

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT : ELECTRONIQUE
N° :



DOMAINE : SCIENCES ET
TECHNOLOGIES
FILIERE : TELECOMMUNICATION

OPTION : SYSTEMES DES
TELECOMMUNICATIONS

**Mémoire présenté pour l'obtention
Du diplôme de Master Académique**

Par :

HAFIDI Salah Eddine

DRIF Nour El-Islam

Intitulé :

**Détection des mauvaises herbes dans un champ
agricole en utilisant l'apprentissage machine**

Soutenu devant le jury composé de :

Dr. KENANE Elhadi	Université Mohammed Boudiaf M'sila	Président
Dr. CHALABI Izzeddine	Université Mohammed Boudiaf M'sila	Rapporteur
Dr. SAHED Mohamed	Université Mohammed Boudiaf M'sila	Examineur

Année universitaire : 2022 /2023

Remerciements

Nous tenons à exprimer notre reconnaissance particulière à **Allah**, qui nous a accordé la santé, la force et la patience pour accomplir ce travail. Sans Sa grâce et Son inspiration, nous n'aurions pu réaliser quoi que ce soit.

Nous souhaitons également exprimer notre profonde gratitude et reconnaissance envers tous ceux qui nous ont aidés et soutenus dans la réalisation de ce travail.

Ce travail n'aurait pas été aussi enrichissant et réussi sans l'aide du **Dr. Chalabi Izzedine**, qui a eu l'honneur d'accepter d'être notre encadreur pédagogique. Nous tenons à le remercier chaleureusement pour ses précieux conseils et recommandations qui se sont avérés d'une grande utilité, et nous lui exprimons notre profonde gratitude.

Nous tenons également à exprimer notre respect et nos remerciements aux honorables membres du jury de soutenance, qui ont aimablement accepté d'évaluer notre travail.

Nous tenons à exprimer notre profonde gratitude envers tous les enseignants du département d'électronique à l'Université de M'Sila.

Dédicaces

Je dédie ce travail à la mémoire de mes grands-parents ainsi que ma grande famille,

et ma grand-mère **Aicha**.

À **ma mère**, aucun hommage ne pourrait être à la hauteur de tous les sacrifices dont elle a fait
preuve.

A **mon père**, je tiens à te remercier pour ton aide, ta patience et ton écoute.

À mon frère **Souhaïb** et mes très chères sœurs **Iman, Douaa** et **Lina**.

À mes frères de cœur **Aboubaker, Abdelaziz, Abdelkrim**, à mon binôme **Nour-Elislam**.

À tous ceux qui ont contribué de près ou de loin pour que ce projet soit possible, je vous remercie.

Salah Eddine

Dédicaces

Je dédie ce travail à toute ma famille et à ceux qui m'ont aidé,

À **ma mère**, la lumière de mes yeux et l'amour de mon cœur.

À **mon père**, dont la générosité est sans limite.

À mes frères et sœurs, **Asmaa, Oussama, Djaber, Souad**, et **Yaakoub**.

À nos adorables petits poussins familiaux, **Saif, Ayoub, Abdullah, Diaa, Malak, Sajid, Amana**,
et **Lyn**.

À mes amis et ma deuxième famille, **Taki, Taher, Ahmed**, et **Abdelouahab** à mon binôme
Salah Eddine.

Sommaire

Chapitre 1

Généralités sur l'apprentissage machine

1.1	Introduction	05
1.2	L'intelligence artificielle	05
1.2.1	Définition	05
1.2.2	L'histoire de l'IA	06
1.2.3	Les domaines d'application de l'IA	07
1.3	L'apprentissage machine	08
1.3.1	Définition	08
1.3.2	La renaissance de l'apprentissage machine	09
1.3.3	Les types d'apprentissage	09
1.3.3.1	Apprentissage supervisé	10
1.3.3.2	Apprentissage non-supervisé	12
1.3.3.3	Apprentissage semi-supervisé	14
1.3.3.4	L'apprentissage par renforcement	14
1.3.3.5	La différence entre les types d'apprentissage	15
1.4	Deep Learning	15
1.4.1	Définition	15
1.4.2	Neurone biologique	16
1.4.3	Neurone artificiel	16
1.4.4	Modèles de Deep Learning dans les réseaux neuronaux	18
1.4.4.1	Réseaux neuronaux récurrents (RNN)	18
1.4.4.2	Réseaux antagonistes génératifs (RAG)	18
1.4.4.3	Réseaux de neurones convolutifs (CNN)	19
1.5	Conclusion	20

Chapitre 2

Classification des mauvaises herbes en utilisant le Deep Learning

2.1	Introduction	22
2.2	Mauvaises herbes	22
2.2.1	Définition	22
2.2.2	Caractéristiques des mauvaises herbes	22
2.2.3	Classification des mauvaises herbes	23
2.2.3.1	Les graminées	24
2.2.3.2	Les dicotylédones	24
2.3	Classification en utilisant Deep Learning	24
2.3.1	Les différentes couches de CNN	25
2.3.2	Modèles de Deep Learning basés sur CNN	32
2.3.2.1	Modèle ResNet50 (Residual Network)	32

2.3.2.2	Modèle VGG16	33
2.3.2.3	Modèle VGG19	33
2.3.2.4	Modèle EfficientNet-B0	34
2.4	Conclusion	35

Chapitre 3

Résultats et discussion

3.1	Introduction	37
3.2	Description de la base de données	37
3.3	Environnement utilisé : Google Colab	37
3.4	Critères d'évaluation des performances	38
3.4.1	Confusion Matrix	38
3.5	Analyse des performances	40
3.5.1	ResNet50	40
3.5.2	VGG16	41
3.5.3	VGG19	43
3.5.4	EfficientNet-B0	44
3.6	Comparaison des résultats	45
3.7	Conclusion	45
	Conclusion générale	46
	Bibliographies	48

List des figures

Figure 1.1	Histoire de l'intelligence artificielle	07
Figure 1.2	Les domaines d'application de l'intelligence artificielle	08
Figure 1.3	Les types d'apprentissage	09
Figure 1.4	Apprentissage supervisé	10
Figure 1.5	Classification binaire	10
Figure 1.6	Classification multi-classes	11
Figure 1.7	Régression	11
Figure 1.8	Machines à vecteurs de support	12
Figure 1.9	Clustering	13
Figure 1.10	Détection anomalies	13
Figure 1.11	Apprentissage par renforcement	14
Figure 1.12	IA vs ML vs DL	16
Figure 1.13	(A) Neurone biologique, (B) Neurone artificiel	17
Figure 1.14	Perceptron multicouches	18
Figure 1.15	Architecture de RNN	18
Figure 1.16	Schéma du fonctionnement d'un RAG	19
Figure 1.17	Architecture d'un réseau CNN	20
Figure 2.1	La différence entre les herbes dans l'apparence extérieure	23
Figure 2.2	Les graminées	24
Figure 2.3	Mauvaises herbes à feuilles larges	24
Figure 2.4	Classification des mauvaises herbes par les CNN	25
Figure 2.5	Convolution 2D	26
Figure 2.6	Le padding	27
Figure 2.7	(A) pooling maximal, (B) pooling moyen	27
Figure 2.8	Fonctions sigmoïde	28
Figure 2.9	Fonctions tanh	29
Figure 2.10	Fonctions Relu	29
Figure 2.11	Fonctions Leakey Relu	30
Figure 2.12	Fonctions ELU	30
Figure 2.13	Opération d'aplatissement	31
Figure 2.14	(A) Bloc résiduel, (B) architecture de ResNet50	32
Figure 2.15	L'architecture de VGG16	33
Figure 2.16	L'architecture de VGG19	34
Figure 2.17	L'architecture de l'EfficientNet-B0	35
Figure 3.1	Exemple de données (Broadleaf, Grass)	37
Figure 3.2	Environnement de travail	38
Figure 3.3	Confusion Matrix	38
Figure 3.4	Accuracy et Validation du ResNet50	41

Figure 3.5	Confusion Matrix du ResNet50	41
Figure 3.6	Accuracy et Validation du VGG16	42
Figure 3.7	Confusion Matrix du VGG16	42
Figure 3.8	Accuracy et Validation du VGG19	43
Figure 3.9	Confusion Matrix du VGG19	43
Figure 3.10	Accuracy et Validation du EfficientNet-B0	44
Figure 3.11	Confusion Matrix du EfficientNet-B0	44

Liste des tableaux

Tableau 1.1	Les différences entre les types d'apprentissage	15
Tableau 3.1	Performances du ResNet50	41
Tableau 3.2	Performances du VGG16	43
Tableau 3.3	Performances du VGG19	44
Tableau 3.4	Performances du EfficientNet-B0	45
Tableau 3.5	Comparaison de modèles	45

Liste des abréviations

ANN	Artificial neural network
CNN	Réseaux de neurones convolutifs
CONV	Couche de convolution
CPU	Central processing unit
DL	Deep Learning
ELU	Exponential Linear Unit
FC	Fully connected
FN	False negative
FP	False positive
GPU	Graphics processing unit
IA	Intelligence artificielle
MBConv	Mobile Inverted Residual Bottleneck Convolution
ML	Machine learning
NAS	Recherche automatique d'architecture neuronale
RAG	Réseaux antagonistes génératifs
Relu	Unité de rectification linéaire
RNN	Réseaux neuronaux récurrents
SGD	Stochastique Gradient Descente
SVM	Support-vector machine
TN	True negative
TP	True Positives
VGG	Visual geometry group

Abstract

Weeds are undesirable plants that grow in agricultural field competing for various nutrients and water from the field themselves, causing losses to field yields. The objective of this work was to use Deep Learning to perform weeds detection in agricultural fields and classify these weeds among grass and broadleaf categories, aiming to apply the specific herbicide to the weed detected. For this purpose, we used an image database containing over four thousand images of the broadleaf and grass weeds. For this, we used different models VGG16, VGG19, ResNet50, and EfficientNet-B0. The obtained result, show that the ResNet50 model provide the best performance with the highest accuracy comparing with the other models.

Keywords: weeds detection, Deep Learning, agricultural

ملخص

الأعشاب الضارة هي نباتات غير مرغوب فيها تنمو في المحاصيل الزراعية وتتنافس على مختلف العناصر الغذائية والمياه من المحاصيل نفسها، مما يتسبب في خسائر في غلة المحاصيل. كان الهدف من هذا العمل هو استخدام التعلم العميق لإجراء اكتشاف الأعشاب الضارة في المحاصيل الزراعية وتصنيف هذه الأعشاب بين الأوراق الطويلة والأوراق العريضة، بهدف استخدام مبيدات الأعشاب المحددة للأعشاب المكتشفة. لهذا الغرض، استخدمنا قاعدة بيانات للصور تحتوي على أكثر من أربعة آلاف صورة لأوراق الطويلة والأوراق العريضة. لتدريب الشبكات العصبية، استخدمنا بنى مختلفة:

(VGG16 ،VGG19 ،ResNet50 ،EfficientNet-B0)

ونتيجة لذلك، حقق النموذج ResNet50 احسن النتائج و افضل دقة لتصنيف الاعشاب الضارة.

Résumé

Les mauvaises herbes sont des plantes indésirables qui poussent dans les cultures agricoles en concurrence pour divers nutriments et l'eau des cultures elles-mêmes, causant des pertes de rendement. L'objectif de ce travail était d'utiliser le Deep Learning pour détecter les mauvaises herbes dans les cultures agricoles et de classer ces mauvaises herbes dans deux classes Grass et Broadleaf, dans le but d'appliquer l'herbicide convenable aux mauvaises herbes détectées. Dans ce stade, nous avons utilisé une base de données d'images contenant plus de quatre mille images de Grass et Broadleaf. Pour cela, nous avons utilisé différents modèles VGG16, VGG19, ResNet50 et EfficientNet-B0. Les résultats obtenus montrent que le modèle ResNet50 donne les meilleures performances avec une grande précision par rapport aux autres modèles.

