



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ MATHÉMATIQUES ET INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : Génie Informatique

Par :

AOUCI ASMAA

Sur le thème

**Classification des images agricoles à l'aide de
I' Apprentissage profond**

Soutenu le 13 / 07/ 2023 à Tiaret devant le jury composé de :

Mr Chennine Abdelkader	MAA Université de Tiaret Président
Mr MAASKRI Mustapha	MCB Université de Tiaret Encadrant
Mr BoudaaBoudjemaa	MCA Université de Tiaret Examineur

2023/2024

Remerciements

En premier lieu Je tiens à remercier ALLAH qui m'adonné la santé et la capacité de réaliser et de présenter cette mémoire. Mes vifs sincères remerciements s'adressent spécialement à mon promoteur MUSTAPHA MAASKRI dont j'ai eu la chance d'avoir comme encadreur pour sa confiance, ses encouragements continus et son suivi de près de mes travaux durant la réalisation de mon mémoire. J'adresse mes remerciements les plus sincères aux membres du jury qui me font l'honneur de juger mon travail. Ma profonde gratitude et mes sincères remerciements vont à tous les enseignants qui m'ont suivi durant mon parcours d'études. Je tiens à exprimer mes vifs remerciements à mes parents pour leur soutien, leur patience et leurs encouragements tout au long de mon parcours universitaire.

Sans oublier d'exprimer ma reconnaissance envers mes frères, sœurs et mes amis pour leur encouragement. Merci à tous.

Résumé

La classification des images agricoles à l'aide de techniques d'apprentissage profond offre des possibilités prometteuses pour améliorer la gestion des cultures, la détection des maladies et la prise de décision agricole.

Ce projet se propose d'explorer les méthodes avancées de classification d'images dans le domaine de l'agricoles, Apprentissage profond.

Grâce aux technologies de télédétection et aux drones, la collecte d'images haute résolution des champs agricoles est désormais possible, offrant une mine d'informations sur les cultures, la santé des plantes et l'environnement. Cette classification, qui attribue des étiquettes aux images en fonction de leur contenu visuel, est cruciale pour les décisions de gestion des cultures, de lutte contre les ravageurs et les maladies, et d'optimisation des rendements. L'apprentissage profond présente des avantages significatifs, permettant de capturer des informations subtiles et de généraliser à partir de données limitées. Cette introduction explore les défis, les opportunités et les applications de cette technologie dans l'agriculture moderne, avec des implications pour sa durabilité et sa rentabilité.

Les motsclés :

Classification d'images agricoles, Apprentissage profond, Réseaux neuronaux convolutifs (CNN), prétraitement des données, Modèles pré-entraînés, Optimisation du modèle, Détection des maladies, Traitement d'images.

ملخص

يوفر تصنيف الصور الزراعية باستخدام تقنيات التعلم العميق إمكانيات واعدة لتحسين إدارة المحاصيل والكشف عن الأمراض واتخاذ القرارات الزراعية.

يهدف هذا المشروع إلى استكشاف طرق متقدمة لتصنيف الصور في مجال الزراعة والتعلم العميق

بفضل تقنيات الاستشعار عن بعد والطائرات بدون طيار، أصبح جمع الصور عالية الدقة للحقول الزراعية ممكنًا الآن، مما يوفر مصدرًا غنيًا بالمعلومات حول الزراعات وصحة النباتات والبيئة. تعتبر هذه التصنيفات، التي تعين العلامات إلى الصور بناءً على محتواها البصري، أمرًا حاسمًا لقرارات إدارة الزراعات ومكافحة الآفات والأمراض، وتحسين العائدات. يقدم التعلم العميق مزايا كبيرة، حيث يمكنه التقاط المعلومات الدقيقة والعمومية من البيانات المحدودة. تستكشف هذه المقدمة التحديات والفرص والتطبيقات لهذه التكنولوجيا في الزراعة الحديثة، مع الآثار على استدامتها وربحيته

الكلمات المفتاحية:

، المعالجة (CNN) تصنيف الصور الزراعية ، التعلم العميق ، الشبكات العصبية التلافيفية المسبقة للبيانات ، النماذج المدربة مسبقا ، تحسين النموذج ، اكتشاف الأمراض ، معالجة الصور.

Abstract

Classifying agricultural images using deep learning techniques offers promising possibilities for improving crop management, disease detection and agricultural decision-making.

This project aims to explore advanced methods of image classification in the field of agriculture, deep learning.

Thanks to remote sensing technologies and drones, collecting high-resolution images of agricultural fields is now possible, providing a wealth of information about crops, plant health, and the environment. This classification, which assigns labels to images based on their visual content, is crucial for decisions regarding crop management, pest and disease control, and yield optimization. Deep learning offers significant advantages, allowing for the capture of subtle information and generalization from limited data. This introduction explores the challenges, opportunities, and applications of this technology in modern agriculture, with implications for its sustainability and profitability.

Keywords:

Agricultural Image Classification, Deep Learning, Convolutional Neural Networks (CNN), Data Preprocessing, Pre-Trained Models, Model Optimization, Disease Detection, Image Processing

Table des matières

Remerciements

Résumé

Les mots-clé

Listes des figures

Problématique

Objectifs de la recherche

Chapitre I.....	1
I.1. Introduction :	2
I.2. L'intelligence artificielle :.....	2
I.2.1. L'utilisation de l'intelligence artificielle:.....	3
I.2.2. Les sous-domaines de l'IA:.....	3
I.2.3. Les avantages, inconvénients et les limites de l'intelligence artificielle:	
4	
I.2.3.1. Les avantages :.....	4
I.2.3.2. Les inconvénients :.....	4
I.3. Machine learning :	4
I.3.1. Différents procédés d'apprentissage automatique.....	5
I.3.1.1. Apprentissage automatique supervisé :.....	5
I.3.1.2. Apprentissage automatique non supervisé :.....	5
I.3.2. Les différents types d'apprentissage automatiques supervisé:	6
I.3.2.1. Classification :	6
I.3.2.2. Régression:	6
I.3.2.3. La différence entre régression et classification :	8
I.3.3. Différents algorithmes machine Learning :	9
I.3.3.1. Algorithmes d'apprentissage supervisé :	9
I.3.3.1.1. Naïve Bayes :	9
I.3.3.1.2. Classificateur de vecteur de support :	9

I.3.3.1.3. Support vector :.....	10
I.3.3.1.4. Arbres de décision :.....	11
I.3.3.2. Algorithmes d'apprentissage non supervisé :	12
I.3.3.2.1. K-meansclustering (K-moyenne) :.....	12
I.3.3.2.2. K plus proches voisins.....	13
I.3.3.2.3. Algorithme des k plus proches voisins (problème de classification): 13	
I.3.3.2.4. Régression logistique :	14
I.3.4. La différence entre apprentissage supervisé et non supervisé :	15
3. Conclusion :	16
Chapitre II.....	17
II.1. Introduction :	18
II.2. Deep Learning :	19
II.2.1. Modèles du Deep Learning :.....	20
II.2.2. Les différentes Architectures du Deep Learning :	20
II.2.2.1. Réseaux de neurones artificiels :.....	20
II.2.2.1.1. Problème de l'overfitting :	21
II.2.2.1.2. Fonction d'activation :.....	22
II.2.2.1.3. Fonction Sigmoidale :.....	22
II.2.2.1.3. Fonction Tanh :.....	23
II.2.2.1.4. Fonction ReLu :.....	24
II.2.2.1.5. Fonction Softmax :.....	24
II.2.2.1.6. Fonction d'erreur :	24
II.2.2.1.7. La régularisation :	24
II.2.2.1.8. Le Dropout :	25
II.2.2.1.9. Earlystopping :.....	26
II.2.2.2. Les réseaux neuronaux convolutionnels (CNN) :.....	26
II.2.2.2.1. Le principe de base d'un CNN pour le traitement d'images :.....	27
II.2.2.2.2. Couche convolutionnelle :.....	28
II.2.2.2.3. PoolingOperation:.....	28

II.2.2.3. Les réseaux de neurones récurrents :.....	30
II.2.2.3.1. Les types de réseaux de neurones récurrents :.....	30
II.2.2.3.2. Architectures RNN :	31
II.2.2.3.3. Réseaux Long Short-Term Memory (LSTM) :.....	32
II.2.3. Évaluation :	33
II.2.3.1. Mesures d'évaluation :.....	34
II.2.3.1.2. Justesse (Accuracy - Exactitude) :.....	34
II.2.3.1.5. F-mesure (F-score) :.....	35
II.2.3.2. Démarche d'évaluation :.....	36
II.2.3.2.1. Validation croisée simple :.....	36
II.3. Le traitement d'image :.....	37
II.3.1. Introduction :.....	Error! Bookmark not defined.
II.3.2. Image Numérique :.....	37
II.3.3. Acquisition d'Image :.....	38
II.3.4. Amélioration et restauration d'image :	39
II.3.5.1. Filtrage spatial passe-bas et passe-haut :	40
II.3.5.2. Moyennage et filtrage passe-bas spatial :.....	40
II.3.5.3. Masque de netteté et accentuation :.....	42
II.3.5.5. Filtre médian :.....	43
II.3.6. Traitement d'image VS Vision par ordinateur:	44
II.3.7. Conclusion :.....	Error! Bookmark not defined.
II.4. Image Classification :.....	45
II.4.1. Introduction :.....	Error! Bookmark not defined.
II.4.2. Les motivations de la classification d'images :.....	45
II.4.3. Classification :.....	46
II.4.3.1. La classification binaire :	46
II.4.3.2. Multi-class classification:	47
II.4.4. Conclusion :.....	47
Chapitre III	17

III.1. Introduction :	51
III.2. L'Agronomie :	51
III.3. L'Agriculture :	52
III.3.1. L'Agro écologie :	52
III.3.2. L'Agroforesterie :	53
III.4. Plante :	53
III. 3.1. Les maladies des plantes :	54
III.3.1.1. Alternariose :	55
III.3.1.2. Anthracnose :	56
III.3.1.3. Brûlure :	57
III.3.1.4. Eclatement ou fissuration des fruits :	57
III.3.1.5. Fonte des semis :	58
III.3.1.6. Hernie du chou :	59
III.3.1.7. Mildiou :	59
III.3.1.8. Moniliose :	60
III.3.1.9. Montaison :	61
III.3.1.10. Nécrose apicale :	61
III.3.1.11. Oïdium :	62
III.3.1.12. Phytophthora :	62
III.3.1.13. Pourriture grise – botrytis :	63
III.3.1.14. Rouille :	64
III.3.1.15. Virose :	64
III.4. Détection des maladies des plantes :	65
III.5. Caractéristiques du système de diagnostic des maladies des plantes :...	66
III.6. Etude de cas :	67
Chapitre IV	69
IV.1. Introduction :	70
IV.2. Les outils de développements :	70
IV.2.1. Python :	70

IV.2.2. Anaconda :	70
IV.2.3. Google Colaboratory :	71
IV.3. Bibliothèques utilisées :	72
IV.3.1. TensorFlow:	72
IV.3.3. OpenCV:	73
IV.3.4. Numpy :	74
IV.3.4. Pandas :	74
IV.4. Lettuce plant diseasedataset:	74
IV.4.1. Data augmentation (Image Data Generator) :	75
IV.4.2. Data Distribution:	76
IV.4.2.1. Image preprocessing (Image enhancement) :	78
IV.4.2.2. Image Enhancement :	78
IV.5. Transfer Learning:	83
IV.5.1. Avantages du transfert d'apprentissage :	83
IV.5.2. Exemple d'application :	84
IV.6. Conclusion :	89
Conclusion général	87
Les Références Bibliographiques	88

Listes des figures

Figure 1: Les sous-domaines de l'IA.	3
Figure 2: représentation des données d'un tableau.	7
Figure 3: ligne de régression.	8
Figure 4: La différence entre régression et classification.	8
Figure 5: Algorithmes d'apprentissage supervisé.	9
Figure 6 : Tracer une ligne qui sépare les cercles noirs et les carrés bleus.	10
Figure 7: échantillon coupé à diviser en deux classes.	10
Figure 8: vecteur de support.	10
Figure 9: Arbre de décision.	11
Figure 10: L'algorithme de clustering k Means fonctionne.	12
Figure 11: K plus proches voisins.	13
Figure 12 : La relation entre l'intelligence artificielle et le ML et le deep learning.	19
Figure 13 : Processus des modèles d'apprentissage automatique classique versus apprentissage profond.	20
Figure 14: Modèles du deeplearning.	20
Figure 15: Un neurone réel.	21
Figure 16: Un neurone artificiel	21
Figure 17: Trois modèles de classifieurs à différents niveaux d'apprentissage. .	22
Figure 18: Représentation du graphe de fonction Sigmoidé.	23
Figure 19: Représentation du graphe de fonction Tanh.	23
Figure 20: Représentation du graphe de fonction Relu.	24
Figure 21: Problème du sur apprentissage.	25
Figure 22: Explication du fonctionnement du Dropout.	26
Figure 23: Fonctionnement de l'Earlystopping.	26
Figure 24: Les parties du CNN.	28
Figure 25 : exemple d'une opération de convolution.	28
Figure 26: Exemple d'une opération pooling avec la mise en commun maximale.	29
Figure 27: Les parties du CNN.	30
Figure 28 : Recurrent Neural Network (RNN).	32
Figure 29: cellule LSTM.	33

