD 5 000 USD	1 400 000 DZD 700 000 DZD
Frais généraux et divers Bureaux et utilitaires Autres dépenses diverses	5 000 USD 5 000 USD	700 000 DZD 700 000 DZD
Total du capital estimé	100 000 USD	14 000 000 DZD

TABLE 8 – Capital estimé

E.2 Coûts d'exploitation mensuels

Poste de dépense	Coût mensuel en USD	Coût mensuel en DZD (1 USD ≈ 140 DZD)
Maintenance des drones Coût par drone (10 unités)	1 000 USD	140 000 DZD
Salaires et rémunérations Salaires des développeurs et techniciens	10 000 USD	1 400 000 DZD
Salaires des personnels de support	3 000 USD	420 000 DZD
Frais de fonctionnement Serveurs et infrastructure IT	1 000 USD	140 000 DZD
Communication et internet	500 USD	70 000 DZD
Marketing et publicité Campagnes publicitaires	1 000 USD	140 000 DZD
Promotions et offres spéciales	500 USD	70 000 DZD
Frais généraux et divers Loyer des bureaux	1 000 USD	140 000 DZD
Utilitaires et autres frais	500 USD	70 000 DZD
Total des coûts d'exploitation mensuels	18 500 USD	2 590 000 DZD

TABLE 9 – Coûts d'exploitation mensuels

E.3 Projections financières sur trois ans

Année	Revenus projetés en USD	Revenus projetés en DZD	Coûts d'exploitation en USD	Coûts d'exploitation en DZD	Bénéfices nets en USD	Bénéfices nets en DZD
Première année	300 000 USD	42 000 000 DZD	222 000 USD	31 080 000 DZD	78 000 USD	10 920 000 DZD
Deuxième année	400 000 USD	56 000 000 DZD	222 000 USD	31 080 000 DZD	178 000 USD	24 920 000 DZD
Troisième année	500 000 USD	70 000 000 DZD	222 000 USD	31 080 000 DZD	278 000 USD	38 920 000 DZD
Total sur trois ans	1 200 000 USD	168 000 000 DZD	666 000 USD	93 240 000 DZD	534 000 USD	74 760 000 DZD

TABLE 10 – Projections financières sur trois ans

E.4 Analyse financière

Aspect	Détails
Investissement initial	100 000 USD / 4 000 000 DZD
Revenus et rentabilité	Les revenus augmentent chaque année, atteignant la rentabilité dès la première année en raison de l'optimisation des coûts d'exploitation.
Optimisation des coûts	Les coûts d'exploitation ont été optimisés, notamment les salaires et les frais de marketing, ce qui permet d'atteindre la rentabilité. Les subventions ou les investisseurs supplémentaires permettront d'accélérer la croissance.
Potentiel de marché	Potentiel élevé pour un système de détection des mauvaises herbes par drone avec une demande croissante pour des solutions agricoles de précision. Expansion progressive et augmentation du nombre d'abonnements permettront d'améliorer la situation financière à long terme.

TABLE 11 – Analyse financière

Business model :

Partenariats Clés :

-Fabricants de Drones : Collaboration avec des entreprises spécialisées dans la fabrication de drones pour intégrer les technologies nécessaires.

-Experts en Agriculture : Partenariats avec des agronomes et des instituts de recherche pour valider et améliorer les algorithmes de détection.

-Distributeurs : Réseaux de distribution pour étendre la portée commerciale du produit.

-Organismes de Régulation : Collaboration avec des agences gouvernementales pour assurer la conformité réglementaire des herbicides utilisés.

Activités Clés :

-Développement Technologique : Conception et amélioration des drones et des logiciels de traitement d'images.

-Marketing et Vente : Promotion du produit auprès des agriculteurs et des entreprises agricoles.

-Maintenance et Support : Fourniture de services de maintenance et de support technique aux clients.

-Recherche et Développement : Innovation continue pour améliorer la précision de la détection et l'efficacité des pulvérisations.

Ressources Clés :

-Technologie Drone : Drones équipés de caméras haute résolution et de systèmes de navigation GPS.

-Logiciels de Traitement d'Images : Algorithmes d'intelligence artificielle pour la détection des mauvaises herbes à partir des images capturées.

-Personnel Qualifié : Ingénieurs en robotique, développeurs de logiciels, et spécialistes en agriculture de précision.

-Infrastructure : Serveurs et équipements pour le traitement et le stockage des données.

Structure de Coûts :

-R&D : Coûts de recherche et développement pour la conception et l'amélioration des technologies.

-Production : Coûts de fabrication des drones et du matériel connexe.

-Marketing : Dépenses pour les campagnes de marketing, la participation à des salons professionnels et autres activités promotionnelles.

-Support Client : Coûts liés à la formation, à la maintenance et au support technique.

-Opérations : Coûts opérationnels incluant les salaires, les infrastructures et les frais administratifs.

Proposition de Valeur :

-Efficacité : Le système offre une méthode précise et rapide pour détecter et traiter les mauvaises herbes, réduisant ainsi l'utilisation d'herbicides et augmentant l'efficacité des traitements.

-Économie de Coûts : Réduction significative des coûts liés aux herbicides en ciblant uniquement les zones affectées, ainsi que des économies sur la main-d'œuvre et les équipements traditionnels de pulvérisation.

-Durabilité : Promotion de pratiques agricoles durables en minimisant l'impact environnemental des herbicides.

-Innovation : Utilisation de technologies de pointe comme les drones et l'intelligence artificielle pour moderniser l'agriculture.

Relations Clients

-Support Technique : Assistance technique pour l'installation, la maintenance et la formation à l'utilisation du système.

-Service Après-Vente : Services de maintenance régulière, mises à jour logicielles et assistance en cas de panne.

-Feedback Client : Recueil des avis et des suggestions des utilisateurs pour améliorer continuellement le produit.

Canaux de Distribution :

-Vente Directe : Vente directe aux agriculteurs et entreprises agricoles via des commerciaux ou des plateformes en ligne.

-Partenariats : Collaboration avec des coopératives agricoles, des distributeurs d'équipements agricoles et des entreprises de services agricoles.

-Événements et Salons Agricoles : Présentation du produit lors de foires et d'expositions agricoles pour démontrer son efficacité.

Segments de Clients :

-Agriculteurs : Petites, moyennes et grandes exploitations agricoles cherchant à optimiser la gestion des mauvaises herbes.

-Entreprises Agricoles : Entreprises offrant des services agricoles, y compris la gestion des cultures et des champs.

-Gouvernements et ONG : Organisations intéressées par la promotion de pratiques agricoles durables et la réduction des impacts environnementaux.

Flux de Revenus :

-Vente de Systèmes : Vente unique des drones et des logiciels de traitement d'images.

-Abonnements : Modèles d'abonnement pour l'accès continu aux mises à jour logicielles et aux services de traitement d'images.

-Services de Pulvérisation à la Demande : Facturation des services de pulvérisation basés sur la surface traitée ou le nombre d'interventions.