Introduction générale

Introduction générale

Les nouvelles technologies révolutionnent depuis plusieurs années de nombreux domaines d'activité. L'agriculture peut, elle aussi, en tirer profit grâce à l'intelligence artificielle. Cela mène à une meilleure productivité, suivi des récoltes, gestion facilitée, coûts réduits ...etc. Parmi les problèmes rencontrés dans le domaine agricole est les mauvaises herbes. Ces derniers, peuvent concurrencer les cultures dans les sources alimentaires et la lumière du soleil, cela provoque une réduction dans le rendement des cultures et entraînant des pertes économiques considérables pour les agriculteurs.

Dans le passé, la lutte contre les mauvaises herbes se faisait au moyen de méthodes manuelles ou mécaniques, ce qui est souvent coûteux et nécessite beaucoup de main-d'œuvre. Cependant, avec les développements technologiques récents dans le domaine de l'intelligence artificielle et de l'apprentissage automatique, de nouvelles approches plus efficaces et automatisées émergent pour la détection et la classification des mauvaises herbes. A l'aide de l'apprentissage machine il est possible d'analyser de grandes quantités d'images de champs agricoles pour détecter et classer les mauvaises herbes avec précision. La classification des mauvaises herbes avec le Deep Learning repose sur des modèles qui sont entraînés sur des ensembles de données étiquetées. Ces ensembles de données comprennent des images de champs agricoles où les mauvaises herbes sont identifiées et étiquetées avec leur espèce respective. Le modèle apprend alors à reconnaître les caractéristiques visuelles distinctives des différentes espèces de mauvaises herbes. Une fois que le modèle est entraîné, il peut être utilisé pour analyser de nouvelles images de champs agricoles et détecter les mauvaises herbes présentes. Il peut également classer les mauvaises herbes détectées en fonction de leur espèce, permettant aux agriculteurs de prendre des décisions sur les méthodes de contrôle appropriées.

Dans ce travail, on va considérer le problème de classification de deux classes de mauvaises herbes à l'aide de Deep Learning.

Ce mémoire est organisé comme suit : dans le premier chapitre on va présenter des généralités sur l'intelligence artificielle et en particulier l'apprentissage machine ainsi que leur type et domaines d'application. Le deuxième chapitre sera focalisé uniquement

sur la classification des mauvaises herbes en utilisant le Deep Learning, on va présenter les caractéristiques des mauvaises herbes. De plus, l'architecture des réseaux de neurones convolutifs et les différents modèles considérés ResNet50, VGG16, VGG19 et EfficientNet-B0 seront présentés en détails. Ensuite, le troisième chapitre sera consacré aux données utilisées pour l'apprentissage et l'évaluation des performances des différents modèles.

Chapitre 1

Généralités sur l'apprentissage machine

1.1 Introduction

Parmi les technologies émergentes de notre époque, l'apprentissage automatique, connu sous le nom de machine learning ML. C'est un sous-domaine de l'intelligence artificielle IA qui consiste à utiliser des algorithmes pour permettre aux ordinateurs de comprendre des modèles de données et d'effectuer des tâches sans être programmées au préalable pour chaque étape. En d'autres termes, l'apprentissage automatique permet aux ordinateurs d'apprendre à partir de données de s'adapter à de nouvelles situations, ce qui les rend utiles pour les tâches qui seraient difficiles ou impossibles à implanter par la programmation traditionnelle. Ce procédé est également utilisé dans différents domaines, comme la reconnaissance d'images, la classification de textes, la prédiction de la demande et l'analyse des données. Par le biais de l'apprentissage automatique, on peut résoudre beaucoup de problèmes réels. Dans ce sens, ce chapitre sera consacré sur des différentes techniques de l'intelligence artificielle et de l'apprentissage machine.

1.2 L'intelligence artificielle

1.2.1 Définition

L'intelligence artificielle est un ensemble de techniques qui permettent aux machines d'effectuer des tâches et de résoudre des problèmes habituellement réservés aux humains. Les tâches effectuées par l'IA sont parfois très simples pour les humains. Par exemple, l'identification des images, la planification des mouvements d'un robot pour attraper un objet ou encore conduire une voiture. Ils nécessitent parfois une planification complexe, un raisonnement de façon déductive comme par exemple jouer aux échecs. De plus, ils nécessitent aussi un traitement des opérations complexes (effectuer plusieurs tâches à la fois) ou de réaliser des tâches répétitives ennuyeuse pour l'être humain [1]. Ces dernières années, l'intelligence a presque toujours été associée à la capacité d'apprendre. Grâce à l'apprentissage, un système intelligent capable d'effectuer une tâche peut améliorer ses performances en fonction de l'expérience. En l'étudiant, il pourra apprendre à effectuer de nouvelles tâches et acquérir de nouvelles compétences. Les algorithmes et l'intelligence artificielle occupent déjà une place importante dans nos vies, et avec le temps cette proportion va augmenter. [2]

1.2.2 L'histoire de l'IA

L'histoire de l'IA peut être divisée en plusieurs étapes, chacune marquée par des percées et des progrès significatifs dans le domaine. Voici une courte liste de ces étapes avec une brève description de chacune :

- La naissance de l'IA (années 1940-1950) - Cette étape est marquée par le développement des premiers ordinateurs numériques qui ont fourni une plateforme pour les chercheurs afin de l'expérimenter avec la création de machines intelligentes. Le terme « intelligence artificielle » a été inventé en 1956 à la Conférence de Dartmouth.
- L'hiver de l'IA (1960-1970) - Les progrès de la recherche sur l'intelligence artificiel ralentissent à cette étape en raison de la puissance et du financement limités des calculs. Cette période a été marquée par un scepticisme et une critique importants de l'IA, conduisant à une baisse de l'intérêt dans le domaine.
- Systèmes experts (1980-1990) - Des systèmes experts ont été élaborés pour reproduire les connaissances et les capacités décisionnelles des experts humains dans des domaines précis. Ces systèmes ont réussi dans certaines applications, mais leur capacité d'apprentissage et d'adaptation était limitée.
- Apprentissage machine (1990-2000) - Cette étape a vu la montée de l'apprentissage machine, qui implique le développement d'algorithmes qui peuvent apprendre et améliorer leurs performances sans être explicitement programmés. Cela a mené à des progrès importants dans des domaines comme la reconnaissance de la parole, la vision par ordinateur et le traitement du langage naturel.
- Deep learning (2010-aujourd'hui) - Cette étape est marquée par le développement de réseaux neuronaux profonds, capables d'apprendre et de traiter des quantités massives de données. Le deep learning a permis de réaliser d'importants progrès dans des domaines comme la reconnaissance de l'image et de la parole, le traitement du langage naturel et le jeu [3].

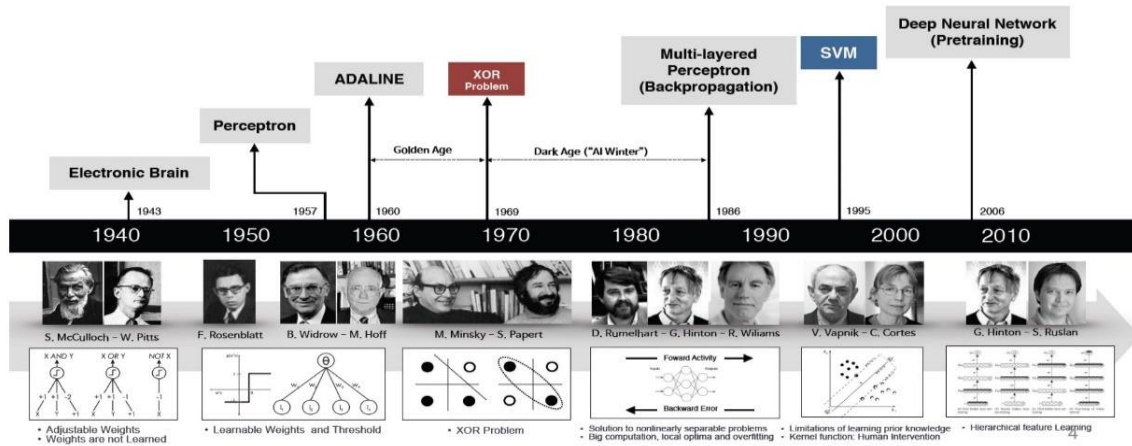


FIGURE 1.1 – Histoire de l'intelligence artificielle

1.2.3 Les domaines d'application de l'IA

- a. **L'apprentissage machine** : Ce domaine de l'IA concerne à la construction de modèles statistiques, puis l'apprentissage de ces modèles à partir des bases de données pour une prise de décision ou une prédiction.
- b. **La vision par ordinateur** : La vision par ordinateur est un domaine de l'intelligence artificielle qui permet aux ordinateurs d'extraire des informations significatives à partir d'images numériques ou des vidéos et de prendre des mesures ou de faire des recommandations suivant les informations collectées. Si l'intelligence artificielle permet aux ordinateurs de penser, la vision par ordinateur leur permet de voir, d'observer et de comprendre.
- c. **La parole** : L'IA utilise la reconnaissance vocale automatique et la technologie texte-parole dans le but de fournir une interface vocale pour les applications de conversation.
- d. **La robotique** : Ce domaine de l'IA se concentre sur la conception et la construction de robots capables d'interagir avec leur environnement.
- e. **Les systèmes experts** : est un logiciel capable de répondre à des questions, en effectuant un raisonnement à partir de faits et de règles connues. Il peut servir notamment comme outil d'aide à la décision. Par exemple, le système expert « Dendral » [4] qui permet d'identifier les constituants chimiques d'un matériau.
- f. **L'optimisation** : Ce domaine de l'IA implique la recherche de solutions optimales à des problèmes complexes à l'aide de techniques comme les méthodes numériques et les

algorithmes génétiques...etc.

- g. Le traitement du langage naturel** : C'est une branche de l'intelligence artificielle qui permet aux ordinateurs de comprendre, de générer et de manipuler le langage humain. Le traitement du langage naturel permet d'interroger les données à l'aide d'un texte ou d'une voix en langage naturel.

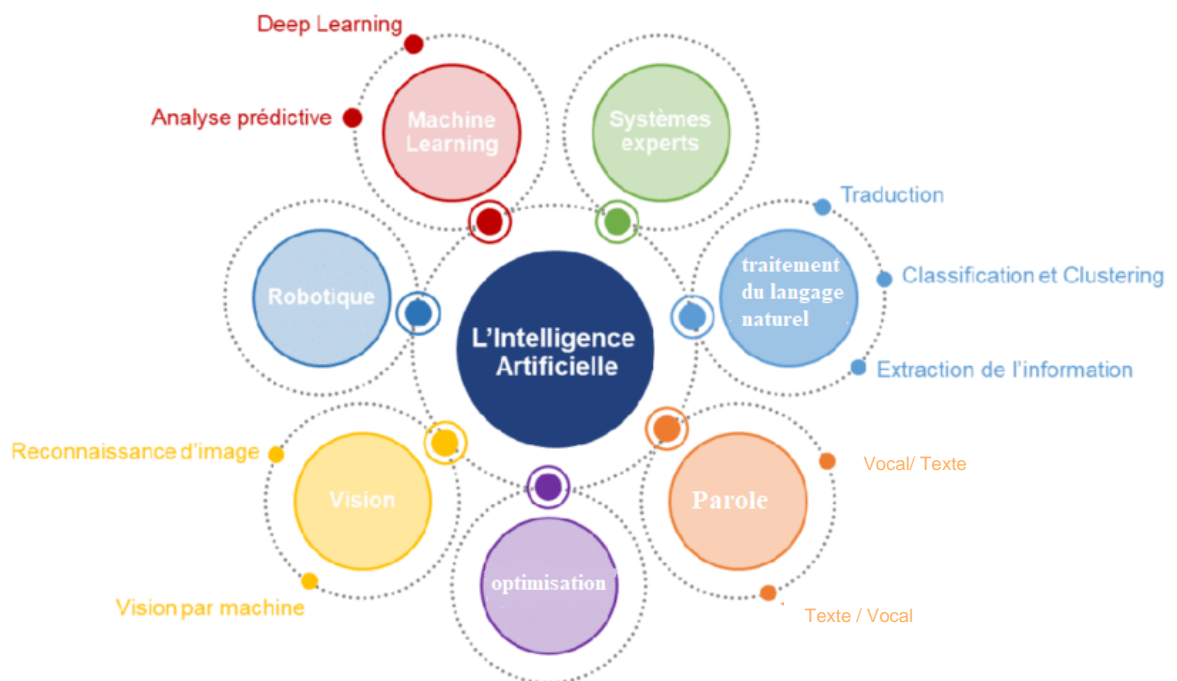


FIGURE 1.2 – Les domaines d'application de l'intelligence artificielle

1.3 L'apprentissage machine

1.3.1 Définition

L'apprentissage machine est un sous-ensemble de l'intelligence artificielle qui implique l'utilisation de techniques statistiques, pour permettre aux systèmes informatiques d'améliorer leurs performances sur une tâche spécifique avec l'expérience sans être explicitement programmés. Cela implique l'utilisation d'algorithmes qui apprennent à partir de données pour faire des prédictions ou des décisions. L'apprentissage machine est appliqué dans plusieurs. Une définition couramment utilisée de l'apprentissage machine est fournie par Tom Mitchell [5] : "un programme informatique est dit apprendre de l'expérience E par rapport à une classe de tâches T et une mesure de performance P , si sa performance sur les tâches de T , telle que mesurée par P , s'améliore avec l'expérience.