Figure 30: Capture d'image : Une scène est éclairée par l'énergie provenant d'une source lumineuse. La lumière réfléchiée peut tomber sur le détecteur et être capturée.....	39
Figure 31: exemple de filtre médian utilisant une fenêtre d'échantillonnage 3*3.	44
Figure 32:Transition du Traitement d'Image à la Vision par Ordinateur.	45
Figure 33 : représentant des plantes.	54
Figure 34 : les types de maladies.	55
Figure 35 : ALTERNARIOSE[4].	56
Figure 36 : Anthracnose [4].	56
Figure 37 : Brûlure [4].	57
Figure 38 : Eclatement ou fissuration des fruits [4].	58
Figure 39 : Fonte des semis[4].	58
Figure 40 : Hernie du chou [4].	59
Figure 41 : Mildiou [4].	60
Figure 42 : Moniliose [4].	60
Figure 43 : Montaison[4].	61
Figure 44 : Nécrose apicale [4].	61
Figure 45 : Oïdium[4].	62
Figure 46 : Phytophthora[4].	63
Figure 47 : Pourriture grise – botrytis [4].	63
Figure 48 : Rouille[4].	64
Figure 49 : Virose [4].	65
Figure 50 : Schéma d'un système de diagnostic des maladies des plantes.	66
Figure 51 : maladies et ravageurs des salades [7].	67
Figure 52:ANACONDA NAVIGATEUR.	71
Figure 53: GOOGLE Collaboratory.	72
Figure 54: Lettuce plant disease data set.	75
Figure 55: data augmentation.	76
Figure 56: Data distribution.	76
Figure 57: Les classes.	77
Figure 58:Image enchancement.	78
Figure 59:Architecture de notre modèle.	79
Figure 60: Résultat train et validation.	80
Figure 61:Résultat Obtenus après l'évaluation du notre model.	81

Figure 62: Predicted class: Bacterial.....	82
Figure 63: Matrice de confusion pour CNN.	83
Figure 64:Le résultat du « Train and Validation » de VGG16.	85
Figure 65:Résultat du « Train et Validation » InceptionV3.....	86
Figure 66: Accuracy Comparaison.	87

Liste des tableaux :

Tableau 1:exemple simple.	7
Tableau 2:Matrice de confusion.	34

Introduction générale

La classification d'images agricoles à l'aide de l'apprentissage profond est devenue un sujet d'intérêt majeur dans le domaine de l'agriculture de précision et de la gestion des cultures. Avec l'avènement des technologies de télédétection et des drones, il est désormais possible de collecter de grandes quantités d'images haute résolution couvrant les champs agricoles à des intervalles réguliers. Ces images offrent une mine d'informations sur l'état des cultures, la santé des plantes, et les conditions environnementales.

La classification d'images agricoles consiste à attribuer des étiquettes ou des catégories à des images de champs agricoles en fonction de leur contenu visuel. Cela peut inclure la détection des types de cultures, l'identification des mauvaises herbes, la cartographie des maladies des plantes, et bien d'autres applications. Cette tâche est essentielle pour les agriculteurs et les gestionnaires de cultures, car elle leur permet de prendre des décisions éclairées en matière de gestion des cultures, de traitement des ravageurs et des maladies, et d'optimisation des rendements.

L'utilisation de l'apprentissage profond dans la classification d'images agricoles offre plusieurs avantages significatifs. Les réseaux neuronaux profonds peuvent apprendre des caractéristiques complexes et abstraites à partir des images, ce qui leur permet de capturer des informations subtiles et difficiles à quantifier à l'œil nu. De plus, ils sont capables de généraliser à partir de données d'entraînement limitées, ce qui les rend adaptés à des environnements agricoles variés et changeants.

Dans cette introduction, nous explorerons les défis et les opportunités de la classification d'images agricoles à l'aide de l'apprentissage profond. Nous examinerons également les différentes applications de cette technologie dans le domaine agricole, ainsi que les implications potentielles pour l'amélioration de la durabilité, de l'efficacité et de la rentabilité de l'agriculture moderne.

Problématique

Pour surmonter ces défis, il est crucial de développer des solutions de détection des maladies qui soient à la fois précises, rapides, abordables, et faciles à utiliser pour les producteurs de salade. L'intégration de l'intelligence artificielle et des systèmes de surveillance basés sur les capteurs pourrait offrir des perspectives intéressantes pour améliorer la détection et la gestion des maladies dans les cultures de salade.

Objectifs de la recherche

L'objectif de ce mémoire est de développer des méthodes de détection automatiquement les maladies sur les plantes. Le système sera capable de classifier les catégories en trois : Bacterial, Fungal, Healthy. Ces systèmes permettra de collecter, traiter et classer les catégories 0,1,2 en utilisant des techniques de l'Apprentissage profond.

Organisation du mémoire

Après cette introduction générale, le reste de notre travail est structuré comme suit :

- **Le premier chapitre**

Dans ce chapitre, j'ai consacré une section à l'intelligence artificielle, explorant ses différents aspects, applications et implications." Cela indique clairement que vous avez traité de l'intelligence artificielle.

- **Le deuxième chapitre**

Dans ce chapitre, j'ai exploré le domaine du deep learning en me concentrant spécifiquement sur le traitement et la classification d'images. J'ai examiné les méthodes, les algorithmes et les applications de cette technologie, en mettant en lumière ses avancées et ses défis actuels.

- **Le troisième chapitre**

Dans ce chapitre, j'ai abordé le domaine de l'agronomie en me penchant particulièrement sur la détection des maladies chez les plantes. Ainsi que sur les différents types de maladies rencontrées.

- **Le quatrième Chapitre**

Dans ce chapitre, j'explore l'implémentation de chaque modèle ainsi que les résultats obtenus

Chapitre I :

I.1. Introduction

L'intelligence artificielle (IA) est un domaine en constante évolution, rendant sa définition précise difficile à établir. Les premiers chercheurs dans ce domaine visaient à créer des machines intelligentes capables d'exécuter des tâches intellectuelles complexes similaires à celles des êtres humains. Cependant, ils ont rapidement reconnu les limitations de leurs ambitions initiales. Par la suite, les chercheurs ont poursuivi leurs efforts en explorant de nouvelles techniques informatiques, tant au niveau des logiciels que du matériel. Ils ont également développé des langages de programmation orientés objet et des machines spécialement conçues pour la programmation symbolique, comme le langage LISP [32].

Au fil des années de recherche, l'IA a quitté les laboratoires pour s'intégrer dans notre quotidien. Par exemple, elle nous aide à naviguer en ville en évitant les embouteillages grâce à des systèmes de navigation intelligents. De plus, nous utilisons des assistants virtuels pour accomplir diverses tâches, telles que la gestion de nos calendriers, la recherche d'informations ou l'automatisation de certaines actions.

L'IA continue de progresser et de trouver de nouvelles applications dans de nombreux domaines, tels que la médecine, la finance, l'industrie, l'agriculture, et bien d'autres. Elle offre des possibilités sans précédent d'automatisation, d'optimisation et de prise de décision basée sur les données [18].

I.2. L'intelligence artificielle

L'intelligence artificielle, ou IA, est une discipline scientifique et technologique visant à doter les machines, telles que les ordinateurs et les logiciels, de la capacité d'exécuter des processus cognitifs habituellement associés au cerveau humain. Ces processus incluent la compréhension, la communication (tant entre les machines qu'avec les humains), l'adaptation et l'apprentissage autonome grâce à des techniques telles que le deep learning. [41].

Chapitre I : L'intelligence artificielle et ses applications.

I.2.1. L'utilisation de l'intelligence artificielle

Au fil des années récentes, l'intelligence artificielle a intégré nos vies quotidiennes et ne cesse d'évoluer rapidement. Voici quelques exemples illustrant son utilisation répandue : [41].

- Les systèmes de messagerie électronique.
- Les réseaux sociaux.
- Les moteurs de recherche.
- Les outils de traduction.
- Les plateformes de commerce en ligne.
- Les applications de navigation.
- Reconnaissance d'image.

I.2.2. Les sous-domaines de l'IA

- Traitement du langage naturel.
- Robotique.
- Apprentissage automatique.
- Système d'aide à la décision.

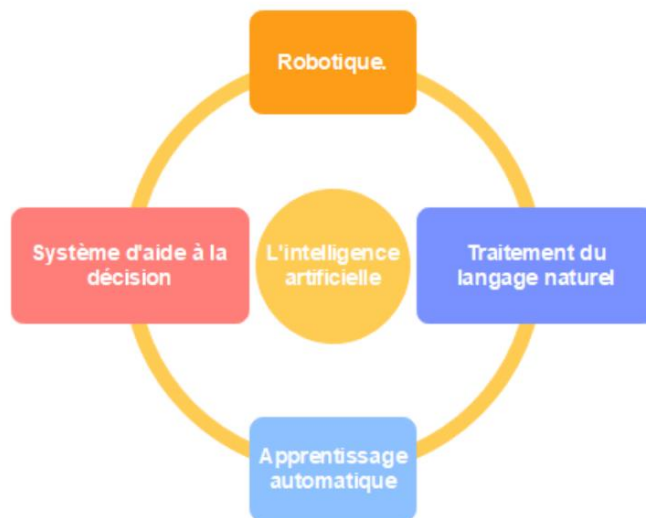


Figure 1: Les sous-domaines de l'IA.

I.2.3. Les avantages, inconvénients et les limites de l'intelligence artificielle

I.2.3.1. Les avantages

L'intelligence artificielle a le potentiel de remplacer les humains dans leurs tâches quotidiennes, permettant ainsi d'effectuer des travaux pénibles ou dangereux tels que le ménage, les courses, la cuisine, le jardinage, sans aucune contrainte physique comme le besoin de repos ou de nourriture [41].

Les algorithmes d'IA accélèrent les calculs sur les ordinateurs, réduisant les erreurs par rapport aux calculs humains.

- Les véhicules autonomes, équipés de caméras et de capteurs, facilitent les déplacements en se déplaçant sans intervention humaine.
- Dans le domaine médical, l'IA offre des avantages multiples, comme le suivi à distance des patients, les prothèses intelligentes et les traitements personnalisés.

I.2.3.2. Les inconvénients

- Une préoccupation majeure concerne la possibilité d'erreurs dans la programmation des robots, compromettant ainsi leur bon fonctionnement. Les machines telles que les ordinateurs, les robots et les véhicules intelligents ne peuvent pas détecter ces erreurs de programmation. Bien que le risque soit généralement faible, les conséquences d'une telle erreur pourraient être catastrophiques à grande échelle.
- L'augmentation du chômage est un autre effet potentiel, car les entreprises pourraient opter pour le remplacement des travailleurs par des robots dotés d'intelligence artificielle. Ces robots ne se fatiguent pas et nécessitent seulement une maintenance occasionnelle, ce qui peut entraîner des suppressions d'emplois.
- Les coûts élevés de recherche et développement dans le domaine de l'IA constituent également un défi. La création de robots autonomes capables de fonctionner dans la vie quotidienne serait extrêmement coûteuse.

I.3. Machine learning

L'apprentissage automatique, ou machine learning, est une branche de l'intelligence artificielle (IA) qui permet aux systèmes d'apprendre et de prendre des décisions de manière autonome, sans nécessiter de programmation humaine.

Chapitre I : L'intelligence artificielle et ses applications.

Ces systèmes peuvent apprendre à partir des actions passées, stocker des données pour les exploiter, et améliorer leurs performances futures.

L'apprentissage automatique se concentre sur le développement de programmes informatiques capables d'accéder aux données et de les utiliser pour apprendre de manière autonome. Le processus d'apprentissage commence par l'observation des données afin de rechercher des modèles, ce qui permet de prendre de meilleures décisions à l'avenir en se basant sur les exemples fournis, comme la reconnaissance des sons. La tâche principale de l'apprentissage automatique est d'extraire des informations précieuses à partir des données d'entraînement, puis de les exploiter pour créer un modèle capable de prédire de nouvelles données. [64] En ce sens, l'apprentissage automatique est synonyme de créativité.