1.3.2 La renaissance de l'apprentissage machine

En 2006, Geoffrey Hinton et d'autres chercheurs ont publié un article [6] montrant comment entraîner un réseau neuronal profond capable de reconnaître des chiffres manuscrits avec une précision de pointe ($> 98\%$). Ils ont nommé cette technique « apprentissage profond » (deep learning). Il était largement admis à l'époque que la formation de réseaux de neurones profonds était impossible, et la plupart des chercheurs ont abandonnés l'idée depuis les années 1990. Cet article démontre que le deep learning est non seulement possible, mais aussi fournit des résultats intéressantes (grâce à une puissance de calcul massive et à des grande quantités de données) par rapport aux autres techniques d'apprentissage machine. Après le deep learning est rapidement propagé à autres domaines d'application.

En une décennie, l'apprentissage machine a conquis des industries entières, il est désormais au cœur des produits de haute technologie. Par exemple, classant les résultats de recherche sur le moteur de recherche Google, la reconnaissance vocale des smartphones, les recommandations des vidéos sur YouTube...etc.

1.3.3 Les types d'apprentissage

Il existe plusieurs méthodes d'apprentissage en intelligence artificielle et en machine learning.

On dénote 4 principaux types, ses dernières dépendent du problème que l'on voudrait traiter :

- ✓ Apprentissage supervisé
- ✓ Apprentissage non-supervisé
- ✓ Apprentissage par renforcement
- ✓ Apprentissage semi-supervisé

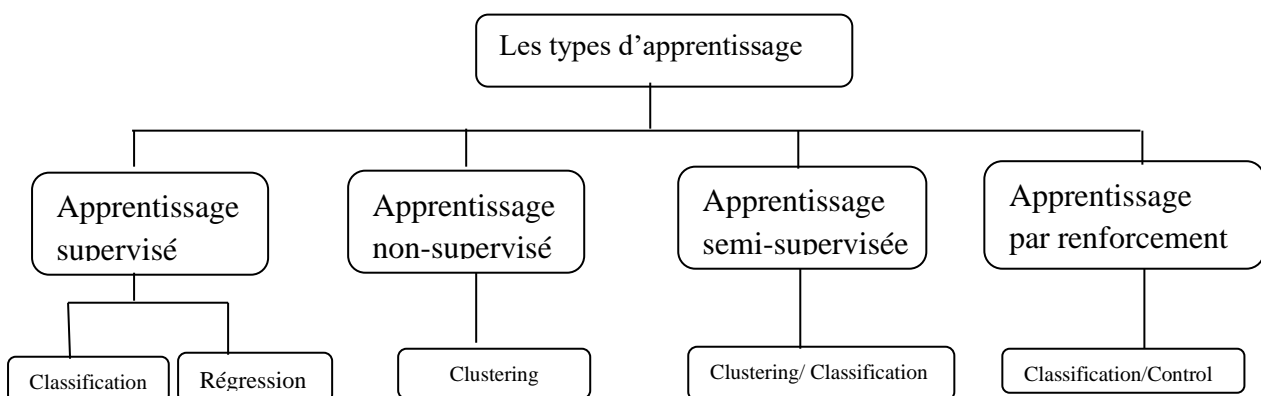


FIGURE 1.3 – Les types d'apprentissage

1.3.3.1 Apprentissage supervisé

Ce type d'apprentissage consiste à fournir au modèle des données d'entrée et de sortie pour qu'il puisse apprendre à faire des prédictions précises. Le modèle est entraîné à partir d'un ensemble de données étiquetées, où chaque exemple est associé à une étiquette de sortie connue.

Les techniques de l'apprentissage supervisé sont la **classification** et la **régression**.

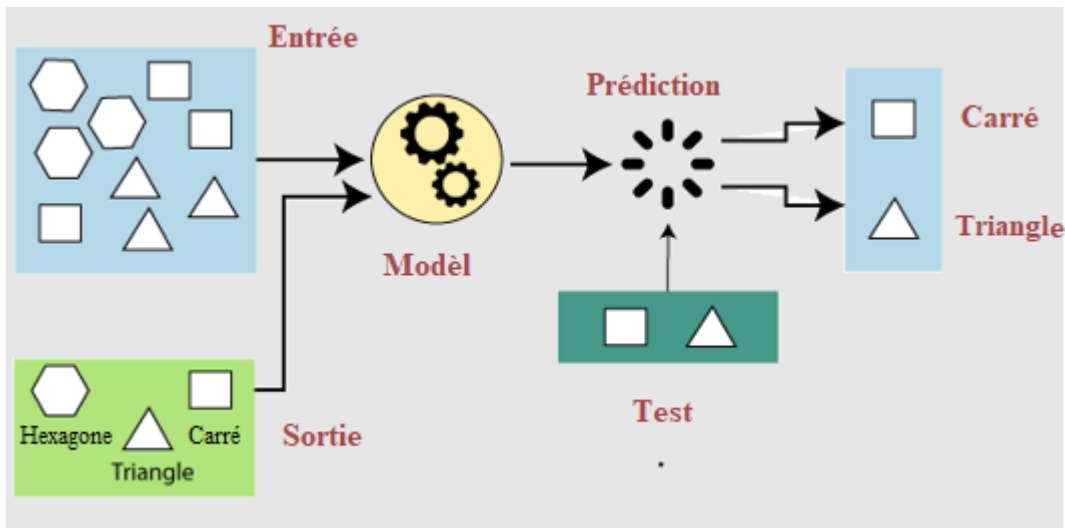


FIGURE 1.4 – Apprentissage supervisé

a. Classification : C'est un type d'apprentissage supervisé dont la sortie a des étiquettes définies (valeur discrète) ce qu'on appelle classes ou catégories. On peut avoir des classifications binaire ou alors multi-classe. La classification binaire prédit pour un modèle (0 ou 1) vrai ou faux.


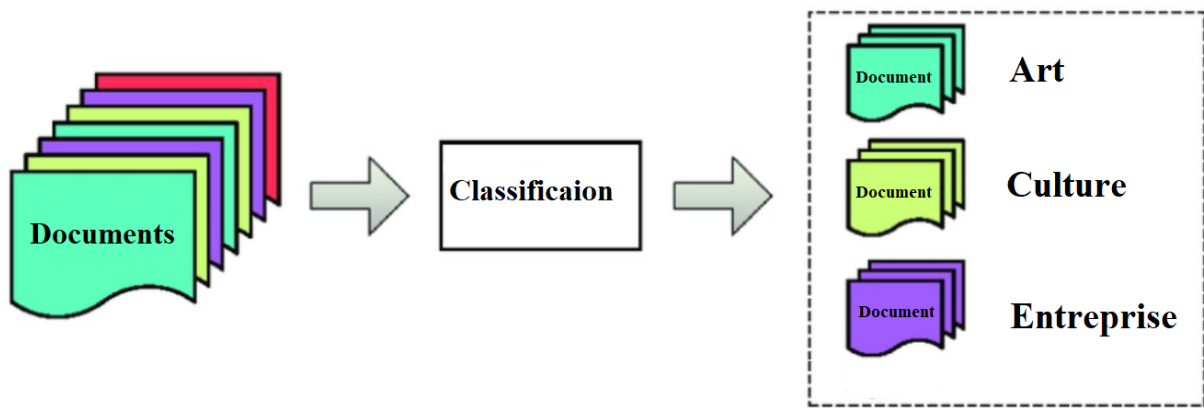



FIGURE 1.5 – Classification binaire

Dans le cas de multi-classes, le modèle va prédire plusieurs classes.

**FIGURE 1.6** – Classification multi-classes

Le but ici reste le même quel que soit le nombre de classes, prédire si les valeurs discrètes appartiennent à une classe particulière.

b. Régression : La régression est le procédé de trouver une fonction qui modélise la relation entre les variables d'entrée et la variable cible, afin de pouvoir prédire la variable cible pour de nouvelles valeurs d'entrée. Dans le cadre de la régression, la variable cible est généralement une variable continue, tels que le prix d'une maison, le chiffre d'affaires d'une entreprise, la température ...etc. [7]

**FIGURE 1.7** – Régression

Il y a des plusieurs algorithmes de l'apprentissage supervisé, par exemple on cite :

- **Régression linéaire** : La régression linéaire est une technique d'analyse de données qui prédit les valeurs de données inconnues en utilisant un ensemble de données connues utilisant une modélisation mathématiquement.
- **Machines à vecteurs de support** : Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais support-vector machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination et de régression. Les SVMs sont une généralisation des classifieurs linéaires. Les SVMs ont été développés dans les années 1990 à partir des considérations théoriques sur le développement d'une théorie statistique de l'apprentissage (théorie de Vapnik-Chervonenkis) [8]. Ils ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper-paramètres, leurs garanties théoriques, et leurs bons résultats en pratique.




FIGURE 1.8 – Machines à vecteurs de support

1.3.3.2 Apprentissage non-supervisé

L'apprentissage non supervisé est une branche de l'apprentissage machine, caractérisée par l'analyse et le regroupement de données non-étiquetées, Il s'agit donc de découvrir les structures sous-jacentes à ces données non étiquetées sans d'intervention humaine.

Voici quelques-uns des algorithmes d'apprentissage non supervisé les plus importants :

- Clustering** : (partitionnement des données) Cette méthode de classification non supervisée est l'un des algorithmes d'apprentissage dont le but est de regrouper les données non étiquetées présentant des propriétés similaires. Par exemple, supposons qu'on a une grande quantité de données sur les visiteurs du blog. on peut utiliser des

algorithmes de clustering pour essayer de détecter des groupes de visiteurs similaires. A tous moment l'algorithme de clustering décide à quel groupe appartient le visiteur sans notre aide « figure 1.9 ».




FIGURE 1.9 – Clustering

b. La détection des anomalies : est une tâche importante de l'apprentissage non supervisé, car elle permet de détecter des points de données anormaux ou inattendus dans un ensemble de données, ce qui peut être utile dans de nombreuses applications telles que la détection de fraudes, la détection de pannes, la détection d'intrusions, ...etc. Par exemple, la détection des transactions inhabituelles par carte de crédit pour éviter la fraude, la détection des défauts de fabrication ou la suppression automatique des valeurs aberrantes d'un ensemble de données avant de les transmettre à un autre algorithme d'apprentissage. Le système est entraîné avec des instances normales et lorsqu'il voit une nouvelle instance, il peut dire si elle ressemble à une instance normale ou s'il s'agit probablement d'une anomalie, comme le montre le graphe suivant « figure 1.10 ».

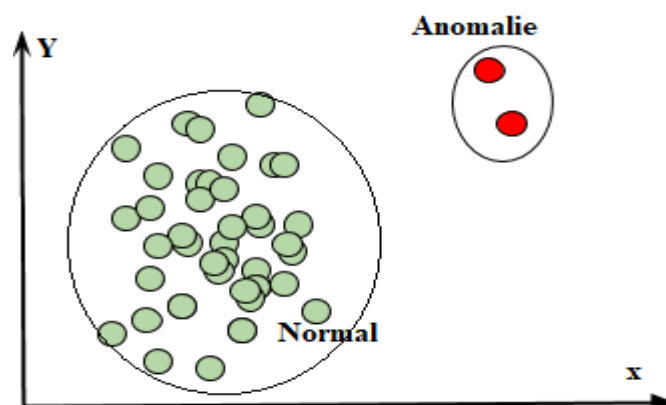


FIGURE 1.10 – Détection anomalies

1.3.3.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé combine les deux approches d'apprentissage supervisé et non-supervisé. L'apprentissage semi-supervisé génère automatiquement des étiquettes, qui peuvent être introduites dans les algorithmes d'apprentissage [9].

L'apprentissage semi-supervisé a un grand avantage financier. Il permet de baisser le coût de l'étiquetage des grands ensembles de données utilisés dans le cadre de l'apprentissage machine.

1.3.3.4 L'apprentissage par renforcement

L'apprentissage par renforcement est une branche de l'apprentissage machine. Contrairement à l'apprentissage supervisé ou non supervisé, l'apprentissage par renforcement ne repose pas sur un jeu de données statiques, mais sur une succession d'expériences dans un environnement dynamique. Les points de données, ou expériences, sont recueillis lors des interactions entre un agent software et son environnement, sur la base d'un apprentissage par essai-erreur. Cet aspect de l'apprentissage par renforcement est important, car il permet de se dispenser de certaines étapes, comme la collecte, le prétraitement et l'étiquetage des données, incontournables dans l'apprentissage supervisé ou non supervisé. Concrètement, cela signifie que, un modèle d'apprentissage par renforcement peut commencer à apprendre un comportement par lui-même, sans supervision humaine [10].

Le scénario général de l'apprentissage par renforcement est illustré par la « figure 1.11 ».



Figure 1.11 – Apprentissage par renforcement

1.3.3.5 Les différences entre les types d'apprentissage

La majeure différence qu'on peut trouver entre ces 4 types d'apprentissages est la disposition des données d'entrée, d'autres différences sont présentées dans le « tableau 1.1 ».

	Apprentissage supervisé	Apprentissage non supervisé	Apprentissage semi-supervisé	Apprentissage par renforcement
Données d'entrée	Caractéristiques étiquetées	Caractéristiques non étiquetées	Une combinaison de caractéristiques étiquetées et non étiquetées	État, action et récompense
Données de sortie	Étiquette	Aucune étiquette	Étiquettes pour une partie des données	Action
Objectif	Prédiction	Découverte de structures ou modèles cachés	Combinaison des objectifs de l'apprentissage supervisé et non supervisé	Apprendre une politique optimale
Exemples d'applications	Classification, régression	Caractéristiques non étiquetées	Utilisé lorsque les données étiquetées sont rares ou coûteuses à obtenir	Jeux, robotique, planification, etc.

Tableau 1.1- Les différences entre les types d'apprentissage

1.4 Deep learning

1.4.1 Définition

Deep learning DL peut être considéré comme une branche de l'intelligence artificielle « figure 1.12 » basée principalement sur l'utilisation de réseaux neuronaux multicouches pour l'apprentissage machine, qui transforment les données d'entrée en représentations internes plus comprises. En général, le deep learning vise à représenter les données d'une manière qui permet d'identifier plus efficacement différents modèles, en formant des réseaux de neurones sur de nombreuses tâches différentes, telles que la classification et la prévision en utilisant des techniques basées par exemple sur les statistiques et les méthodes numérique. Le deep learning est l'une des innovations les plus importantes dans le domaine de l'intelligence artificielle au cours de la dernière décennie. Cette technologie a été impliquée dans différents domaines, tels que l'amélioration du système de reconnaissance du son et de l'image, l'analyse de texte, la génération de texte et d'autres [11].

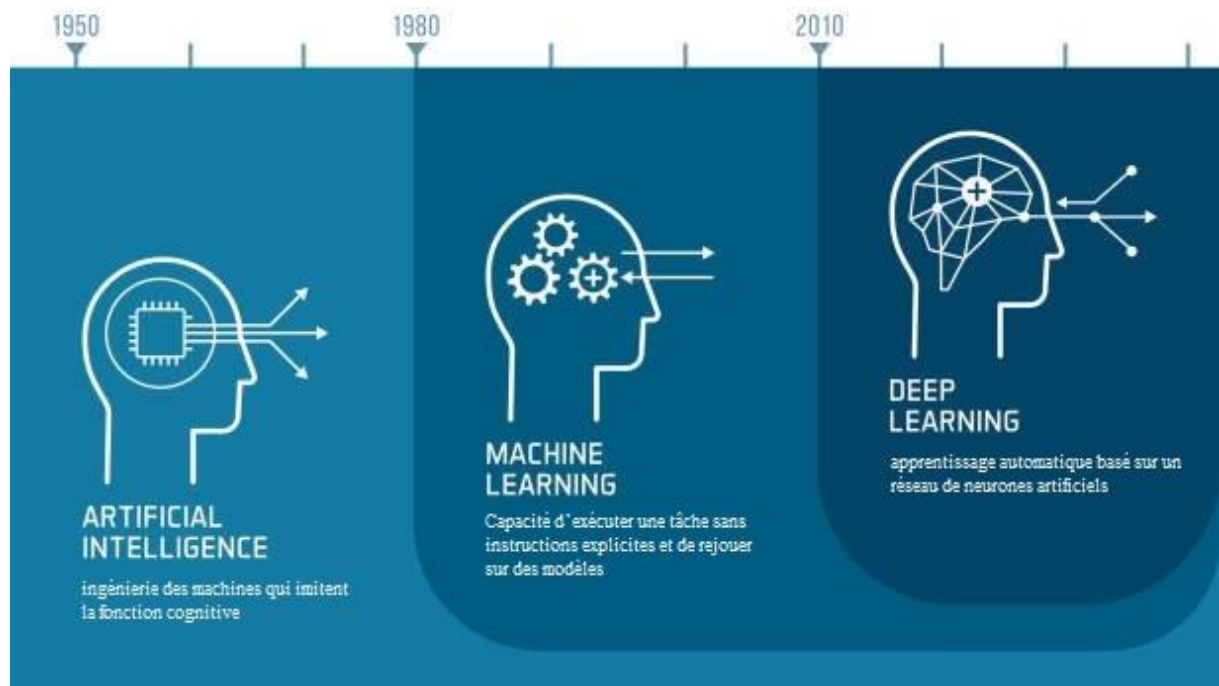


FIGURE 1.12 – IA vs ML vs DL

1.4.2 Neurone biologique

Un neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on appelle des dendrites. Celles-ci sont parfois si nombreuses qu'on parle alors de poils dendritiques ou d'arborisation dendritique. C'est par les dendrites que l'information est transmise de l'extérieur vers le corps du neurone. Les informations traitées par le neurone voyagent ensuite le long de l'axone pour être transmises à d'autres neurones. La transmission entre deux neurones n'est pas directe. En effet, entre l'axone du neurone afférent et la dendrite du neurone efférent, il existe un gap cellulaire de plusieurs dizaines d'Angströms [12].

1.4.3 Neurone artificiel

a. Structure :

La « figure 1.13 » montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées provenant d'autres neurones en amont. Chaque entrée est associée à un poids w (weight) représente la force de la connexion. Chaque neurone artificiel est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval.

b. Perceptron :

La forme la plus simple d'un réseau de neurone est le perceptron. Ce réseau est considéré parmi les premiers réseaux de neurones. Il a été inventé en 1957 par Rosenblatt. Le perceptron se compose d'un neurone artificiel à poids ajustable et d'un seuil. Il n'a qu'une seule sortie à laquelle toutes les entrées sont connectées.

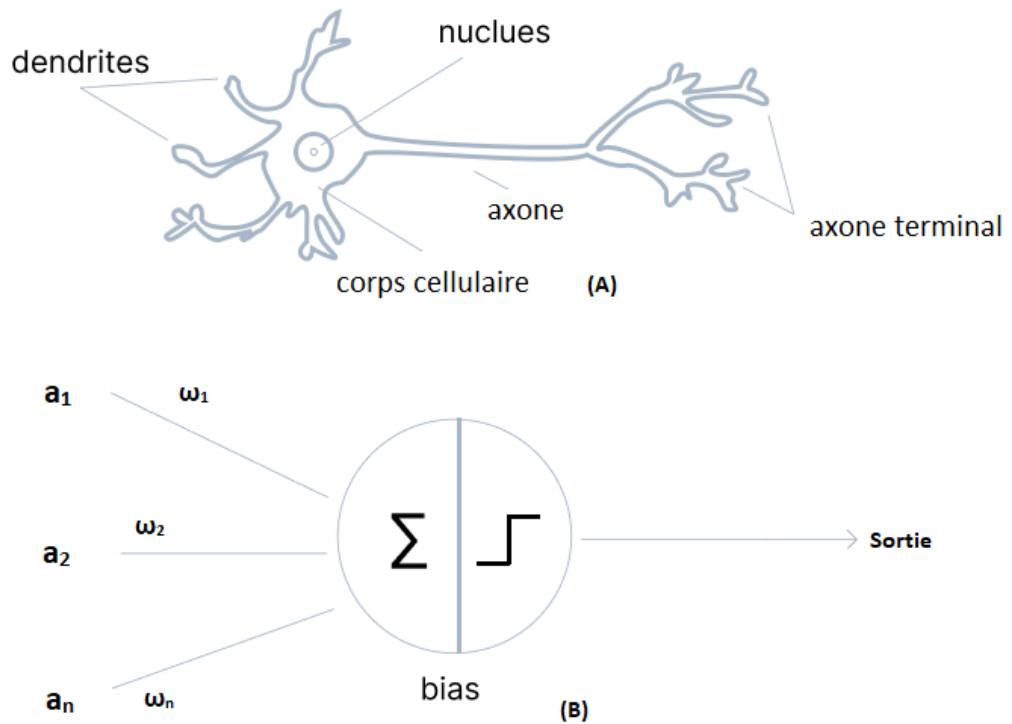


FIGURE 1.13 – (A) Neurone biologique, (B) Neurone artificiel

Le fonctionnement interne d'un perceptron peut être résumé par la formule suivante :

$$Sortie = \sigma\left(b + \sum_{i=1}^n a_i w_i\right) \quad (1.1)$$

a: les entrée

ω : le poid

b : bais

σ : fonction sigmoïde

c. Perceptron multi couche :

C'est un réseau de neurone composé d'une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées.




FIGURE 1.14 – Perceptron multicouches

1.4.4 Modèles de deep learning dans les réseaux neuronaux

1.4.4.1 Réseaux neuronaux récurrents (RNN)

Les réseaux de neurones récurrents sont une variante très importante des réseaux de neurones qui sont largement utilisés. L'aspect récurrent est due que le calcul à un instant t est à base de l'information apportée de l'instant $t-1$, elle-même calculée à partir de l'information apportée de $t-2$, ... etc. Une autre façon de penser aux RNN est qu'ils ont une "mémoire" qui capture des informations sur ce qui a été calculé jusqu'à présent [13].




FIGURE 1.15 – Architecture de RNN

1.4.4.2 Réseaux antagonistes génératifs (RAG)

Les réseaux antagonistes génératifs sont un type de modèle génératif profond qui utilise deux réseaux neuronaux distincts : un générateur et un discriminant. Le générateur est chargé

de créer des données simulées (par exemple, des images, des vidéos ou des textes), tandis que le discriminant est formé pour distinguer les données simulées des données réelles. Les deux réseaux sont entraînés simultanément dans un processus d'apprentissage supervisé. Le but est d'optimiser le générateur pour qu'il puisse produire des données simulées de haute qualité qui peuvent tromper le discriminant et être confondues avec des données réelles. [14]

Les RAGs ont connu un grand succès dans la création de contenu numérique, tels que des images, des vidéos et même des sons et de la musique. Ils ont également été utilisés pour des applications pratiques telles que la synthèse de données pour l'entraînement de modèles de l'apprentissage machine, l'amélioration de la résolution d'images et la restauration de données manquantes ou corrompues.