I.3.1. Différents procédés d'apprentissage automatique

I.3.1.1. Apprentissage automatique supervisé

L'apprentissage supervisé est un système qui fournit à la machine à la fois des données d'entrée et les résultats attendus. Il consiste à fournir à la machine toutes les réponses correctes et précises, en entraînant le modèle avec des données étiquetées, c'est-à-dire que certaines données d'entrée ont été annotées avec la bonne réponse. L'objectif de l'apprentissage supervisé est d'apprendre à faire des prédictions à partir d'une liste d'exemples étiquetés [11]. Il existe deux types principaux d'apprentissage supervisé :

- Régression.
- Classification.

I.3.1.2. Apprentissage automatique non supervisé

Dans ce cas, le modèle n'a aucune idée préalable des données, mais il essaie de trouver des regroupements en analysant les données pour établir des liens et découvrir des structures. Cela implique de former la machine sur des données non étiquetées, où les algorithmes traitent les informations et tirent des conclusions sans assistance humaine. L'objectif est d'entraîner la machine à prédire correctement la sortie pour des entrées non étiquetées.

Une caractéristique distinctive de ces modèles est qu'ils peuvent proposer différentes façons de classer ou d'organiser les données, ainsi que plusieurs aspects de la solution, en fonction du type de données, de leur organisation et de

leur qualité. Voici quelques exemples populaires d'algorithmes d'apprentissage automatique non supervisé :

- K-means clustering (K-moyennes).
- Réseaux de neurones (Neural Network) /Deep Learning.
- Analyse des composants principaux (Principal Component Analysis).
- Décomposition en valeur singulière (Singular Value Décomposition)[11].

I.3.2. Les différents types d'apprentissage automatiques supervisé

I.3.2.1. Classification

C'est le travail de diviser un groupe d'éléments en plusieurs sections, basé sur des caractéristiques similaires. Cette opération est effectuée sans l'aide des connaissances existantes sur les groupes et leurs caractéristiques [5].

- **Ses utilisations**
 - Filtrage des spams.
 - Détection de la langue.
 - Analyse des sentiments.
 - Détection de fraude
- **Quelques exemples algorithmes d'apprentissage automatique supervisé:**
 - Naïve Bayes.
 - classificateur de vecteur de support.
 - Arbres de décision.
 - K plus proches voisins.
 - Régression logistique.

I.3.2.2. Régression

L'algorithme de régression linéaire est un algorithme d'apprentissage automatique supervisé utilisé pour résoudre des problèmes de prédiction. Cet algorithme prédit la variable cible en trouvant la meilleure ligne d'ajustement entre la variable dépendante et la variable indépendante. La régression linéaire étudie la relation entre deux variables uniquement, en cherchant à établir une relation linéaire entre elles en ajustant la meilleure ligne, connue sous le nom de ligne de régression, représentée par une équation linéaire : $y = \mathbf{ax} + \mathbf{b}$.

- **Ses utilisations**

Chapitre I : L'intelligence artificielle et ses applications.

- Analyse de la demande et du volume des ventes.
- La météo.
- Diagnostic médical.
- **Types de régression linéaire**
- Types de régression linéaire
- La régression linéaire multiple
- **Exemple :**

Régression linéaire simple, nous pouvons prédire les valeurs d'une variable spécifique (la variable dépendante) en fonction des valeurs d'une deuxième variable (la variable indépendante).

X	Y
1.00	1.00
2.00	2.00
3.00	1.3
5.00	2.25
4.00	3.75

Tableau 1:exemple simple.

Nous pouvons représenter les données du tableau dans la figure 2 suivante :




Figure 2: représentation des données d'un tableau.

Chapitre I : L'intelligence artificielle et ses applications.

La régression linéaire cherche à trouver la ligne la mieux ajustée qui passe par les points de la figure. Par conséquent, la ligne illustrée à la figure 2.

La figure est appelée la droite de régression et se compose du résultat attendu sur Y pour chaque valeur possible de X. Les lignes verticales reliant les points à la ligne de régression représentent les erreurs de prédiction.




Figure 3: ligne de régression.

Le point rouge est très proche de la droite de régression, ce qui indique une faible erreur de prédiction. En revanche, le point jaune est nettement au-dessus de la ligne de régression, ce qui signifie une erreur de prédiction élevée [4].

I.3.2.3. La différence entre régression et classification

La régression traite des données numériques continues, tandis que la classification traite des données catégoriques étiquetées. Cependant, il existe un certain chevauchement entre les algorithmes de classification et de régression. Par exemple, un algorithme de classification peut prédire une valeur continue, mais cette valeur est généralement exprimée sous forme de probabilité (étiquette de classe). De plus, un algorithme de régression peut prédire une valeur discrète, mais cette valeur discrète est exprimée en tant que quantité numérique [4].




Figure 4: La différence entre régression et classification.

I.3.3. Différents algorithmes machine Learning

I.3.3.1. Algorithmes d'apprentissage supervisé

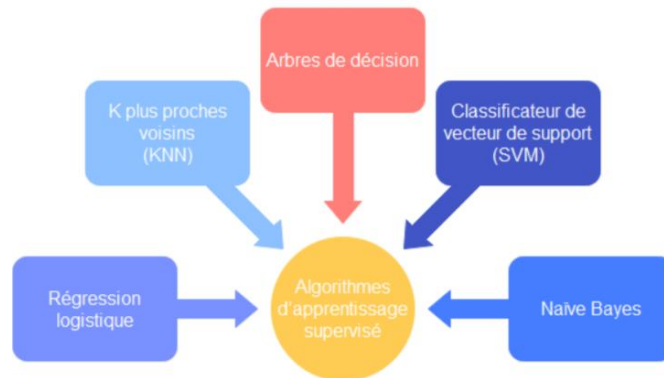


Figure 5: Algorithmes d'apprentissage supervisé.

I.3.3.1.1. Naïve Bayes

Naïve Bayes est un algorithme d'apprentissage simple qui utilise la règle de Bayes avec une forte hypothèse selon laquelle les attributs sont conditionnellement indépendants étant donné la classe. Dans la pratique, Naïve Bayes rivalise souvent bien avec des classificateurs plus sophistiqués [59].

Notre approche utilise des simulations de Monte Carlo, ce qui permet une étude systématique de la précision de la classification pour plusieurs classes de problèmes générés aléatoirement. Nous analysons l'impact de l'entropie de la distribution sur l'erreur de classification, montrant que les distributions de caractéristiques à faible entropie donnent de bonnes performances pour Naïve Bayes. Le résultat surprenant est que la précision de Naïve Bayes n'est pas directement corrélée avec le degré de dépendance des caractéristiques, mesuré comme l'information mutuelle conditionnelle de classe entre les caractéristiques. Un meilleur prédicteur de la précision de Naïve Bayes est la quantité d'informations sur la classe qui est perdue en raison de l'hypothèse d'indépendance.

I.3.3.1.2. Classificateur de vecteur de support

Il s'agit d'un ensemble d'algorithmes d'apprentissage automatique supervisé, ce qui signifie qu'il s'agit d'un classifieur discriminant formellement

Chapitre I : L'intelligence artificielle et ses applications.

défini par un niveau discret supérieur. Classifier des documents par SVM signifie avoir un classifieur pour chaque classe. L'objectif est de trouver le classifieur qui sépare Les algorithmes déterminent le superniveau qui sépare les deux ensembles de points[24]. Ce classificateur, également appelé classificateur de haut niveau, classe ou sépare correctement les données tout en étant le plus éloigné possible de toutes les observations. Par conséquent, le principe de base des machines à vecteurs de support (SVM) est de réduire le problème de discrimination à un problème linéaire afin de trouver l'hyperplan optimal. Cet hyperplan sépare les classes de données avec la plus grande marge possible, assurant ainsi une classification précise et robuste. [4].



Figure 6 : Tracer une ligne qui sépare les cercles noirs et les carrés bleus.




Figure 7: échantillon coupé à diviser en deux classes.

I.3.3.1.3. Support vector

Ce sont les points les plus proches de la surface de décision, car ce sont les points décisifs dans la décision de classer les points d'un groupe à un autre, et leur suppression nécessiterait de redéfinir la surface de décision.




Figure 8: vecteur de support.

I.3.3.1.4. Arbres de décision

Les arbres de décision sont une méthode d'apprentissage supervisé utilisée pour la classification et la régression. Leur objectif est de créer un modèle qui prédit la valeur d'une variable cible en utilisant des règles de décision simples apprises à partir des données caractéristiques. Ces règles de décision sont représentées sous forme d'arbre, où chaque nœud interne correspond à une caractéristique (ou attribut) et chaque branche à une règle de décision basée sur cette caractéristique. L'arbre se divise récursivement en sous-arbres jusqu'à ce que chaque feuille représente une classe (dans le cas de la classification) ou une valeur (dans le cas de la régression). La logique derrière les arbres de décision est facilement compréhensible car ils montrent une structure arborescente. Le principe des arbres de décision consiste à déterminer des actions à prendre en cas de problème en établissant un arbre de décision qui permet de prendre des décisions en fonction de différents scénarios possibles[56].

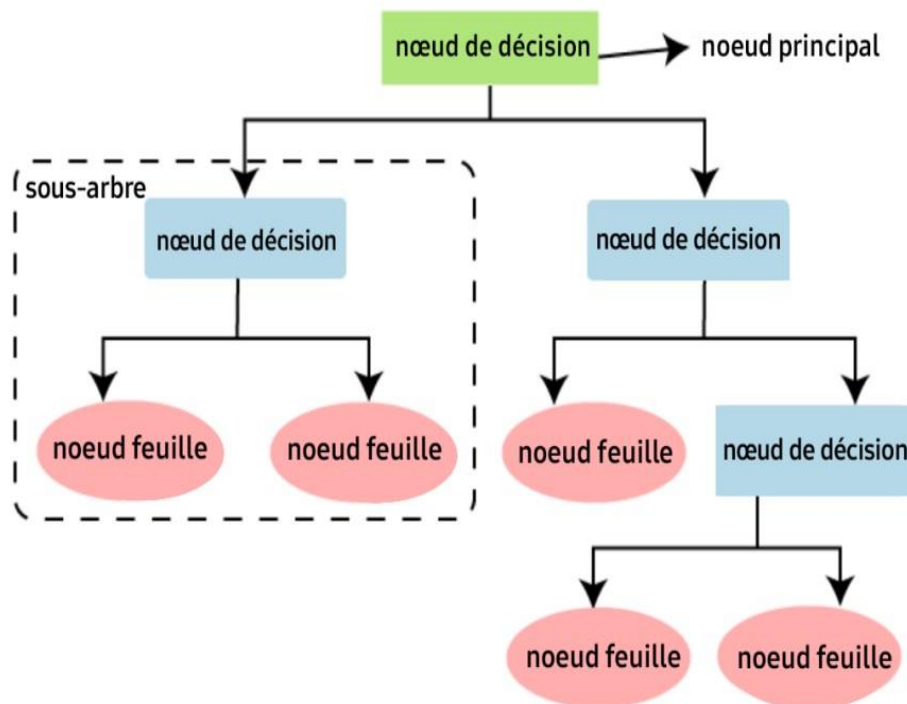


Figure 9: Arbre de décision.

Chaque branche représente le résultat d'un test, et chaque nœud feuille représente l'étiquette de classe.

I.3.3.2. Algorithmes d'apprentissage non supervisé

I.3.3.2.1. K-meansclustering (K-moyenne)

Le clustering K-Means est généralement la méthode de clustering la plus connue et la plus utilisée. Il s'agit d'un apprentissage non supervisé. L'algorithme de clustering K-Means est en fait un processus de classification, mais il n'a pas de classes prédéfinies. Il tente de trouver des objets similaires (selon certaines caractéristiques) et de les regrouper en un groupe, de manière à ce qu'il regroupe des objets ayant de nombreuses caractéristiques similaires en une seule classe. Cet algorithme nous permet de déterminer le clustering K-Means vise à partitionner n objets en k clusters, où chaque objet appartient au cluster le plus proche ayant une moyenne exactement k . Cette méthode permet d'obtenir le plus grand nombre possible de clusters distincts. Le meilleur nombre de clusters k , permettant une plus grande séparation (distance), n'est pas connu a priori et doit être calculé à partir des données [39].