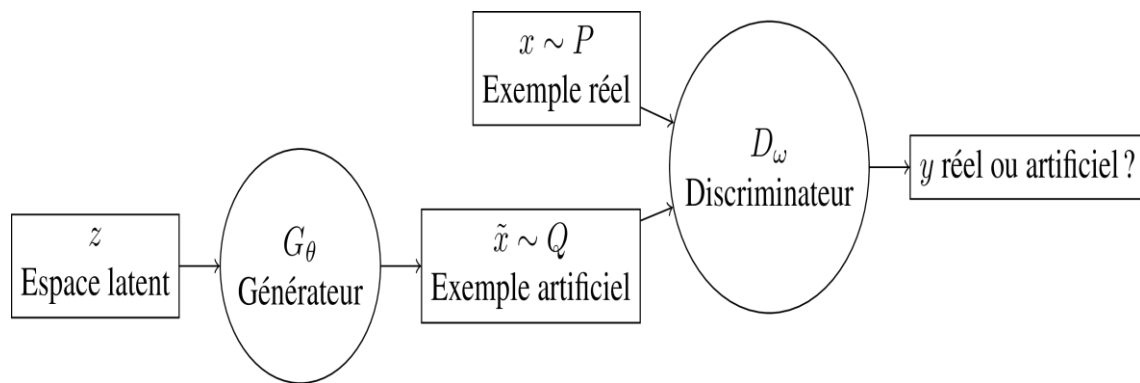


FIGURE 1.16 – Schéma du fonctionnement d'un RAG

1.4.4.3 Réseaux de neurones convolutifs (CNN)

Un CNN est un sous-ensemble des réseaux neuronaux. Un réseau de neurone convolutif est une sorte de méthode d'apprentissage profond supervisé qui est une extension des réseaux neuronaux artificiels. Il est principalement utilisé dans la reconnaissance d'image/vidéo, l'analyse sémantique, le traitement du langage naturel et la détection de paraphrase ...etc [15,16]. La couche de convolution, la couche de regroupement (Pooling layer) et la couche entièrement connectée (Fully-connected layer) sont les trois couches qui composent un réseau neuronal convolutif. L'objectif principal de la convolution est d'extraire les caractéristiques des photos d'entrée tout en gardant intacte la relation spatiale entre les pixels [17].




FIGURE 1.17 – Architecture d'un réseau CNN

1.5 Conclusion

Dans ce premier chapitre, nous avons présenté d'une manière globale l'apprentissage machine ainsi que leur type et domaines d'application. En bref, l'apprentissage machine est un domaine important et prometteur dans de notre vie, aidant à résoudre de nombreux problèmes difficiles et complexes rencontrés par les humains. Parmi ces domaines d'application, on va considérer le domaine agricole, exactement le traitement des mauvaises herbes que ce soit la détection ou la classification utilisant le deep learning.

Chapitre 2

Classification des mauvaises herbes en utilisant le Deep Learning

2.1 Introduction

Les mauvaises herbes constituent un défi majeur en agriculture parce qu'elles entravent la croissance des cultures, réduisent la productivité et peuvent entraîner des pertes financières importantes. Dans ce chapitre, nous allons considérer quelques types de mauvaises herbes dans le but de les identifier et les classer. Cette identification et classification des mauvaises herbes aide la sélection d'herbicides adéquats.

Dans un premier lieu, Nous allons présenter les différentes techniques de détection et de classification les plus utilisées dans le domaine agricole. Après, nous exposons une étude détaillée sur le Deep Learning où le principe de fonctionnement d'un réseau CNN sera présenté. Dans la suite, nous considérons les modèles les plus reconnus.

2.2 Mauvaises herbes

2.2.1 Définition

Les mauvaises herbes sont des plantes qui poussent au mauvais endroit et qui affect négativement sur les champs agricole et les environnants naturels. Les mauvaises herbes varient selon les milieux et les conditions environnementales, ces herbes appartiennent à plusieurs espèces comme le millet, le blé sauvage, l'ortie, la fourchette, le genévrier...etc. [18]. Les mauvaises herbes affectent d'autres plantes et se disputent des ressources vitales telles que l'eau, les aliments et la lumière, affectant ainsi négativement la productivité agricole et la qualité des cultures. Les mauvaises herbes posent parfois un risque pour les animaux et les humains, car elles peuvent causer des allergies, des empoisonnements et la transmission de maladies. Par conséquent, il est essentiel de réduire la propagation des mauvaises herbes pour préserver l'environnement naturel et assurer la productivité agricole. [19].

2.2.2 Caractéristiques des mauvaises herbes

Les caractéristiques des mauvaises herbes peuvent être extraites en observant plusieurs facteurs [20], notamment :

- a. **Apparence extérieure** : Les mauvaises herbes ont des formes très différentes, et peuvent être identifiées en observant les feuilles, les fleurs, les fruits et autres caractéristiques. « figure2.1 »



FIGURE 2.1 – La différence entre les herbes dans l'apparence extérieure

- b. Modèle de croissance* : Les mauvaises herbes se caractérisent par une croissance et une propagation rapide et étendues, certaines espèces se propageant par leurs graines. Il est également possible d'identifier les mauvaises herbes en observant les espaces vides dans les champs, les jardins et les terres agricoles.
- c. Couleur et odeur* : Les mauvaises herbes peuvent avoir une couleur ou une odeur différente des plantes naturelles. Elles peuvent avoir une odeur forte ou désagréable, ce qui peut aider à les identifier.
- d. Dommages causés* : Les mauvaises herbes peuvent être identifiées en observant les dommages qu'elles causent aux autres plantes et aux champs agricoles. Il est possible de déterminer les mauvaises herbes en observant les symptômes qu'elles laissent sur les feuilles, les fruits, les racines et autres systèmes.

2.2.3 Classification des mauvaises herbes

Les mauvaises herbes peuvent être classées selon le format de leurs feuilles en deux catégories les graminées (Grass) et les dicotylédones (Broadleaf). La séparation de ces deux classes est adéquate parce que les graminées et les dicotylédones sont différenciées dans le traitement en raison de la sélectivité de certains herbicides pour une classe spécifique [21]. Donc, l'application d'herbicides donne de meilleurs résultats si le traitement est ciblé sur une classe spécifique de mauvaises herbes.

2.2.3.1 Les graminées

Les graminées sont des mauvaises herbes caractérisées par leurs feuilles étroites et allongées. Elles affectent négativement et se disputent des ressources vitales telles que l'eau, les aliments et la lumière. La « figure 2.2 » montre un exemple de graminées utilisées dans ce mémoire.




FIGURE 2.2 – Les graminées

2.2.3.2 Les dicotylédones

Les dicotylédones sont des plantes indésirables caractérisées par des feuilles larges et plates plutôt que des feuilles en forme d'aiguille. La « figure 2.3 » présente un exemple de mauvaises herbes à feuilles larges considérées dans ce travail.




FIGURE 2.3 – Mauvaises herbes à feuilles larges

2.3 Classification en utilisant Deep Learning

Le Deep Learning peut classifier les mauvaises herbes avec une grande précision et automatiquement. L'apprentissage des modèles est effectué en utilisant un large nombre d'images de mauvaises herbes. Après l'apprentissage, le modèle peut analyser

automatiquement l'image pour classifier.

Dans ce mémoire, le Deep Learning basé sur le CNN sera utilisé pour analyser les images et distinguer leurs classes en fonction de ces caractéristiques. Les modèles CNN contiennent plusieurs couches qui seront détaillées dans la sous-section suivante.

2.3.1 Les différentes couches de CNN

Les réseaux de neurones convolutifs se composent de plusieurs couches différentes qui réalisent des tâches distinctes. La « figure 2.4 » montre les différentes couches d'un CNN.

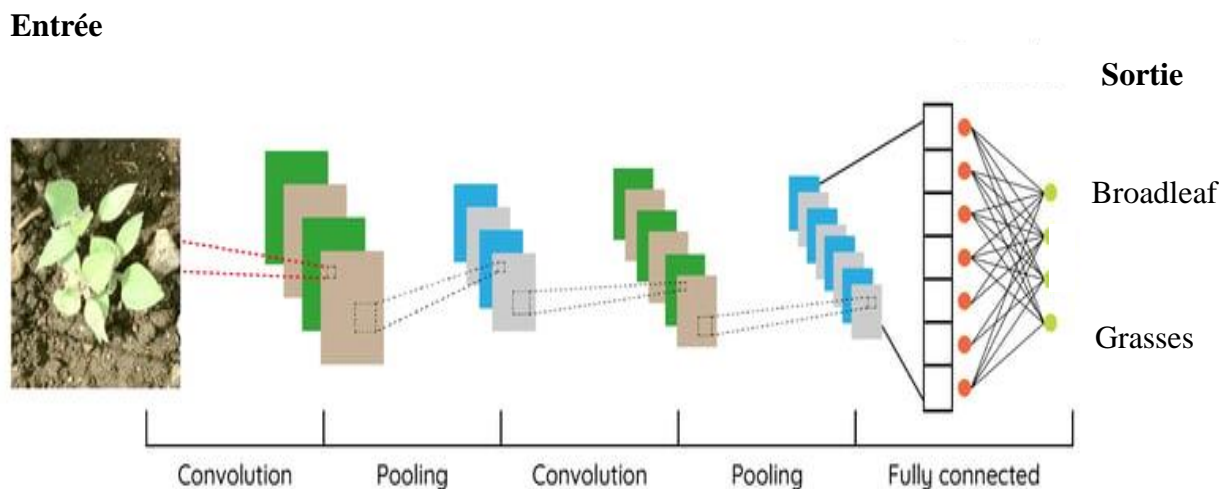


FIGURE 2.4 – Classification des mauvaises herbes par les CNN

a. La couche d'entrée (Input Layer)

La couche d'entrée est la première couche d'un réseau de neurone convolutif, elle est chargée de recevoir les données d'entrée. En particulier, dans le cas des réseaux Deep Learning pour l'analyse d'images, la couche d'entrée reçoit une image sous la forme d'une matrice bidimensionnelle (2D) ou tridimensionnelle (3D) représentant la hauteur, la largeur et la profondeur de l'image (canaux de couleur), respectivement. [6]

Avant que les images arrivent au niveau de la couche d'entrée, elles sont généralement converties en images numériques à l'aide de techniques d'imagerie numérique et de capteurs électroniques spécialement conçus à cet effet. Ensuite, elles sont transmises aux couches suivantes du réseau. [22]

b. La couche de convolution

La couche de convolution est la couche de principale des réseaux de neurones convolutifs, elle est chargée d'analyser les images à l'aide d'un ensemble de petits motifs appelés filtres ou Kernel. Les filtres déterminent les caractéristiques fondamentales de l'image en effectuant une opération de convolution sur les données provenant de la couche précédente et les transformées en un modèle de nombres, tout en contrôlant les caractéristiques sensibles telles que la netteté, la couleur et l'angle [23].