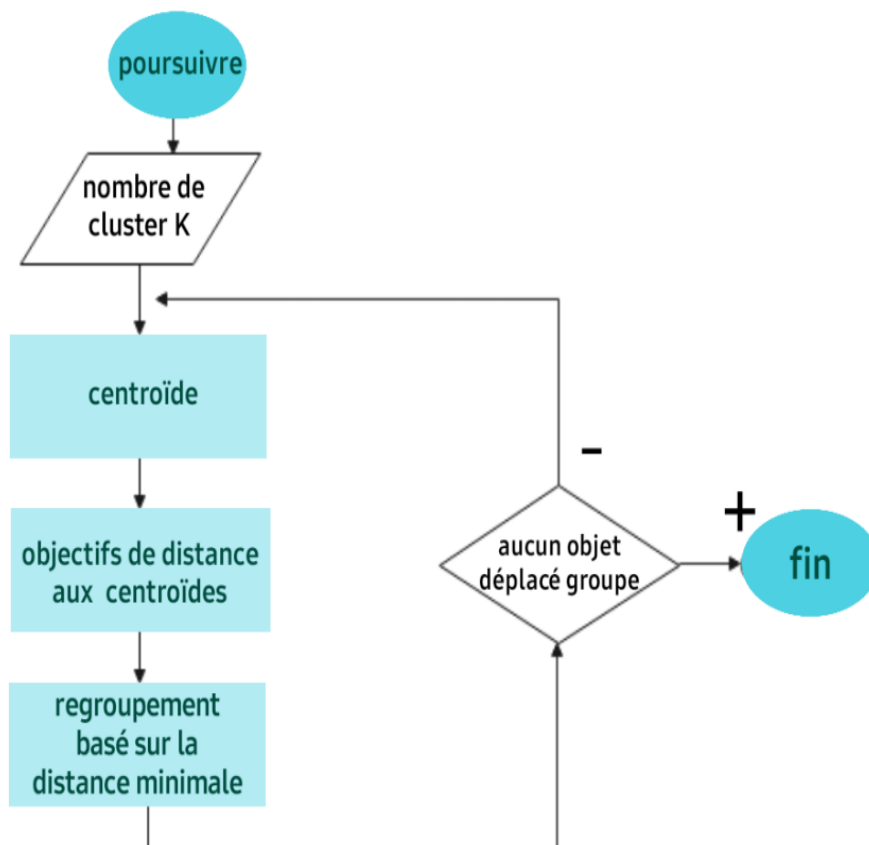


Figure 10: L'algorithme de clustering k Means fonctionne.

I.3.3.2.2. K plus proches voisins

L'algorithme des k plus proches voisins (k-nearestneighborskNN) est un algorithme de machine learning qui appartient à la classe des algorithmes d'apprentissage supervisé. Il est simple et facile à mettre en œuvre, et peut être utilisé pour résoudre des problèmes de classification et de régression. Les algorithmes kNN utilisent des données et classifient de nouveaux points de données en fonction de mesures de similarité (fonction de distance). Le classement se fait en se basant sur la majorité de ses voisins. Les données sont affectées à la classe qui a les voisins les plus proches. La méthode kNN est donc une méthode basée sur le voisinage, non paramétrique, ce qui signifie que l'algorithme permet de faire une classification sans faire d'hypothèse reliant la variable dépendante aux variables indépendantes.[19]

I.3.3.2.3. Algorithme des k plus proches voisins (problème de classification)

L'algorithme KNN est utilisé pour les problèmes de classification (apprentissage supervisé). Chaque fois que le modèle est alimenté avec des données de test, il calcule la distance entre ce point et tous les autres points des données d'entraînement. Ensuite, il sélectionne les k membres les plus proches de ce point. Le paramètre k dans KNN fait référence au nombre de voisins les plus proches inclus dans le processus de vote à la majorité.




Figure 11: K plus proches voisins.

Considérez la figure 11. On y observe des classes de données (rouge et vert) ainsi qu'un nouveau point de données (noir). Nous souhaitons déterminer à quelle classe ce nouveau point de données appartient. Le point de données (noir) est classé par un vote à la majorité de ses voisins les plus proches. Dans cet

exemple, le point de données sera classé comme un point rouge, car parmi les 5 points les plus proches, 3 d'entre eux sont rouges [5].

- **Principe de l'algorithme KNN**

1. Sélectionner le nombre K de voisins.
2. Calculer la distance.
3. Prendre les K voisins les plus proches en fonction de la distance calculée.
4. Parmi ces K voisins, compter le nombre de points appartenant à chaque catégorie.
5. Attribuer le nouveau point à la catégorie la plus présente parmi ces K voisins.

I.3.3.2.4. Régression logistique

La régression logistique est l'une des techniques de régression couramment utilisées par les scientifiques des données en apprentissage automatique. La mesure d'association calculée dans ce modèle est l'oddsratio, qui quantifie la force de l'association entre la survenue d'un événement (représenté par une variable dichotomique) et les facteurs susceptibles de l'influencer (représentés par des variables explicatives). Le choix des variables explicatives intégrées au modèle repose sur une connaissance préalable du phénomène étudié afin de ne pas omettre les facteurs de confusion déjà identifiés. Les auteurs exposent les principes fondamentaux de la régression logistique et les principales étapes de sa réalisation.

- **Principe de la régression logistique**

Effectuer une régression consiste à essayer de réduire les données d'un phénomène complexe à une loi mathématique simplifiée. La fonction logistique présente des caractéristiques qui expliquent l'utilisation des mathématiques dans un modèle d'analyse de données. Elle varie de 0 à 1 en fonction de la probabilité d'occurrence. Sa représentation graphique, une courbe sigmoïde, correspond plus ou moins au modèle de la relation entre l'occurrence de l'événement étudié et le facteur d'exposition. De plus, elle permet un calcul facile des rapports de cotes.

Le modèle de régression logistique permet d'estimer la force de l'association entre une variable qualitative à deux catégories (variable dépendante) et des variables explicatives, qui peuvent être qualitatives ou

quantitatives (variables indépendantes). La variable dépendante représente la survenue ou la non-survenue de l'événement étudié, tandis que les variables explicatives sont les facteurs qui influencent potentiellement la survenue de cet événement (facteurs d'exposition).

Cependant, la régression logistique peut être uni variée (avec une seule variable indépendante) ou multi variée (avec plusieurs variables indépendantes). La régression logistique multi variée présente l'avantage de son utilisation, car elle permet d'estimer la force d'association entre la variable dépendante et chaque variable explicative, en prenant en compte l'effet simultané de toutes les autres variables explicatives intégrées dans le modèle. [14].

- **Conditions pour le modèle de régression logistique**

- Indépendance des différentes observations les unes par rapport aux autres : Chaque observation doit être indépendante, c'est-à-dire qu'aucune donnée ne doit être influencée par une autre.
- Distribution normale des variables quantitatives incluses dans le modèle : Les variables quantitatives doivent suivre une distribution normale, ce qui facilite l'estimation des paramètres du modèle et la validité des tests statistiques.
- Relation linéaire entre chacune de ces variables quantitatives et la variable dépendante : Il doit exister une relation linéaire entre chaque variable quantitative et la variable dépendante en termes de log-odds, c'est-à-dire que la transformation logarithmique de la probabilité de l'événement doit être linéairement liée aux variables explicatives.

- **Types d'analyse de régression logistique**

- Régression logistique binaire.
- Régression logistique multinomiale.
- Régression logistique ordinale.

I.3.4. La différence entre apprentissage supervisé et non supervisé

L'apprentissage supervisé est une méthode d'apprentissage automatique qui utilise des données préalablement annotées ou étiquetées. En revanche, l'apprentissage non supervisé peut être utilisé pour partitionner des données (ou les regrouper) et même pour créer des systèmes de recommandation, tels que des moteurs de recommandation de produits qui prennent en compte les préférences des clients. Les fonctions de détection d'anomalies font généralement appel à des techniques d'apprentissage non supervisé [7].

3. Conclusion

Dans ce chapitre, nous avons défini le concept d'intelligence artificielle et nous avons expliqué les concepts d'intelligence artificielle (IA), d'apprentissage machine (ML).

L'intelligence artificielle est un domaine dynamique et en perpétuelle évolution, dont la définition échappe encore à une précision totale en raison de sa complexité et de ses multiples facettes. Les ambitions initiales des premiers chercheurs, qui cherchaient à créer des machines capables de répliquer les capacités intellectuelles humaines, ont rapidement montré leurs limites. Néanmoins, l'évolution des techniques informatiques et des technologies, comme les langages de programmation orientés objet et les machines dédiées à la programmation symbolique, a permis à l'IA de se développer de manière significative. Aujourd'hui, l'IA est omniprésente dans notre quotidien, facilitant des tâches variées telles que la navigation urbaine et l'assistance virtuelle. En outre, ses applications continuent de s'étendre à de nombreux secteurs comme la médecine, la finance, l'industrie et l'agriculture, offrant des opportunités inédites d'automatisation, d'optimisation et de prise de décision basée sur les données. L'avenir de l'IA promet encore de nombreuses avancées, transformant profondément notre société et nos modes de vie.

Chapitre II

II.1. Introduction

Le deep learning, ou apprentissage profond, représente une avancée majeure dans le domaine de l'intelligence artificielle, reposant sur des réseaux de neurones artificiels inspirés du cerveau humain. Ces réseaux, en particulier les réseaux de neurones convolutifs (CNN), ont la capacité de traiter des volumes massifs de données et d'apprendre des représentations hiérarchiques de celles-ci, ce qui les rend particulièrement adaptés à des tâches complexes.

Le traitement d'image est une branche de l'informatique qui se concentre sur l'analyse et la manipulation des images numériques. Cela comprend une variété de techniques pour améliorer, restaurer, segmenter et comprendre les images. Les avancées en deep learning ont transformé ce domaine, permettant des niveaux de précision et de performance auparavant inaccessibles.

L'une des applications les plus marquantes du deep learning dans le traitement d'image est la classification d'images. Cette technique consiste à identifier et étiqueter automatiquement les objets ou les caractéristiques présentes dans une image. Grâce aux réseaux de neurones convolutifs, les systèmes de classification d'images peuvent apprendre à distinguer avec une grande précision entre différentes catégories d'objets, même dans des ensembles de données vastes et variés. Cette capacité a révolutionné de nombreux secteurs, allant de la reconnaissance faciale et de la surveillance à l'imagerie médicale et à la conduite autonome, en rendant les systèmes de traitement d'image plus intelligents et plus efficaces.




Figure 12 : La relation entre l'intelligence artificielle et le ML et le deep learning.

II.2. Deep Learning

C'est une branche de l'apprentissage automatique où l'objectif est de simuler le fonctionnement des neurones du cerveau humain en créant un réseau de neurones artificiels. Ce réseau peut analyser d'énormes quantités de données non structurées, telles que différents langages et images, et les traiter en les faisant passer par les différentes couches du réseau de neurones pour les identifier à travers plusieurs étapes, comme la reconnaissance de la parole et des images. L'apprentissage en profondeur se réfère à un réseau de neurones avec un grand nombre de paramètres et de couches, qui peut être l'un des quatre types d'architectures de réseau de base :

- Les réseaux de neurones artificiels (ANN).
- Les réseaux de neurones à convolution (CNN).
- Les réseaux de neurones récurrents (RNN).
- Les réseaux de neurones récurrents à mémoire à court terme (LSTM).

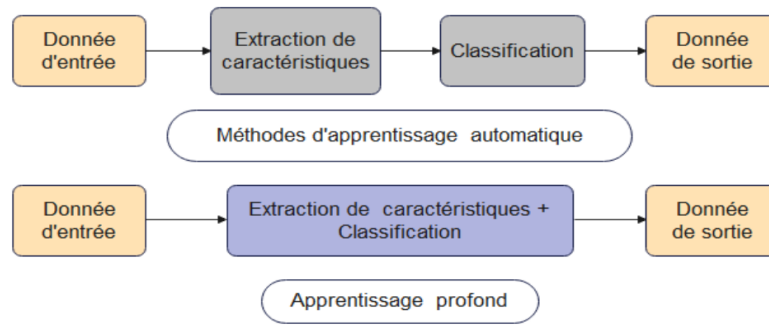


Figure 13 : Processus des modèles d'apprentissage automatique classique versus apprentissage profond.

II.2.1. Modèles du Deep Learning

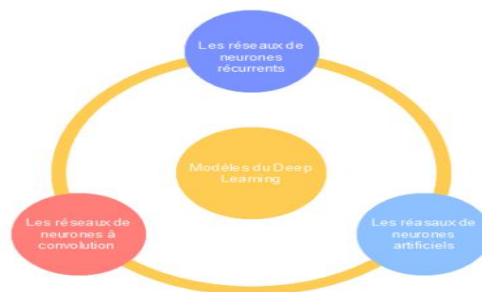


Figure 14: Modèles du deep learning.

II.2.2. Les différentes Architectures du Deep Learning

Le Deep Learning repose sur le concept des réseaux de neurones artificiels et est spécialement conçu pour traiter de grandes quantités de données en ajoutant des couches au réseau. Un modèle de deep Learning est capable d'extraire des caractéristiques à partir des données brutes en utilisant plusieurs couches de traitement qui comprennent des transformations linéaires et non linéaires. Il peut apprendre progressivement à partir de ces caractéristiques à travers chaque couche, avec une intervention humaine minimale [29].

II.2.2.1. Réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des modèles d'apprentissage automatique capables de représenter une relation entre des données d'un espace X et un espace de sortie Y . Ils sont utilisés dans de nombreux domaines, tels que la vision assistée par ordinateur [46] [35] [10], le traitement du langage naturel [53] l'analyse audio [3] [12], mais aussi pour développer des machines d'IA

Chapitre II : l'Apprentissage profond.

capables de jouer à des jeux ou utilisées en tant qu'assistant personnel (comme Amazon Alexa, Apple Siri, Microsoft Cortana ou l'Assistant Google).

L'unité de calcul de base est le neurone. Celui-ci prend plusieurs signaux en entrée et les interprète pour envoyer un nouveau signal à d'autres neurones ou à la sortie du réseau neuronal, c'est-à-dire à la sortie du modèle. Il existe de nombreuses architectures pour construire des réseaux de neurones artificiels.

Avant d'introduire les réseaux de neurones artificiels, nous passerons en revue plusieurs concepts biologiques sur les neurones, puis nous commencerons par présenter un modèle composé d'un seul neurone, appelé le modèle du perceptron. Cela nous permettra de mettre en évidence les mécanismes de base de tout réseau de neurones artificiels.




Figure 15: Un neurone réel.




Figure 16: Un neurone artificiel.

II.2.2.1.1. Problème de l'overfitting

Un problème classique en apprentissage automatique est le surapprentissage (overfitting) de l'ensemble d'entraînement. Ce problème survient lorsque le modèle appris commence à s'adapter aux cas particuliers du jeu de données, au détriment des cas généraux. Ce scénario est illustré dans la Figure N°17. Ce phénomène provient d'un jeu de données d'apprentissage insuffisamment large par rapport à la complexité du modèle d'apprentissage. Étant donné que les réseaux de neurones artificiels (ANN) sont des modèles très complexes avec un nombre particulièrement élevé de paramètres, leur entraînement nécessite une attention particulière à ce phénomène de

surapprentissage, notamment dans le cas où le jeu de données d'entraînement est relativement petit.

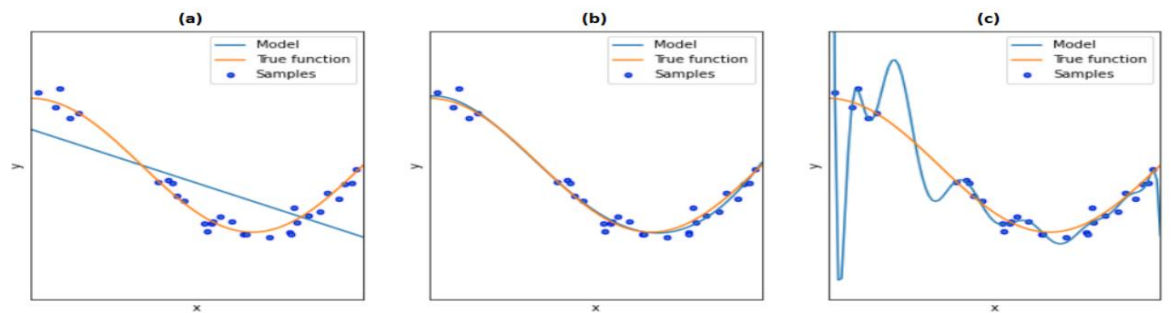


Figure 17: Trois modèles de classifieurs à différents niveaux d'apprentissage.

a) classifieur sous-appris, b) classifieur bien appris, et c) classifieur sur appris. Les points violets et oranges représentent les données des deux différentes classes.

II.2.1.2. Fonction d'activation

Une fonction d'activation, cruciale dans le fonctionnement des réseaux de neurones artificiels, est appliquée au signal en sortie de chaque neurone. Son nom découle du concept biologique du "potentiel d'activation", seuil qui, une fois franchi, déclenche une réaction neuronale. Cette fonction est généralement non linéaire, essentielle pour transformer un réseau de neurones en un modèle capable de capturer des relations complexes. Sans elle, le réseau ne serait qu'un simple modèle de régression linéaire.

Au fur et à mesure que les données se propagent d'un neurone à l'autre, elles peuvent croître en amplitude, ce qui complique les calculs. Les fonctions d'activation non linéaires permettent de réguler cette croissance, souvent en restreignant la sortie du neurone à une simple probabilité, facilitant ainsi le traitement des informations. [44].

Parmi les principales fonctions d'activation étudiées, on retrouve : [47]

- Les valeurs transmises de neurone en neurone peuvent devenir de plus en plus grandes, rendant les calculs plus complexes.
- Les fonctions d'activation non linéaires réduisent la valeur de sortie d'un neurone, généralement sous forme d'une simple probabilité, pour remédier à cela.

II.2.2.1.3. Fonction Sigmoidale

Chapitre II : l'Apprentissage profond.

Sa sortie est entre 0 et 1 et a une courbe de forme en S. Si on remarque bien, on voit que les valeurs de X entre -2 et 2 ont une valeur de Y qui change rapidement, ce qui signifie qu'une petite modification de X dans cet intervalle entraînera un changement significatif des valeurs de Y. Sa fonction est :

$$\delta(z) = \frac{1}{1 + \exp(-z)}$$




Figure 18: Représentation du graphe de fonction Sigmoïde.

II.2.2.1.3. Fonction Tanh

Cette fonction ressemble à la fonction tangente hyperbolique (Tanh). La différence avec la fonction Sigmoïde est que la fonction Tanh produit un résultat compris entre -1 et 1. La fonction Tanh est généralement préférable à la fonction Sigmoïde car elle est centrée sur zéro. Les grandes entrées négatives tendent vers -1 et les grandes entrées positives tendent vers 1. Sa fonction est :

$$F(z) = \frac{\exp(z) - \exp(-z)}{\exp(z) + \exp(-z)}$$




Figure 19: Représentation du graphe de fonction Tanh.

II.2.2.1.4. Fonction ReLu

C'est une fonction simple qui renvoie X en tant que sortie s'il est supérieur à 0, sinon sa sortie sera 0. Sa fonction est: **Fonction(X) = max(0, X)**.

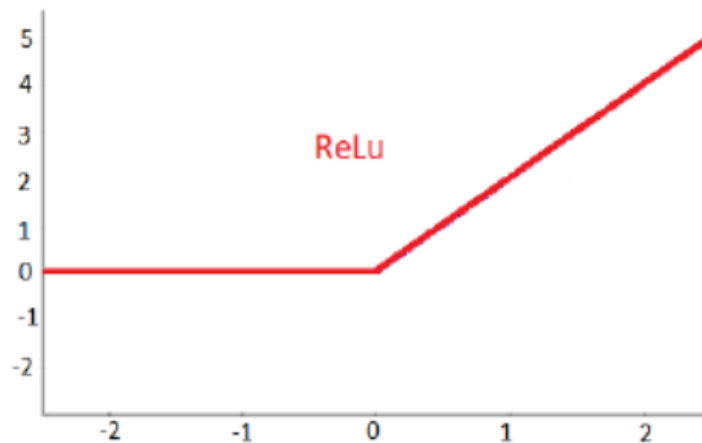


Figure 20: Représentation du graphe de fonction Relu.

II.2.2.1.5. Fonction Softmax

Est une généralisation de la régression logistique que nous pouvons utiliser pour la classification multi-classes. Contrairement à d'autres types de fonction, la sortie d'un neurone d'une couche utilisant la fonction softmax dépend des sorties de tous les autres neurones de sa couche. Cela s'explique par le fait qu'il nécessite que la somme de toutes les sorties soit égale à 1. Sa fonction est

$$F(Z) = \frac{e^{z_i}}{\sum_{k=1}^k e^{z_k}} \text{ pour } i, \dots, k$$

II.2.2.1.6. Fonction d'erreur

La fonction d'erreur est utilisée pour déterminer la bonne combinaison des poids. Pour ce faire, elle calcule la différence entre la sortie réelle du réseau et la sortie attendue après qu'un cas a circulé à travers le réseau. Parmi les principales fonctions d'erreur étudiées, on retrouve :

II.2.2.1.7. La régularisation

Chapitre II : l'Apprentissage profond.

La régularisation est utilisée pour éviter le problème du sur-apprentissage. En d'autres termes, elle permet de gérer l'augmentation de la complexité du modèle de manière à réduire l'erreur d'apprentissage sans augmenter l'erreur de test. Il existe plusieurs méthodes pour résoudre ce problème, parmi les quelles. [57]




Figure 21: Problème du sur apprentissage.

II.2.2.1.8. Le Dropout

Le Dropout est une méthode utilisée pour éviter la surallocation. Elle vise à réduire l'erreur de généralisation. Il est généralement utilisé au niveau de certaines couches du réseau. Le Dropout supprime de manière aléatoire certains neurones, ainsi que leurs connexions d'entrée-sortie. Lorsque des neurones sont supprimés de manière aléatoire du réseau pendant l'entraînement, les neurones restants sont contraints de répondre et de contrôler la représentation nécessaire pour effectuer des prédictions sur les neurones manquants. Cette méthode améliore la généralisation car elle oblige les couches à apprendre le même concept avec différents neurones [28].

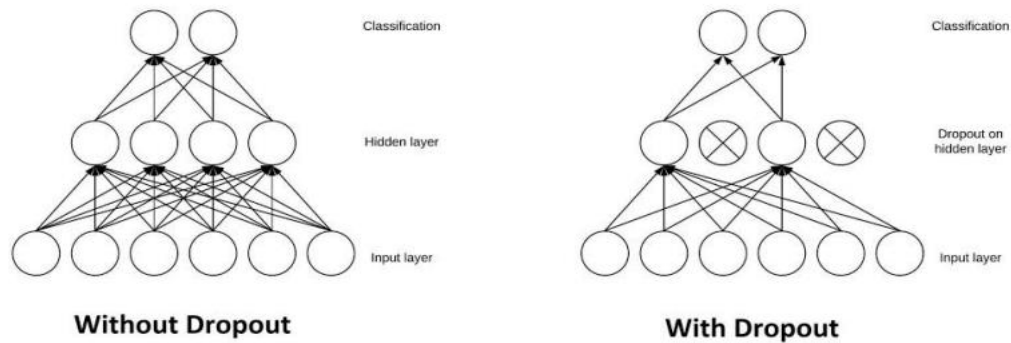


Figure 22: Explication du fonctionnement du Dropout.

II.2.1.9. Earlystopping

L'Earlystopping (arrêt précoce) est une technique de validation croisée où une partie de l'ensemble de formation est réservée comme ensemble de validation. Lorsque les performances sur l'ensemble de validation commencent à se détériorer, l'entraînement du modèle est immédiatement arrêté. Cela correspond à ce que l'on appelle l'arrêt prématuré.



Figure 23: Fonctionnement de l'Earlystopping.

II.2.2.2. Les réseaux neuronaux convolutionnels (CNN)

Les réseaux neuronaux convolutionnels (CNN), introduits par Lecun et al, se distinguent par l'utilisation de l'opération de convolution dans les premières couches intermédiaires du réseau neuronal. À l'origine, cette opération était utilisée comme filtre dans le domaine de l'image ou du son pour mettre en évidence des motifs ou réduire un type de bruit. Dans les CNN, le modèle lui-même apprend les filtres des différentes convolutions afin de mettre en évidence les motifs des données d'entrée qui sont utilisés dans les couches suivantes. Un CNN classique est généralement composé de quatre types de couches.

- Les couches de convolution, qui contiennent plusieurs opérations de convolution appliquées à la même entrée.
- Les couches d'opérations de pooling.
- Les couches d'activation.
- Les couches entièrement connectées.

II.2.2.2.1. Le principe de base d'un CNN pour le traitement d'images

Le rôle principal d'un Convolutional Neural Network (CNN) est de réduire la taille des représentations d'image tout en accélérant le calcul. Un CNN se compose de différentes couches, notamment la couche d'entrée, la couche de convolution, la couche de regroupement (pooling), et la couche entièrement connectée.

- Couche d'entrée : Cette couche prend initialement les valeurs des pixels de l'image comme entrée.
- Couche de convolution (CONV) : Cette couche a pour but de filtrer les entrées pour en extraire des caractéristiques. Elle applique des filtres (ou noyaux) qui parcourent l'image et produisent des cartes de caractéristiques (featuremaps).
- Couche de regroupement (POOL) : Cette couche combine les sorties des couches de convolution en réduisant leur dimension tout en conservant les informations essentielles. Les techniques de pooling courantes incluent le max-pooling et l'average-pooling.
- Couches entièrement connectées : Ces couches s'occupent des tâches de classification grâce aux données issues des couches précédentes. Elles sont similaires aux couches des réseaux de neurones traditionnels et fournissent les probabilités de classification pour chaque classe.

En résumé, un CNN transforme l'image d'entrée en une représentation plus compacte et pertinente à travers les différentes couches, permettant ainsi une classification plus efficace des images. [16]




Figure 24: Les parties du CNN.