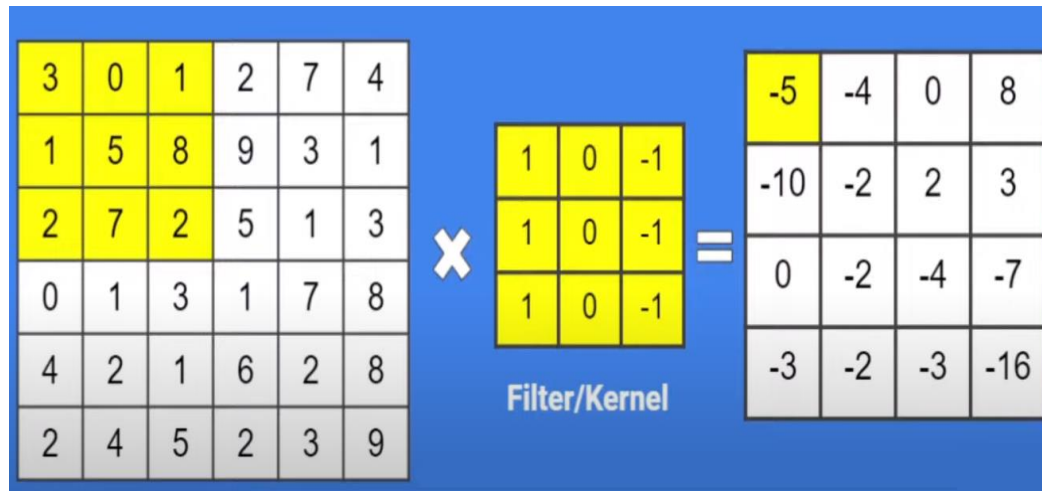


FIGURE 2.5 – Convolution 2D

Il y a trois hyper-paramètres sont utilisés pour régler le volume de la couche convolutive (volume de sortie) ; "profondeur", "pas" et "padding".

➤ **La profondeur** : la profondeur d'une couche liée au nombre et la taille des filtres. Il peut y avoir un nombre raisonnable de filtres. AlexNet a utilisé 96 filtres de taille 11×11 dans la première couche de convolution. VGGNet a utilisé 96 filtres de taille 7×7 , et une autre variante de VGGNet a utilisé 64 filtres de taille 11×11 dans la première couche de convolution.

➤ **Le pas** : contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.

➤ **Le padding** : se réfère à entourer une matrice avec des zéros. Cela peut aider à préserver les caractéristiques qui existent sur les bords de la matrice d'origine et contrôler la taille de la carte des caractéristiques de sortie.

0	0	0	0	0	0
0	5	8	9	3	0
0	7	2	5	1	0
0	1	3	1	7	0
0	2	1	6	2	0
0	0	0	0	0	0

FIGURE 2.6 – Le padding

c. La couche pooling :

La couche pooling est généralement placée entre deux couches convolutives. Elle vise à réduire progressivement la dimensionnalité de la représentation (image, matrice de sortie de la couche cachée, ...etc.), et donc à réduire le nombre de paramètres et la complexité de calcul du modèle [24]. Il existe différents types de pooling (Max pooling, pooling Moy, ...).

➤ **Pooling maximal** : cette technique consiste à extraire la valeur maximale à partir de chaque région locale de la carte de caractéristiques. Elle est très courante dans les CNN car elle permet de préserver les caractéristiques les plus discriminantes tout en réduisant la taille de la représentation.

➤ **Pooling moyen** : cette technique consiste à calculer la moyenne des valeurs de chaque région locale de la carte de caractéristiques. Elle est moins courante que le max pooling, mais peut être utile dans certaines situations où une réduction de la variance est souhaitée.

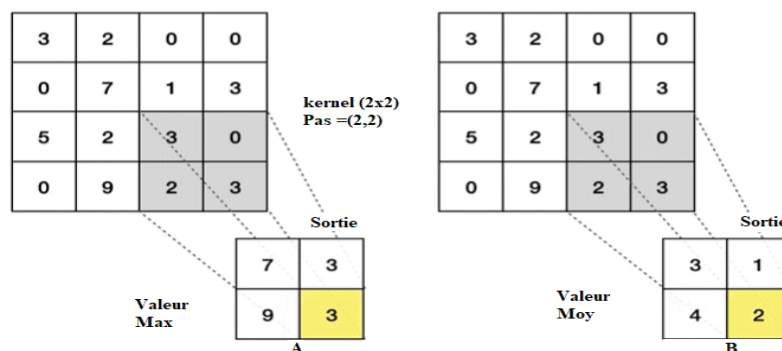


FIGURE 2.7 – (A) pooling maximal, (B) pooling moyen

d. La couche d'activation

La couche d'activation (Activation Layer) est l'une des couches de base des réseaux de neurones convolutifs. Sa fonction principale est de convertir les valeurs produites par la

couche de convolution ou la couche pooling en valeurs d'activation comprises entre 0 et 1 ou entre -1 et 1 selon la fonction utilisée. Cette couche contribue à introduire de l'imprévisibilité et de la complexité dans les réseaux de neurones convolutifs, et elle transforme les données brutes collectées en une forme interprétable et améliore la précision finale du modèle [25]. La couche d'activation est généralement composée de fonctions d'activation telles que Sigmoid, ReLU, Tanh, ...etc.

Les couches d'activation peuvent être empilées dans les réseaux de neurones convolutifs pour améliorer la précision finale du modèle, et plusieurs fonctions d'activation peuvent être utilisées ensemble pour améliorer les performances [26].

- **Sigmoïde** : La fonction Sigmoïde donne une valeur entre 0 et 1. Elle est donc très utilisée pour la classification binaire, cette fonction est donnée par

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$




FIGURE 2.8 –Fonctions sigmoïde

- **Tanh** : La fonction tanh est simplement la fonction de la tangente hyperbolique. Il s'agit en fait d'une version mathématiquement décalée de la fonction sigmoïde (tanh donne un résultat entre -1 et 1). L'avantage de tanh est que les entrées négatives seront bien répertoriées comme négatives là où, avec sigmoïde, les entrées négatives peuvent être confondues avec les valeurs proche de nulles.




FIGURE 2.9 –Fonctions tanh

- **Relu (Rectified Linear Unit)** : La fonction Relu est la fonction d'activation la plus simple et la plus utilisée. Elle donne x si x est supérieur à 0 et 0 sinon. Donc, elle donne le maximum entre x et 0.

$$\text{Relu}(x) = \max(x,0) \quad (2.2)$$




FIGURE 2.10 –Fonctions Relu

- **Leaky Relu** : La Leakey Relu permet d'ajouter une variante pour les nombres négatifs, ainsi les neurones ne meurent jamais. Ils entrent dans un long coma mais on toujours la chance de se réveiller à un moment donné.

$$L_Relu(x) = \max(ax, x) \quad (2.3)$$




FIGURE 2.11 –Fonctions Leakey Relu

- **ELU (Exponential Linear Unit)** : La fonction ELU est une amélioration de Relu car elle permet d'avoir des valeurs lisses lorsque $x < 0$. Pour $x < 0$, ELU a des valeurs négatives différents de 0 (ce qui n'est pas le cas de Relu). Effectivement, plus x diminue, plus ELU saturent à une valeur négative. Cette fonction est définie comme suite

$$ELU = \begin{cases} x: & x \geq 0 \\ \alpha(e^x - 1): & x < 0 \end{cases} \quad (2.4)$$




FIGURE 2.12 –Fonctions ELU

e. La couche entièrement connectée (FC : fully connected)

Dans les opérations entièrement connectées des réseaux de neurones, la représentation d'entrée est aplatie en vecteurs de caractéristiques et passée à travers le réseau de neurones pour prédire les probabilités de sortie. Le schéma suivant décrit l'opération d'aplatissement :




FIGURE 2.13 –Opération d’aplatissement

Les vecteurs de caractéristiques sont ensuite passés à travers plusieurs couches denses (entièrement connectées). A chaque couche dense, les vecteurs caractéristiques subissent les mêmes opérations que dans les réseaux de neurones classiques. Les couches entièrement connectées aident à cartographier les représentations entre l’entrée et la sortie.

f. Fonction de perte

Pour maximiser l’apprentissage dans un réseau de neurones, il est essentiel de réduire au minimum l’erreur. C’est ainsi que nous définissons la fonction de perte, également connue sous le nom de fonction de coût ou d’erreur [27].

Il existe plusieurs fonctions qui peuvent être utilisées pour déterminer les erreurs, mais dans le contexte de Deep Learning, les deux fonctions les plus couramment utilisées sont :

➤ **Méthode du maximum de vraisemblance** : la méthode du maximum de vraisemblance tente de trouver la valeur optimale du paramètre en maximisant la fonction de vraisemblance dérivée des données d’apprentissage [28].

➤ **Méthode de l’entropie croisée (Cross-Entropy)** : Dans le cas de problèmes de classification utilisant des réseaux de neurones convolutifs comme notre étude, la fonction d’entropie croisée est privilégiée. Il est donné par la formule suivante :

$$\sum_{c=1}^M (y_c \log \hat{y}_c) \quad (2.5)$$

Où M est le nombre de classes, et \hat{y}_c est la prédiction du modèle pour cette classe y_c à la

valeur de 0 ou 1.

2.3.2 Les modèles de Deep Learning basés sur CNN

Il existe plusieurs modèles de Deep Learning basés sur les CNN proposés dans le domaine d'identification et de classification des images. Dans ce travail on va considérer les modèles les plus reconnus : ResNet 50, VGG16, VGG19 et EfficientNet-B0.

2.3.2.1 Modèle ResNet 50 (Residual Network)

ResNet est une technique utilisée dans le domaine de l'apprentissage automatique, en particulier l'analyse et la reconnaissance et classification d'images. Il a été développé par des chercheurs de Microsoft dans un article scientifique intitulé " Deep Residual Learning for Image Recognition ". [29]

La méthode ResNet est basée sur les réseaux de neurones profonds et l'utilisation de blocs résiduels pour résoudre le problème de la dégradation des performances du modèle à mesure que la profondeur du réseau augmente.

Cette technique consiste à entraîner un modèle et stocker des informations résiduelles en ajoutant des blocs résiduels au modèle de base. Ce processus améliore la dégradation susmentionnée.

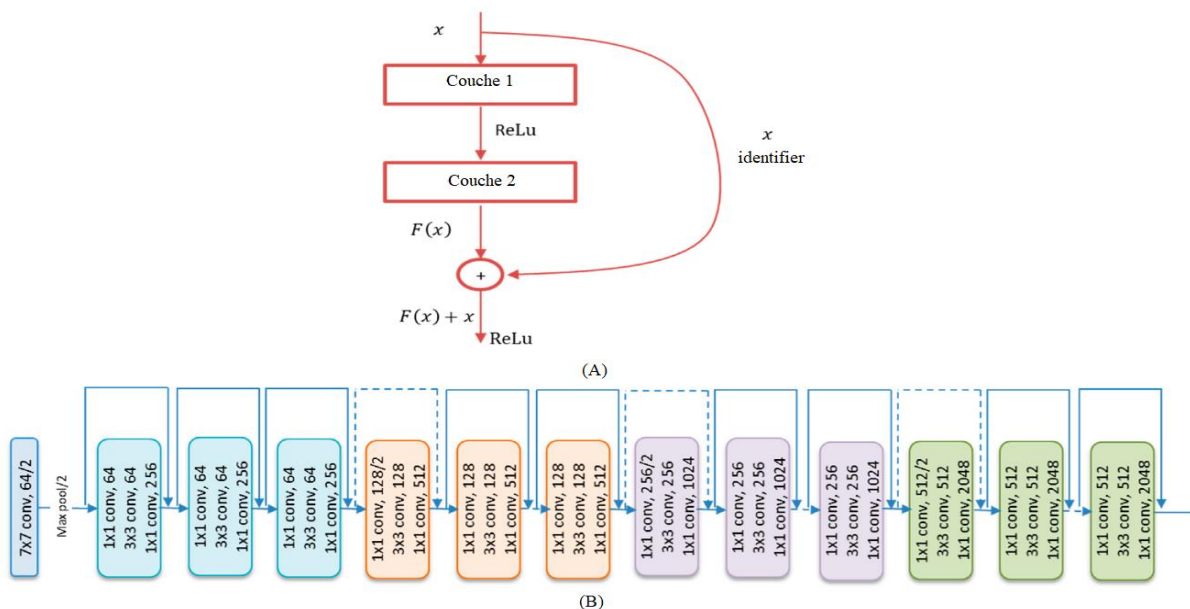


FIGURE 2.14 – (A) Bloc résiduel, (B) architecture de ResNet 50

2.3.2.2 Modèle VGG16

Le modèle VGG16 est un réseau neuronal convolutif développé particulièrement pour la classification d'images [30]. Le modèle se compose de 16 couches, y compris des couches d'entrée et de sortie.