II.2.2.2.2. Couche convolutionnelle

La couche convolutionnelle effectue l'opération de convolution des images d'entrée en utilisant des filtres de noyau pour extraire les caractéristiques fondamentales. Les filtres de noyau ont les mêmes dimensions mais avec des paramètres constants plus petits par rapport aux images d'entrée. Par exemple, pour calculer une image scalogramme 2D de $35 \times 35 \times 2$, la taille de filtre acceptable est de $f \times f \times 2$, où f peut être 3, 5, 7, etc. Cependant, la taille du filtre doit être plus petite par rapport à celle de l'image d'entrée. Le masque de filtre glisse sur l'ensemble de l'image d'entrée étape par étape et estime le produit scalaire entre les poids des filtres de noyau et la valeur de l'image d'entrée, ce qui produit une carte d'activation 2D. Ainsi, le CNN apprendra une caractéristique visuelle. [16]




Figure 25 : exemple d'une opération de convolution.

II.2.2.2.3. Pooling Operation

Chapitre II : l'Apprentissage profondi.

Les couches de convolution peuvent être suivies par une opération de mise en commun. Elle vise à réduire la dimension des couches de neurones en regroupant les informations présentes sur les neurones proches les uns des autres. Le principe est de faire glisser une fenêtre sur les neurones et d'appliquer une opération de mise en commun à celle-ci. Il existe différents types d'opérations de mise en commun telles que la fonction maximale ou moyenne. Un exemple d'opération de mise en commun est illustré dans la Figure N°26.

Les couches entièrement connectées et les couches d'activation sont identiques aux MLP (respectivement les couches neuronales classiques et la fonction d'activation appliquée à une couche entière). Les couches entièrement connectées sont généralement placées à la fin des CNN (juste avant la couche de sortie). Elles permettent de corrélérer tous les motifs détectés par les couches de convolution dans les couches précédentes. Les couches d'activation sont généralement placées après chaque couche de convolution et chaque couche entièrement connectée. Les couches d'activation et les couches de mise en commun ne sont pas des couches neuronales car elles ne contiennent pas de connexions à apprendre (ce qui ne signifie aucun paramètre entraînable).

Contrairement aux MLP, le nombre de paramètres à apprendre dans les CNN est généralement inférieur, mais le nombre d'opérations reste plus élevé. Cela est dû au fait que les filtres, généralement de petite taille, sont partagés par les neurones d'une ou plusieurs dimensions de la couche de sortie. Les CNN sont principalement utilisés dans le domaine de l'imagerie, où ils surpassent d'autres méthodes d'apprentissage [1] [10]. Ils sont également utilisés dans le domaine du son [12] ou de la vidéo. Des variantes existent également pour l'analyse de graphiques arbitraires .




Figure 26: Exemple d'une opération pooling avec la mise en commun maximale.

(à droite) et la mise en commun moyenne (à gauche). La fenêtre de défilement a une taille de 2×2 et se déplace de 2 en 2 le long de l'axe y et de 2 en 2 le long de l'axe x.

II.2.2.3. Les réseaux de neurones récurrents

Les réseaux de neurones récurrents (RNN) sont des réseaux de neurones dont le graphe de connexion contient au moins un cycle. Ils sont utilisés dans le traitement automatique du langage naturel et la reconnaissance vocale. Les couches d'un RNN sont des entités primitives qui permettent aux réseaux d'apprendre à partir de séquences d'entrée et sont des modèles capables de prendre en compte le contexte dans leur fonction de décision.

Le but d'un RNN est de conserver les informations dans le temps au sein des couches de neurones afin de donner un contexte aux données analysées. La sortie d'un RNN à l'instant (t) dépend non seulement de l'entrée à cet instant, mais aussi de l'état du RNN calculé à l'instant $(t - 1)$.

Une couche d'un RNN peut être décrite comme une couche entièrement connectée qui prend en entrée la couche précédente $(l - 1)$ à l'instant (t) , concaténée à sa propre sortie (c'est-à-dire la couche (l) à l'instant $(t - 1)$).




Figure 27: Les parties du CNN.

Un type de réseau de neurones récurrents a acquis une reconnaissance importante en raison de ses performances exceptionnelles sur diverses tâches : il s'agit des réseaux de neurones à cellules Long Short-Term Memory (LSTM).

II.2.2.3.1. Les types de réseaux de neurones récurrents

Les réseaux de neurones traditionnels analysent des données étiquetées mais ne sont pas conçus pour faire des prédictions sur des séries temporelles, c'est-à-dire des données qui évoluent dans le temps. Pour traiter ce type de données, il existe trois principaux types de réseaux de neurones récurrents : le RNN simple, le LSTM et le GRU.

Le RNN simple, également appelé "Vanilla RNN", est la forme la plus basique de RNN. Il ne possède pas de portes (Gates), ce qui signifie que le flux

d'informations n'est pas contrôlé. Les informations essentielles à la tâche peuvent être écrasées par des informations redondantes ou non pertinentes. En pratique, les RNN simples ne sont pas largement utilisés et sont principalement étudiés à des fins d'enseignement.

Les LSTM (Long Short-Term Memory) et les GRU (Gated Recurrent Unit) sont des améliorations des RNN simples. Ils comprennent plusieurs portes (respectivement 3 et 2) qui permettent de contrôler sélectivement l'oubli ou la mémorisation des informations de la séquence temporelle précédente dans une mémoire dynamique. Ces portes permettent aux LSTM et aux GRU de mieux gérer les dépendances à long terme dans les données séquentielles, ce qui les rend plus adaptés pour les tâches de prédiction de séries temporelles. Comme les réseaux de neurones traditionnels, les réseaux de neurones récurrents peuvent également comporter plusieurs couches. Cela leur permet de capturer davantage de non-linéarités dans les données, mais cela augmente également le temps de calcul lors de la phase d'apprentissage. De plus, il est possible de combiner des couches récurrentes avec des couches classiques telles que des couches denses (MLP) ou des couches de convolution (CNN) pour bénéficier des avantages des deux architectures.

II.2.2.3.2. Architectures RNN :

L'architecture d'un réseau de neurones récurrents (RNN) se compose généralement de plusieurs couches récurrentes empilées. Chaque couche récurrente peut être un RNN simple, un LSTM ou un GRU, comme mentionné précédemment. Voici une représentation générale de l'architecture d'un RNN :

- **Entrée (Input):** Les données séquentielles sont introduites dans le réseau par l'intermédiaire de l'entrée. Chaque séquence de données est représentée par une série d'éléments (par exemple, des mots dans une phrase ou des instants temporels dans une série temporelle).
- **Couche récurrente (Recurrent Layer):** Les informations séquentielles sont traitées dans la couche récurrente. Cette couche possède des connexions de rétroaction qui permettent aux informations de circuler d'une étape à l'autre dans la séquence. Cela permet au réseau de capturer les dépendances temporelles et de modéliser les relations complexes entre les éléments séquentiels. Optionnel : Stacking de couches récurrentes (Stacking Recurrent Layers) : Il est possible d'empiler plusieurs couches récurrentes les unes sur les autres pour former un réseau de neurones

récurrents profond. Chaque couche récurrente traite les informations provenant de la couche précédente, permettant ainsi au réseau de capturer des niveaux de représentation plus abstraits et complexes.

- **Couche de sortie (Output Layer):** La couche de sortie génère les prédictions ou les sorties souhaitées en fonction des informations traitées par les couches récurrentes. La nature de la tâche détermine le type de couche de sortie utilisée. Par exemple, pour la classification, une couche de sortie dense avec une fonction d'activation appropriée peut être utilisée.




Figure 28 : Recurrent Neural Network (RNN).

II.2.2.3.3. Réseaux Long Short-Term Memory (LSTM)

Les réseaux de neurones à mémoire à court et long terme (LSTM) représentent une variante spéciale des RNN, conçue pour apprendre des dépendances à long terme. Ils excellent dans une diversité de problèmes et sont aujourd'hui largement adoptés, résolvant ainsi les difficultés associées aux dépendances à long terme. Leur capacité à retenir des informations sur des périodes prolongées constitue un aspect essentiel de leur fonctionnement. [44].

L'idée principale des cellules LSTM est de maintenir un état de mémoire comprenant trois portes distinctes, qui agissent comme des mécanismes de contrôle régulant le flux d'informations : la porte d'oubli (Forget gate), la porte d'entrée (Input gate) et la porte de sortie (Output gate).

Comme illustré dans la figure 29, la cellule mémoire est principalement influencée par ces trois portes, chacune jouant le rôle d'une vanne ayant une fonction spécifique :

- La porte d'entrée décide si l'entrée doit affecter le contenu de la cellule.

Chapitre II : l'Apprentissage profond.

- La porte d'oubli détermine s'il est nécessaire de réinitialiser le contenu de la cellule.
- La porte de sortie détermine si le contenu de la cellule doit influencer la sortie du neurone.

Le fonctionnement des trois portes est essentiellement similaire : l'ouverture ou la fermeture de chaque vanne est contrôlée par une fonction (f), généralement une sigmoïde, appliquée à la somme pondérée des entrées.

On observe également deux types de sorties, appelées états (Hidden state et Cell state)[60].

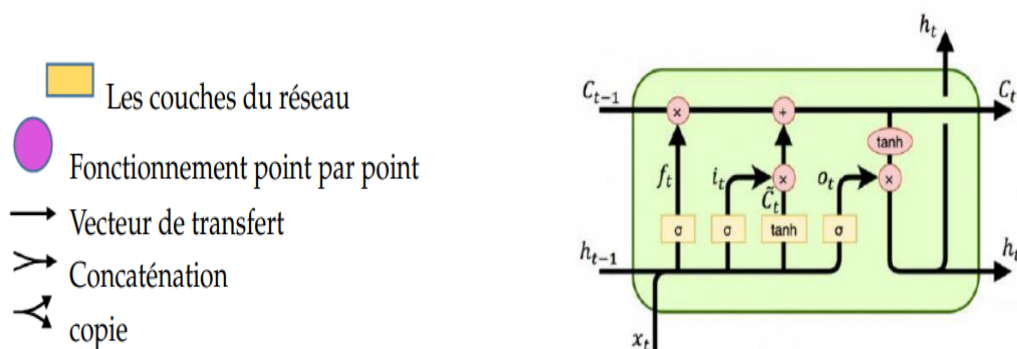


Figure 29: cellule LSTM.

II.2.3. Évaluation

La matrice de confusion est une représentation tabulaire utilisée dans la technique de benchmarking de la classification en apprentissage automatique. Elle résume, décrit ou évalue les performances d'un modèle de classification sur un ensemble de données de test lorsque les vraies valeurs sont connues.

Chaque colonne de la matrice de confusion représente les instances d'une classe réelle, tandis que chaque ligne représente les instances d'une classe prédite. Cependant, cette disposition peut également être inversée, c'est-à-dire que les colonnes peuvent représenter les classes prédites et les lignes les classes réelles [6].

La matrice de confusion visualise l'exactitude d'un classificateur en comparant les classes réelles et prédites.

	POSITIVE	NEGATIVE
Positive	True positive (TP)	False negative (FN)
Negative	False positive (FP)	TrueNegative (TN)

Tableau 2:Matrice de confusion.

- TP (VP) Nombre de vrais positifs : représente le nombre de messages exprimant une opinion positive et classés positifs par le classifieur.
- TN (VN) Nombre de vrais négatifs : représente le nombre de messages exprimant une opinion négative et classés négatifs par le classifieur
- FP (FP) Nombre de faux positifs : représente le nombre de messages exprimant une opinion négative et classés positifs par le classifieur.
- FN (FN) Nombre de faux négatifs : représente le nombre de messages exprimant une opinion positive et classés négatifs par le classifieur.

II.2.3.1. Mesures d'évaluation

La majorité des études de la littérature ont recours aux métriques courantes d'extraction d'informations pour évaluer leurs méthodes.[6]

- Justesse (Accuracy-Exactitude).
- Précision.
- Rappel (Recall).
- F-mesure (F-score).
- Courbe ROC.

II.2.3.1.2. Justesse (Accuracy - Exactitude)

C'est une mesure qui évalue le pourcentage de prédictions correctes, ce qui en fait un indicateur facile à interpréter. Dans le cas de la classification binaire, la précision peut être calculée en tenant compte des avantages et des inconvénients, tels que : $Accuracy = \frac{TP+TN}{TN+FN+TP+FP}$

II.2.3.1.3. Précision

Chapitre II : l'Apprentissage approfondi.

La précision est définie comme le nombre de documents pertinents retrouvés divisé par le nombre total de documents proposés pour une requête donnée. Elle permet de répondre à la question suivante : "Quelle proportion de documents positifs était effectivement correcte ?" La précision est un indicateur essentiel pour évaluer la qualité d'un système de recherche d'informations, car elle mesure l'exactitude des résultats fournis. Si la précision est élevée, cela signifie que peu de documents non pertinents sont proposés par le système, ce qui indique que le système est précis dans ses recommandations.

La formule de calcul de la précision est la suivante : $\text{Precision} = \frac{TP}{TP+FP}$

II.2.3.1.4. Rappel (Recall)

Le rappel est défini comme le ratio des observations positives correctement prédites par rapport à toutes les observations de la classe réelle "OUI". Le rappel mesure la capacité d'un modèle ou d'un système à identifier tous les documents pertinents parmi ceux présents dans la base de données. Il répond à la question suivante : "Quel pourcentage de positifs réels a été correctement identifié ?" Lorsque l'utilisateur interroge la base de données, il souhaite voir tous les documents qui peuvent répondre à ses besoins d'information. Ainsi, le rappel est un indicateur crucial pour évaluer l'exhaustivité des résultats fournis par le système.

La formule de calcul du rappel est la suivante : $\text{Rappel} = \frac{TN}{TP+FN}$

II.2.3.1.5. F-mesure (F-score)

La F-mesure, également appelée score F, est la moyenne harmonique de la précision et du rappel. Lorsqu'il s'agit de trouver un équilibre entre la précision et le rappel, il est possible d'augmenter la valeur de l'un, mais cela se fait souvent au détriment de l'autre. La F-mesure combine ces deux mesures pour fournir un compromis entre les deux.

La formule de calcul de la F-mesure est la suivante :

$$F_{\text{mesure}} = 2 * \frac{\text{Precision} * \text{Rappel}}{\text{Precision} + \text{Rappel}}$$

II.2.3.1.6. Courbe ROC (ROC curve)

Chapitre II : l'Apprentissage approfondi.

Les courbes ROC sont un outil statistique utilisé pour évaluer le pouvoir discriminant des tests diagnostiques dichotomiques. Elles expriment la sensibilité en fonction des faux positifs (complément de la spécificité) à différents seuils et ne nécessitent aucune intervention subjective de la part de l'utilisateur. Les courbes ROC peuvent être utilisées pour sélectionner le seuil le plus approprié pour un test, comprendre ses performances globales et comparer le pouvoir discriminant de deux ou plusieurs tests de diagnostic. Elles sont largement utilisées dans le domaine de la classification.

La courbe ROC utilise différentes distributions des coûts de mauvaise classification pour différents classificateurs. Cela signifie que l'utilisation de la courbe ROC équivaut à utiliser différentes échelles pour évaluer différentes règles de classification. Par exemple, avec un classificateur, mal classer un point de classe 1 peut être considéré comme (p) fois plus grave que mal classer un point de classe 0, tandis qu'avec un autre classificateur, mal classer un point de classe 1 peut être considéré comme (P) fois plus grave, où ($p = P$). Cependant, les intensités relatives des différentes espèces ne sont pas déterminées par les classificateurs choisis, mais plutôt par les caractéristiques intrinsèques du problème. [15].

II.2.3.2. Démarche d'évaluation

L'objectif de l'évaluation est de mieux estimer les performances du classifieur sur de nouvelles données, afin de prédire son comportement dans des situations réelles. Pour cela, l'évaluation doit reposer sur une approche qui saisit la capacité du classifieur à généraliser à de nouvelles données. Ainsi, plutôt que d'utiliser le même ensemble de données pour l'apprentissage et l'évaluation, il est préférable d'utiliser des techniques d'échantillonnage pour construire et évaluer le modèle sur des données indépendantes tirées de la même population.

C'est là qu'intervient l'évaluation par validation croisée. Les deux principales variables évaluées lors de la validation croisée sont : [57]

II.2.3.2.1. Validation croisée simple

Cette méthode est adaptée aux cas où l'on dispose d'un petit jeu de données. Elle constitue une technique d'évaluation statistique qui implique de diviser les données en deux échantillons : l'échantillon d'apprentissage (D_a), utilisé pour former le modèle, et l'échantillon de test (D_t), utilisé pour évaluer ce modèle, tout en tenant compte de la distribution de la variable de classe.

Généralement, l'échantillon d'apprentissage (D_a) représente 60 % des données, tandis que l'échantillon de test (D_t) représente les 40 % restants. Ainsi, nous débutons par la construction du classifieur en utilisant les observations de D_a , puis nous évaluons le modèle en construisant la matrice de confusion (M) et en prédisant la classe de chaque observation dans D_t .

II.2.3.2.2. K-Validation croisée

La validation croisée k-fold est la méthode la plus recommandée, à condition d'avoir suffisamment de données pour l'appliquer. Tout d'abord, nous choisissons une valeur pour k (généralement, nous prenons $k=10$). Ensuite, nous divisons les données en k blocs de taille égale (D_1, D_2, \dots, D_k). Ensuite, nous construisons k classifieurs, chacun basé sur l'observation d'un bloc de données D_i , où i est compris entre 1 et k. Enfin, pour chaque classifieur, nous construisons une matrice de confusion M_i basée sur les k-1 autres blocs de données (D_j , ou j appartient à $[1, k]$ et $j \neq i$).

II.3. Le traitement d'image

II.3.2. Image Numérique

Dans le monde réel, une image peut être une photographie, une peinture ou même un rêve, mais dans le monde des ordinateurs, c'est un ensemble de points appelés "pixels". Une telle image est communément appelée image numérique et définie formellement comme un tableau de pixels dont les valeurs spécifient l'intensité lumineuse du flux sur l'élément d'image représenté par ce pixel. Comme mentionné précédemment, l'image numérique est une fonction de deux variables x et y, responsables de la distribution (positions) des pixels de l'image. Les positions et les valeurs sont des scalaires positifs dont la plage dépend des caractéristiques de l'unité de numérisation. La valeur de chaque pixel peut être comprise entre 0 et 255. Trois types différents d'images numériques peuvent être illustrés :

- Image en noir et blanc,
- Image en niveaux de gris,
- Image en couleur.

II.3.3. Acquisition d'Image

Avant de pouvoir entamer toute procédure de traitement d'image, il est nécessaire de capturer une image et de la convertir en forme numérique. Ce processus est appelé acquisition d'image ; son objectif est de transformer une vue du monde réel en une image numérique. Cependant, une bonne compréhension du processus de formation de l'image est essentielle pour toute analyse quantitative des images.

Pour qu'un objet du monde tridimensionnel devienne une image numérique dans la mémoire d'un ordinateur, il doit passer par trois étapes nécessaires :

- **Devenir visible:** En interagissant avec la lumière ou plus généralement avec une radiation électromagnétique, un objet peut devenir visible. La lumière collectée par un système de caméra est déterminée par les propriétés optiques du matériau dont l'objet est constitué ainsi que par l'éclairage
- **Projection :** Le système optique collecte les rayons lumineux réfléchis par les objets et projette le monde tridimensionnel sur un plan d'image bidimensionnel.
- **Numérisation :** L'image continue sur le plan de l'image doit être convertie en points d'image sur une grille discrète. De plus, l'intensité à chaque point doit être représentée par un nombre fini approprié de valeurs de gris (quantification).
- **Amélioration et Restauration d'Image**

Sur Internet, dans nos téléphones et ordinateurs portables, des millions d'images allant des images biomédicales aux images des environnements naturels contiennent une quantité importante d'informations utiles dans divers domaines d'application. La qualité de l'image de sortie peut être inférieure à celle de l'image d'origine lorsqu'elle est convertie d'une forme à une autre par des processus tels que l'imagerie, la numérisation ou la transmission. Il est donc nécessaire d'améliorer la qualité de ces images afin que l'image de sortie soit meilleure pour la perception humaine ou l'analyse par machine.

Le domaine de l'amélioration d'image englobe le renforcement du contraste et des contours, le filtrage du bruit, l'accentuation des caractéristiques, et ainsi de suite. Ces méthodes trouvent des applications dans l'affichage d'informations visuelles, l'extraction de caractéristiques, la reconnaissance d'objets, et bien

d'autres encore. Elles visent principalement à améliorer l'apparence visuelle de l'image ou à rendre l'image d'origine plus adaptée au traitement humain ou informatique.




Figure 30: Capture d'image : Une scène est éclairée par l'énergie provenant d'une source lumineuse. La lumière réfléchiée peut tomber sur le détecteur et être capturée.

II.3.4. Amélioration et restauration d'image

Parfois, nous recevons des images floues ou bruitées qui sont dégradées par un mécanisme de dégradation quelconque. Un flou peut être causé par une caméra mal mise au point, une dégradation atmosphérique, ou un mouvement relatif accéléré entre l'objet et le plan focal de l'objectif de la caméra lors de la capture d'une scène. Dans de tels cas, les techniques d'amélioration conventionnelles ne seraient pas adaptées pour clarifier l'objet dans l'image, mais la restauration ou la reconstruction de la scène originale pourrait fonctionner très bien si nous pouvons modéliser mathématiquement la cause de la dégradation.

Il va sans dire que les techniques de reconstruction ou de restauration diffèrent des techniques d'amélioration, qui sont employées non pas nécessairement pour récupérer l'objet original de la scène, mais essentiellement pour obtenir une image de meilleure qualité. Les techniques de restauration d'image cherchent à récupérer une image qui a été dégradée par un phénomène

de dégradation, tandis que le but ultime des techniques d'amélioration d'image est d'améliorer la qualité de l'image.

II.3.5. Techniques d'amélioration spatiale de l'image

Les techniques de filtrage spatial utilisées pour la réduction du bruit (ou le lissage) sont les suivantes :

- Filtrage spatial passe-bas, passe-haut et passe-bande.
- Accentuation floue et accentuation.
- Lissage directionnel.
- Filtrage médian.

II.3.5.1. Filtrage spatial passe-bas et passe-haut

Dans la théorie du traitement du signal, le filtrage passe-bas atténue la composante haute fréquence du signal et est essentiellement équivalent à l'intégration du signal. Une telle intégration implique la sommation et la moyennisation du signal. Le filtre passe-bas est également appelé filtre de flou ou de lissage, c'est une opération de moyennisation spatiale. Le filtre passe-bas le plus simple calcule simplement la moyenne d'un pixel et de tous ses huit voisins immédiats, de sorte que la valeur d'origine du pixel sera remplacée par la valeur résultante. En particulier, cette opération est utile pour éliminer le bruit visuel, qui apparaît généralement sous forme de points lumineux nets dans l'image.

D'autre part, le filtrage passe-haut d'une image produit une image de sortie dans laquelle les composantes de basse fréquence spatiale sont atténuées ; il est principalement utilisé pour l'amélioration des contours afin de mettre en évidence les détails fins de l'image. Puisque la netteté d'une image est liée au contenu des composantes haute fréquence, le filtrage passe-haut est utilisé pour la déconvolution, tandis que le filtrage passe-bas conduit au flou. Un tel filtre peut facilement être implémenté en soustrayant la sortie passe-bas de son entrée. Typiquement, le filtre passe-bas effectuerait un moyen spatial relativement long terme, $((2q + 1) \times (2q + 1))$ avec $q \in \mathbb{Z}^+$ fenêtre [34].

II.3.5.2. Moyennage et filtrage passe-bas spatial

Chapitre II : l'Apprentissage profondi.

Si l'image résultante est une image filtrée passe-bas, ce qui signifie que chaque pixel est remplacé par une moyenne pondérée de ses pixels voisins, l'image de sortie dans ce cas est exprimée comme suit :

$$g(m, n) = \sum \sum_{-q \leq k, i \leq q} a(k, i) f(m - k, n - i)$$

où (m, n) et (m, n) sont respectivement les images d'entrée et de sortie, W est un voisinage convenablement choisi autour du pixel à la position (m, n) , $(m - k, n - i) \in W$, et $a(m - k, n - i)$ sont les poids du filtre.

En général, dans les filtres de moyennage spatial, tous les poids se voient attribuer des valeurs égales.

Ainsi, la représentation mathématique du filtrage devient : où N est le nombre de pixels dans le voisinage W .

$$g(m, n) = \frac{1}{N} \sum \sum_{-q \leq k, i \leq q} f(m - k, n - i)$$

L'opération de moyennage spatial sur une image peut être utilisée pour atténuer le bruit. Si l'image observée est donnée par : $(m, n) = (m, n) + (m, n)$

Alors la moyenne spatiale donne :

$$g(m, n) = \frac{1}{N} \sum \sum_{-q \leq k, i \leq q} f(m - k, n - i) + \mu(m, n)$$

Où $\bar{\mu}(m, n)$ est la moyenne spatiale de la composante de bruit $\mu(m, n)$. Si le bruit a une variance σ^2 , alors on peut montrer que $\bar{\mu}(m, n)$ a une moyenne nulle et une variance σ^2/N . Cela implique que la puissance du bruit de l'image est réduite d'un facteur égal au nombre de pixels choisis dans le voisinage du pixel central en effectuant le filtrage par moyennage spatial.