Le modèle se distingue par ses avantages en matière de classification et de reconnaissance d'images, grâce à sa conception profonde lui permettant de mieux comprendre les images. Le modèle réduit également le problème de similarité entre les objets dans les images, qui survient parfois lors de l'utilisation d'autres modèles.

Le modèle VGG16 a été appliqué à de nombreuses applications nécessitant une classification d'images, telles que la reconnaissance faciale, la classification d'images médicales, ...etc. De plus, le modèle VGG16 a été une source d'inspiration pour le développement de nouveaux modèles dans le domaine de la classification et de la reconnaissance d'images.




FIGURE 2.15 –L'architecture de VGG16

2.3.2.3 Modèle VGG19

Le modèle VGG19 est un modèle de réseau neuronal profond utilisé dans la reconnaissance d'image. Il a été proposé dans [30]. Le VGG19 se caractérise par sa profondeur, avec un total de 19 couches. Les couches convolutives sont utilisées pour transformer les images en une série de caractéristiques hiérarchiques, tandis que les couches entièrement connectées sont utilisées pour classer les images et extraire des informations spécifiques à une catégorie. [31]

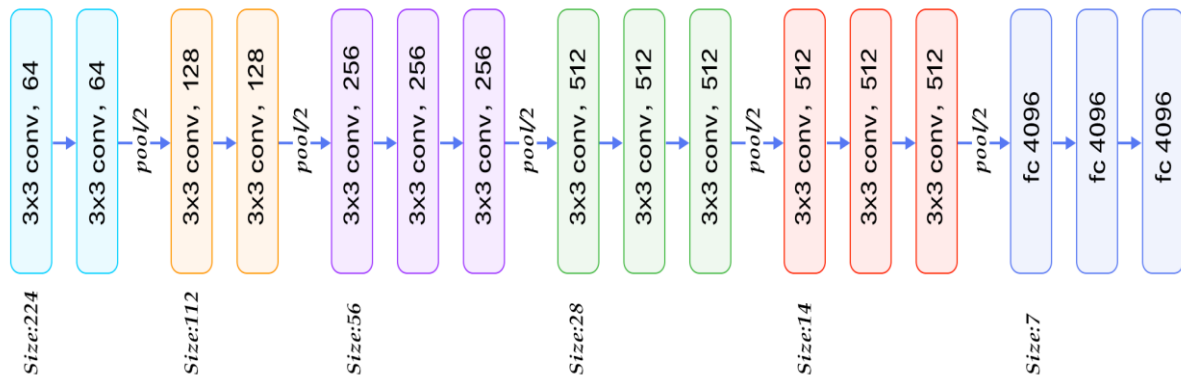


FIGURE 2.16 –L’architecture de VGG19

2.3.2.4 Modèle EfficientNet-B0

EfficientNet est une architecture de réseau neuronal convolutif conçue pour optimiser simultanément la profondeur, la largeur et la résolution du réseau. L'architecture utilise une combinaison de recherche automatique d'architecture neuronale (NAS) et de mise à l'échelle du modèle (scale model) [32] :

✓ Recherche automatique d'architecture neuronale

NAS est une méthode de recherche automatique de la meilleure architecture des réseaux de neurones profonds. L'idée est d'utiliser des algorithmes d'apprentissage automatique pour générer des architectures qui optimisent une fonction objectif spécifique. EfficientNet utilise une variante de NAS appelée MBConv (Mobile Inverted Residual Bottleneck Convolution) pour générer son architecture.

✓ Mise à l'échelle du modèle

La mise à l'échelle du modèle implique d'augmenter la profondeur, la largeur et la résolution du réseau selon des principes. EfficientNet utilise une méthode de mise à l'échelle composée qui redimensionne uniformément les dimensions du réseau. Le facteur d'échelle est contrôlé par un coefficient qui est optimisé pendant le processus NAS.




FIGURE 2.17 – L’architecture de l’EfficientNet-B0

2.4 Conclusion

Dans ce chapitre, nous avons présenté les caractéristiques de classification des mauvaises herbes. En particulier, l’apparence extérieure où les mauvaises herbes sont classées en deux catégories suivant le format de leurs feuilles, Grass et Groadleaf. De plus, on a expliqué le principe de fonctionnement d’un réseau CNN. Par la suite, nous avons rappelé les différents modèles et architectures les plus reconnus dans le domaine de classification d’image. Dans ce mémoire, nous avons considéré les modèles ResNet50, VGG16, VGG19 et EfficientNet-B0. Dans l’objectif d’illustrer les performances des différents modèles considérés, une étude comparative sera établie dans le chapitre suivant.

Chapitre 3

Résultats et discussion

3.1 Introduction

Ce chapitre sera consacré sur l'évaluation des performances des différents modèles présentés précédemment, ResNet50, VGG16, VGG19 et EfficientNet-B0. Cette analyse est effectuée utilisant une base de données de mauvaises herbes qui contient deux classes suivant leur format de feuille. L'environnement de travail exploite dans cette étude est Google Colab. Les performances sont évaluées à l'aide des critères de mesures utilisés dans le domaine de classification d'images.

3.2 Description de la base de données

La base de données utilisées dans ce travail est une collection d'image de plusieurs classes de mauvaises herbes créée par Alessandro et al [33]. Cette base de données est caractérisée par sa robustesse et clarté. Dans notre étude, on a considéré les deux classes grass et broadleaf, la classe de grass contient 3520 images et la classe broadleaf contient 1991 images. La catégorie grass est caractérisée par des feuilles étroites de forme d'aiguille et la catégorie broadleaf est caractérisée par des feuilles larges et plates.



FIGURE 3.1 – Exemple de données (Broadleaf, Grass)

3.3 Environnement utilisé : Google Colab

Google Colab est une plate-forme cloud puissante et sophistiquée qui permet aux utilisateurs de consommer et de développer un environnement Python via un navigateur. Google Colab est la solution idéale pour les développeurs, les chercheurs, les étudiants en sciences et les passionnés de codage, offrant un environnement convivial et interactif pour travailler sur des projets d'intelligence artificielle et d'analyse de données volumineuses.



FIGURE 3.2– Environnement de travail

Google Colab offre un certain nombre de fonctionnalités avancées, notamment l'accès au CPU et au GPU. L'accès aux processeurs et aux GPU fournit une puissance de calcul massive, permettant d'effectuer des expériences d'apprentissage en profondeur et d'analyser des données plus efficacement. La collaboration de Google avec des processeurs et des GPU de hautes performances aide à obtenir des performances époustouflantes, une formation plus rapide et une analyse de données volumineuses. [34]

3.4 Critères d'évaluation des performances

L'évaluation des performances des modèles de Deep Learning est une étape intéressante qui nous donne un aperçu sur l'efficacité et la précision. De nombreux critères d'évaluation existent dans la bibliographie de l'apprentissage automatique [35]. Les critères d'évaluation les plus utilisés dans ce domaine sont présentés ci-dessous.

3.4.1 Confusion Matrix

Confusion Matrix est une matrice $n \times n$ utilisé pour visualiser les résultats d'un modèle prédictif dans un problème de classification, où n est le nombre de classes dans l'ensemble de données. Dans cette matrice, la véritable classe cible est intersectée avec la classe prédite obtenue. Cela nous donne le nombre d'instances correctes et erronées [36].

		Réponse de l'expert	
		p	n
Réponse de classifier	Y	Vrai Positive	Faux Positive
	N	Faux Négative	Vrai Négative

FIGURE 3.3– Confusion Matrix

Confusion Matrix fournit des informations détaillées sur les performances du modèle pour chaque classe. La matrice comprend quatre mesures principales :

- *Les vrais positifs (True Positive TP)* : le nombre d'instances positifs correctement classés.
- *Les faux positifs (False Positive FP)* : le nombre d'instances positifs mal classés.
- *Les faux négatifs (False Negative FN)* : le nombre d'instances négatifs mal classés.
- *Les vrais négatifs (True Negative TN)* : le nombre d'instances négatives correctement classées.

Ces mesures peuvent être utilisées pour calculer d'autres critères d'évaluation comme suite :

a. Accuracy

Accuracy de la classification est la mesure la plus courante des performances des modèles. Elle est calculée en comparant le nombre de classification vrais avec toutes les classifications effectuées par le modèle [37].

$$\text{Accuracy} = (3.1) \quad \frac{TP + TN}{TP + TN + FP + FN}$$

b. Precision

Precesion de la classification est calculée en comparant le nombre des classifications vrais positives avec le nombre de toutes les classifications vrais [37].

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.2)$$

c. Recall

Recall est une métrique utilisée pour nous indique la capacité d'un modèle à détecter tous les classifications vrais positives dans un problème de classification [38].

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.3)$$

d. F1-Score

Le F1-Score peut être interprété comme une moyenne pondérée de Precision et Recall, où la meilleure valeur du F1-Score est 1 et la pire valeur est 0. Par conséquent, le F1-Score prend en compte à la fois les classifications fausses positives et fausses négatives. F1-Score est calculé utilisant à la fois Precision et Recall [39].

$$\mathbf{F1-Score} = \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.4)$$

3.5 Analyse des performances

Premièrement, l'ensemble de données est divisé en groupes. Le premier groupe est utilisé pour l'apprentissage (training) et contient 70% des données, tandis que le deuxième groupe est utilisé pour la validation et contient 20% des données et le troisième groupe 10% pour les tests. La présente section vise à fournir un ensemble équilibré de données pour l'apprentissage, la validation et les tests, pour aider à évaluer le rendement du modèle sur des données inconnues et pour obtenir des résultats plus précis et généraux.

Les modèles ont été formés selon les paramètres suivants :

- Optimizer : Adam
- Learning rate = 0,001
- Batch size = 32
- Epochs = 10

Les résultats obtenus pour chaque modèle sont comme suit :

3.5.1 ResNet50

Les résultats de l'entraînement et de validation du modèle ResNet50 sont présentés dans la «figure 3.4 ». La courbe Accuracy est un outil qui reflète les variations de précision tout au long du processus d'entraînement et de validation. Cette courbe permet de mesurer l'amélioration de Accuracy au fur et à mesure que les étapes d'entraînement et de validation progressent sur un certain nombre d'époques. Dans la « Figure 3.4 » ci-dessus, le modèle ResNet50 atteint une Accuracy d'environ 99% en utilisant les paramètres mentionnés précédemment.

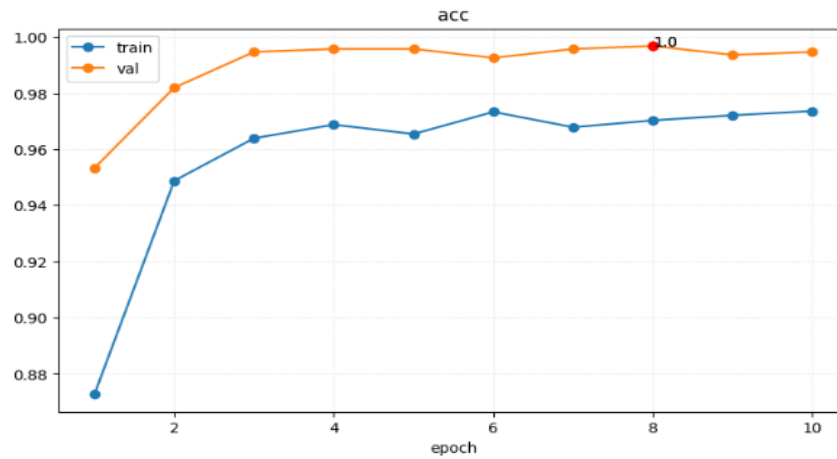


FIGURE 3.4– Accuracy et Validation du ResNet50

Confusion Matrix pour le modèle ResNet50 « figure 3.5 » montre que le modèle a fait une seul classification fausse.

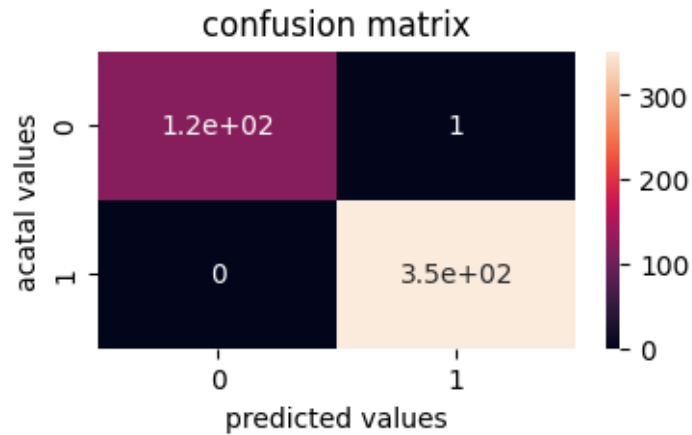


FIGURE 3.5– Confusion Matrix du ResNet50

Les autres critères sont calculés basant sur la Confusion Matrix, le « Tableau 3.1 » montre qu'une Accuracy de 99,79 %.

	precision	recall	f1-score	support
broadleaf	1.000	0.9917	0.9958	120
grass	0.9972	1.0000	0.9986	352
accuracy			0.9979	472

Tableau 3.1- Performances du ResNet50

3.5.2 VGG16

Résultats de l'entraînement et la validation du modèle VGG16 est illustrés dans la « figure 3.6 ». Cette figure indique la progression du modèle au cours du processus d'entraînement et de validation utilisant les mêmes paramètres.




FIGURE 3.6– Accuracy et Validation du VGG16

La « figure 3.7 » présente la Confusion Matrix du modèle VGG16. Cette matrice montre que le modèle a commis des erreurs de classification pour 5 instances.




FIGURE 3.7– Confusion Matrix du VGG16

Le « Tableau 3.2 » montre que l'Accuracy est de 98,94%, ce qui indique que le modèle a correctement classé 98,94 %.

	precision	recall	f1-score	support
broadleaf	1.000	0.9583	0.9787	120
grass	0.9860	1.0000	0.9929	352
accuracy			0.9894	472

Tableau 3.2- Performances du VGG16

3.5.3 VGG19

Les résultats de l’entrainement et de validation du modèle VGG19 sont illustrés dans La « figure 3.8 », cette figure montre que le modèle a atteint des excellentes performances après 10 Epochs.




FIGURE 3.8–Accuracy et Validation du VGG19

Confusion Matrix du modèle VGG19 est présentée dans la « figure 3.9 ».




FIGURE 3.9– Confusion Matrix du VGG19

Les autres critères d'évaluation sont résumés dans le « Tableau 3.3 ».

	precision	recall	f1-score	support
broadleaf	0.9915	0.9750	0.9832	120
grass	0.9915	0.9972	0.9943	352
accuracy			0.9915	472

Tableau 3.3- Performances du VGG19

3.5.4 EfficientNet-B0

Résultats de l'entraînement et de validation du modèle EfficientNet-B0 est montré dans la « figure 3.10 », cette figure montre que le processus d'entraînement et de validation est effectué pour 10 Epochs.




FIGURE 3.10–Accuracy et Validation du EfficientNet-B0

La « figure 3.11 » montre que le modèle a mal classé 3 images du total des données de test.




FIGURE 3.11– Confusion Matrix du EfficientNet-B0

Le « Tableau 3.4», montre que l’Accuracy du modèle EfficientNet-B0 est de 99,36 %.

	Precision	Recall	F1-score	Support
Broadleaf	0.9916	0.9833	0.9874	120
Grass	0.9943	0.9972	0.9957	352
Accuracy			0.9936	472

Tableau 3.4- Performances du EfficientNet-B0

3.6 Comparaison des résultats

D’après les résultats de classification des deux classes des mauvaises herbes à savoir grass ou broadleaf obtenus précédemment. Basant sur les différentes Confusion Matrix, on observe que le modèle ResNet50 offre le plus faible nombre de fausse classification par rapport aux autres modèles avec une seule instance mal classée suivi par le modèle EfficientNet-B0 avec trois fausses classification.

Le « Tableau 3.5 » présente une comparaison de l’Accuracy des modèles ResNet50, VGG16, VGG19, et EfficientNet-B0. Il est clair que le modèle ResNet50 donne le meilleur résultat par rapport aux autres modèles avec une Accuracy de 99,79%, EfficientNet-B0 il atteint une Accuracy de 99,36%, VGG19 avec une Accuracy de 99,15% et le VGG16 avec une Accuracy de 98,94%.

Modèle	Accuracy (%)
ResNet50	99.79
Vgg16	98.94
Vgg19	99.15
EfficientNet-B0	99.36

Tableau 3.5- Comparaison de modèles

3.8 Conclusion

Dans ce chapitre, nous avons présenté la base de données utilisées pour l’apprentissage et le test des modèles ResNet50, VGG16, VGG19, EfficientNet-B0. Cette base de données contient deux classes de mauvaises herbes, grass et broadleaf. Dans le but d’évaluer les performances des différents modèles, une étude comparative a été réalisée en utilisant les différents critères d’évaluation. Les résultats obtenus montrent que le modèle ResNet50 est le plus performant avec une grande précision.

Conclusion générale

Conclusion générale

La classification des mauvaises herbes est un facteur important pour l'amélioration du rendement agricole, cette classification aide l'agriculteur de sélectionner le type d'herbicide approprié pour traiter ces mauvaises herbes.

Dans le cadre de ce mémoire, nous avons étudié un système efficace capable d'identifier et de classer les mauvaises herbes avec une grande précision à l'aide de Deep Learning. Ceci est réalisé en exploitant les modèles ResNet50, VGG16, VGG19 et EfficienNet-B0. L'apprentissage de ces modèles est effectué à travers une base de données d'images collectées de deux classes de mauvaises herbes, la première est nommé Grass qui est caractérisée par ces feuilles étroites sous la forme d'aiguille, la deuxième class est dite Broadleaf qui est caractérisée par ces feuilles larges.

Les modèles ResNet50, VGG16, VGG19 et EfficienNet-B0 s'appuient sur les réseaux de neurones profonds et des architectures optimisées pour extraire les caractéristiques importantes des images pour les classer avec précision.

D'après les résultats obtenus, nous pouvons conclure que l'utilisation des modèles ResNet50, VGG16, VGG19 et EfficienNet-B0 dans la classification des mauvaises herbes à l'aide de Deep Learning est prometteuse. Les comparaisons effectuées montrent que le modèle ResNet50 offre les meilleures performances avec une grande précision par rapport aux autres modèles.

Comme perspectives, nous proposons d'implémenter ces modèles dans des systèmes de surveillance en temps réels de lutte contre les mauvaises herbes dans les champs agricoles utilisant des Drones.

Bibliographies

Bibliographies

- [1]Dodou, D., & de Winter, J. C. (2014). Social desirability is the same in offline, online, and paper surveys: A meta-analysis. *Computers in Human Behavior*, 36, 487-495.
- [2]Lecun, Y. (2016). Les enjeux de la recherche en intelligence artificielle. Accès https://dataanalyticspost.com/wpcontent/uploads/2017/04/ylecun_college_France.
- [3]Russell, S. J. (2010). *Artificial intelligence a modern approach*. Pearson Education, Inc.
- [4]Lindsay, R. K., Buchanan, B. G., Feigenbaum, E. A., & Lederberg, J. (1993). DENDRAL: a case study of the first expert system for scientific hypothesis formation. *Artificial intelligence*, 61(2), 209-261.
- [5]Awad, M., & Khanna, R. (2015). *Efficient learning machines : theories, concepts, and applications for engineers and system designers* (p. 268). Springer nature.
- [6]Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [7]Géron, A. *Hands-on machine learning with scikit-learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*. 2019 : " O'Reilly .
- [8]Schölkopf, B., Smola, A. J., & Bach, F. (2002). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press
- [9]Chen, L. P. (2019). Mehryar Mohri, Afshin Rostamizadeh, and Ameet Talwalkar: *Foundations of machine learning: The MIT Press, Cambridge, MA, 2018, 504 pp*.
- [10]Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- [11] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- [12]Bolón-Canedo, V., Sánchez-Marono, N., Alonso-Betanzos, A., Benítez, J. M., & Herrera, F. (2014). A review of microarray datasets and applied feature selection methods. *Information sciences*, 282, 111-135.
- [13]Rumelhart DE, Hinton GE, Williams RJ (1986) Learning representations by backpropagating errors. *Nature* 323 :533–536.
- [14] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.

- [15] An, J., Li, W., Li, M., Cui, S., & Yue, H. (2019). Identification and classification of maize drought stress using deep convolutional neural network. *Symmetry*, 11(2), 256.
- [16] Cai, Z., Fan, Q., Feris, R. S., & Vasconcelos, N. (2016). A unified multi-scale deep convolutional neural network for fast object detection. In *Computer Vision—ECCV, 14th European Conference, Amsterdam, Netherlands, October 11–14, 2016, Proceedings, Part IV 14* (pp. 354-370). Springer International Publishing.
- [17] Venkatesan, R., & Li, B. (2017). *Convolutional neural networks in visual computing: a concise guide*. CRC Press.
- [18] Caussanel, J. P. (1989). Nuisibilité et seuils de nuisibilité des mauvaises herbes dans une culture annuelle: situation de concurrence bispécifique. *Agronomie*, 9(3), 219-240
- [19] Bhowmik, P. C., Inderjit., & Singh, K. (Eds.). (2019). *Biological management of weeds*. Springer
- [20] Zwiggelaar, R. (1998). A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop protection*, 17(3), 189-206
- [21] Bolón-Canedo, V., Sánchez-Marono, N., Alonso-Betanzos, A., Benítez, J. M., & Herrera, F. (2014). A review of microarray datasets and applied feature selection methods. *Information sciences*, 282, 111-135.
- [22] Zhao, M., Hu, C., Wei, F., Wang, K., Wang, C., & Jiang, Y. (2019). Real-time underwater image recognition with FPGA embedded system for convolutional neural network. *Sensors*, 19(2), 350.
- [23] O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458
- [24] Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
- [25] Rizzo, J., & Duong, T. (2010, August). Practical Padding Oracle Attacks. In *WOOT*.
- [26] Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- [27] Hien, D. (2017). *The Modern History of Object Recognition—Infographic*.
- [28] Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. 1). Cambridge, MA, USA: MIT press.
- [29] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [30] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

- [31] Sudha, V., & Ganeshbabu, T. R. (2021). A convolutional neural network classifier VGG-19 architecture for lesion detection and grading in diabetic retinopathy based on deep learning. *CMC-Computers Materials & Continua*, 66(1), 827-842
- [32] Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- [33] dos Santos Ferreira, A., Freitas, D. M., da Silva, G. G., Pistori, H., & Folhes, M. T. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314-324.
- [34] Kanani, P., & Padole, M. (2019). Deep learning to detect skin cancer using google colab. *International Journal of Engineering and Advanced Technology Regular Issue*, 8(6), 2176-2183
- [35] Malina, M. A., & Selto, F. H. (2004). Choice and change of measures in performance measurement models. *Management accounting research*, 15(4), 441-469.
- [36] Mozhgovoy, D., Hnatushenko, V., & Vasyliev, V. (2018, August). Accuracy evaluation of automated object recognition using multispectral aerial images and neural network. In *Tenth International Conference on Digital Image Processing (ICDIP 2018)* (Vol. 10806, pp. 124-131). SPIE.
- [37] Kavzoglu, T. (2009). Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software*, 24(7), 850-858.
- [38] Visa, S., Ramsay, B., Ralescu, A. L., & Van Der Knaap, E. (2011). Confusion matrix-based feature selection. *Maics*, 710(1), 120-127.
- [39] Yacoub, R., & Axman, D. (2020, November). Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. In *Proceedings of the first workshop on evaluation and comparison of NLP systems* (pp. 79-91).