Le filtrage spatial conventionnel utilise une procédure de moyennage pour générer l'image lissée. Les poids utilisés pour la moyenne sont invariants par rapport aux données de l'image. Ainsi, toutes les régions de l'image qui peuvent être incluses dans un voisinage arbitraire W sont également affectées. De cette manière, le filtrage spatial par moyennage :

- I. Ne prend pas en compte l'effet de la différence de niveaux de gris entre le pixel central et un pixel voisin.
- II. Ne tient pas toujours compte de l'influence décroissante des pixels situés à une distance croissante du pixel central.[34]

Comme nous l'avons observé ci-dessus, une image nette peut être obtenue en filtrant une image floue avec un filtre passe-haut. Alternativement, soustraire une version floue de l'image de l'image originale peut également conduire à la netteté de l'image. Voici l'équation correspondante :

II.3.5.3. Masque de netteté et accentuation

Comme nous l'avons observé précédemment, une image nette peut être obtenue en filtrant une image floue avec un filtre passe-haut. Alternativement, soustraire une version floue de l'image de l'image originale peut également conduire à la netteté de l'image.[34]

$$v(m, n) = f(m, n) + g(m, n)$$

Où (m, n) est une version de l'image originale filtrée par un filtre passe-bas.

Un masque de netteté (Unsharpmask) est simplement un autre type de filtre passe-haut. Un tel masque est construit en filtrant une image avec un filtre passe-bas. Généralement, le masque est mis à l'échelle avant d'être soustrait pour faciliter le contrôle de la quantité de netteté appliquée. De plus, la force du filtre passe-bas utilisé peut également être ajustée. D'un autre point de vue, pour obtenir une meilleure image à fort contraste, un gradient ou un signal passe-haut peut être ajouté à l'image originale. L'opération de masquage de netteté peut être représentée par :

$$(m, n) = (m, n) + \gamma h(m, n)$$

où $\gamma > 0$ et $h(m, n)$ est un gradient défini de manière appropriée en (m, n) . Cela est également appelé filtre à forte accentuation où les composantes de basse fréquence sont conservées tout en mettant en évidence les composantes de haute fréquence de l'image.

II.3.5.4. Lissage directionnel

Une image floue est toujours le résultat lors de l'utilisation d'un filtre passe-bas et très souvent, les contours nets sont floutés par la moyenne. Pour minimiser cet effet, l'opération de moyenne directionnelle est souvent utilisée pour empêcher les contours de devenir flous suite à l'opération de lissage. Les moyennes spatiales $(m,n ; \theta)$ sont calculées dans plusieurs directions θ comme suit : $g(m, n; \theta) = -f(m - k, n - i)$.

Où $(m - k, n - i) \in W_0$, et W_0 est le voisinage sélectionné dans la direction θ .

La clé de la mise en œuvre d'un lissage directionnel efficace est d'identifier une direction spécifique θ^* pour laquelle $|(m, n) - g(m, n; \theta^*)|$ est minimale.

II.3.5.5. Filtre médian

Le filtre médian standard (SM) est un lissage non linéaire simple ; Il est particulièrement efficace pour réduire le bruit de type impulsif [66]. Dans le filtrage médian, le pixel d'entrée est remplacé par la médiane des pixels contenus dans le voisinage [45]. Symboliquement, cela peut être représenté comme suit :

$$(m, n) = \text{médian} \{y(m - k, n - i) \mid y(k, i) \in W, -q \leq k, i \leq q\}$$

Où W est un voisinage convenablement choisi. L'algorithme de filtrage médian nécessite d'organiser les valeurs de gris des pixels dans le voisinage par ordre croissant ou décroissant, puis de sélectionner la valeur située au centre du tableau (voir Figure 31). Généralement, la taille du voisinage est choisie comme un nombre impair afin qu'une valeur centrale bien définie existe. Si, cependant, la taille du voisinage est paire, la médiane est calculée comme la moyenne arithmétique des deux valeurs au centre.

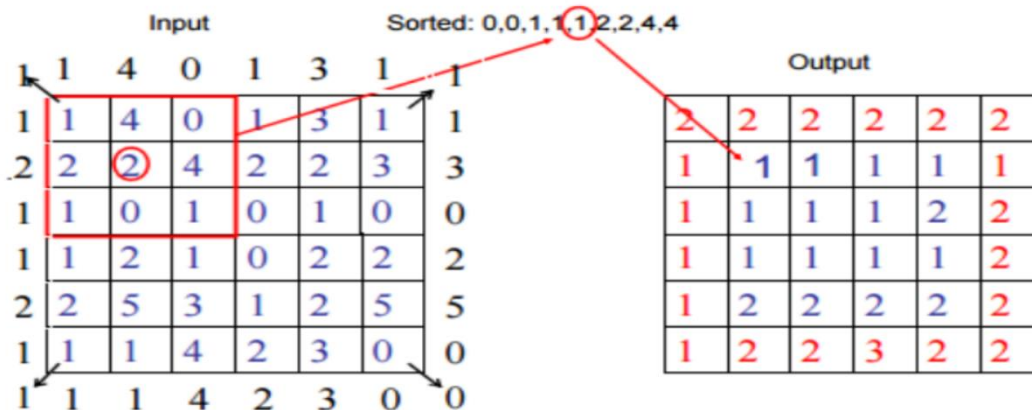


Figure 31: exemple de filtre médian utilisant une fenêtre d'échantillonnage 3*3.

II.3.6. Traitement d'image VS Vision par ordinateur

Dans de nombreux contextes, les termes "vision par ordinateur" et "traitement d'image" sont utilisés presque comme s'ils se confondaient dans le même concept. Ils impliquent tous les deux la réalisation de calculs sur des images. Mais sont-ils vraiment identiques?

Dans le traitement d'image, une image est donnée en entrée pour être "traitée", et une image de sortie est renvoyée après l'application des transformations en fonction du contexte et des objectifs à atteindre. Les transformations peuvent être le "lissage", "l'affûtage", "le contraste" et "l'étirement". Contrairement à la vision par ordinateur, qui prend une image ou une vidéo en entrée, le but étant d'acquérir une compréhension de haut niveau de l'image et de son contenu, y compris la capacité d'en déduire quelque chose. La vision par ordinateur utilise des algorithmes de traitement d'image pour résoudre certaines de ses tâches.

La transition du traitement d'image à la vision par ordinateur peut être classée en trois niveaux de processus : bas, moyen et haut niveau [13] (voir Figure 30). Dans le processus de bas niveau, à la fois les entrées et les sorties sont définies comme des images, de tels processus concernent les opérations de prétraitement d'image telles que l'amélioration du contraste, la réduction du bruit et l'affûtage de l'image. Les processus de niveau moyen concernent des opérations telles que la segmentation, la représentation et la description, et la classification des objets. Enfin, dans la dernière étape, des processus de haut niveau sont réalisés pour donner un sens, une compréhension et une navigation autonome des objets individuels pour la vision. Ainsi, du niveau bas au niveau moyen, les processus sont dédiés au traitement d'image, tandis que du niveau moyen au niveau haut, les processus sont dédiés à la vision par ordinateur.

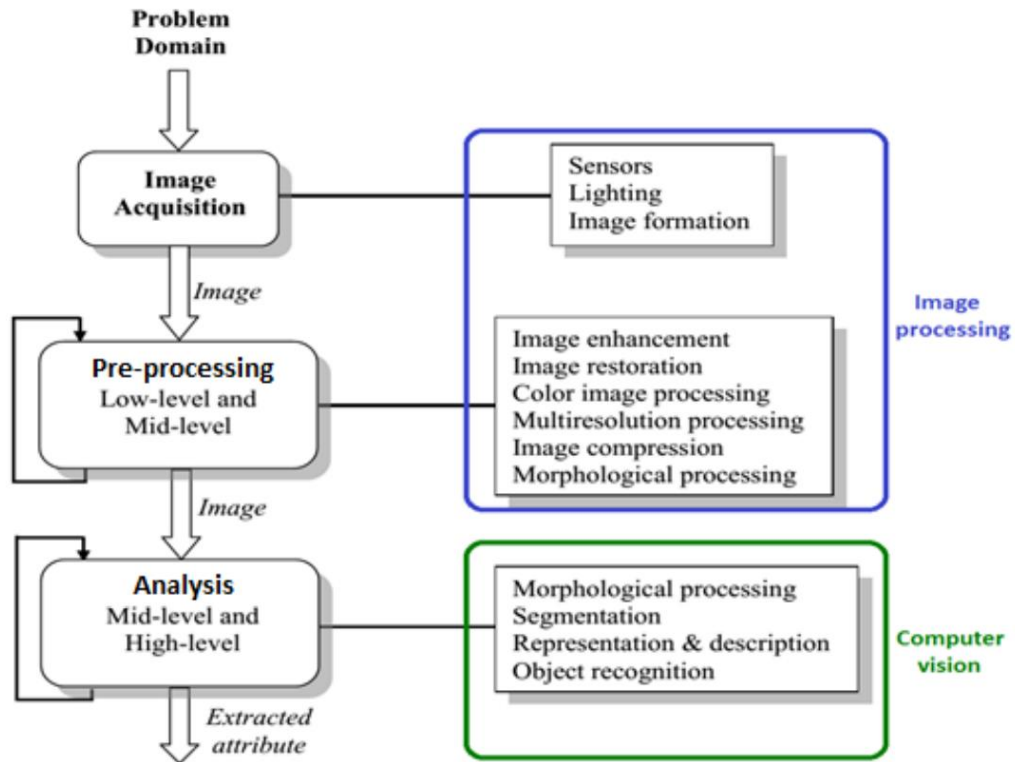


Figure 32: Transition du Traitement d'Image à la Vision par Ordinateur.

II.4. Image Classification

II.4.2. Les motivations de la classification d'images

L'objectif de la classification d'images est de développer un système capable d'attribuer automatiquement une classe à une image. Ainsi, ce système permet d'effectuer une tâche d'expert qui peut être coûteuse à acquérir pour un être humain en raison notamment de contraintes physiques telles que la concentration, la fatigue ou le temps nécessaire par un grand volume de données d'image.

Les applications de la classification automatique d'images sont nombreuses et vont de l'analyse de documents à la médecine et à l'armée [54]. Ainsi, nous trouvons des applications dans le domaine médical telles que la reconnaissance de cellules [37], de tumeurs dans les mammographies, en agriculture comme la classification du pollen la reconnaissance du type de sol et des grains [43] [63] [62], la classification des herbes; dans le domaine du document comme la reconnaissance d'écriture pour les chèques, les codes postaux, les cartes; dans le domaine urbain comme la reconnaissance de panneaux de signalisation [65], la reconnaissance de piétons [61], la détection de véhicules, la reconnaissance des bâtiments [49] pour aider à la localisation; dans le domaine des bio marqueurs

tels que la reconnaissance faciale [22] [50], les empreintes digitales, les iris [21]. Le point commun de toutes ces applications est qu'elles nécessitent l'établissement d'une chaîne de traitement à partir des images disponibles composée de plusieurs étapes afin de fournir une décision en tant que sortie. Chaque étape dans l'établissement d'un tel système de classification nécessite la recherche de méthodes appropriées pour des performances globales optimales ; notamment la phase d'extraction de caractéristiques et la phase d'apprentissage. Typiquement, nous disposons de données d'image à partir desquelles nous devons extraire des informations pertinentes traduites en vecteurs numériques. Cette phase d'extraction nous permet de travailler dans un espace numérique. Il s'agit alors de développer, dans la phase d'apprentissage, à partir de ces données initiales, une fonction de décision pour décider si une nouvelle donnée appartient à l'une des classes impliquées.

La phase d'extraction de caractéristiques peut être précédée d'une phase dite de prétraitement. Le but de cette phase est de nettoyer l'image (comme mentionné dans le premier chapitre de ce thème), c'est-à-dire d'isoler le contenu informatif ou intéressant dans l'image. Cette opération permet ainsi de masquer ou d'atténuer toute information susceptible de nuire à la description du contenu pertinent lors de la phase d'extraction de caractéristiques. Nous trouvons ainsi des techniques d'atténuation du bruit, de renforcement des contours, des techniques d'amélioration de l'image telles que l'amélioration du contraste, la réduction de la taille de l'image par binarisation [51], la réduction de l'image à ses primitives visuelles telles que la squelettisation [33] [38] ou même l'extraction des contours à l'aide de techniques de filtrage. Le lecteur peut se référer à un état de l'art des techniques de prétraitement dans [38] .

II.4.3. Classification

La classification consiste à attribuer des individus à des classes préexistantes. Ces classes peuvent éventuellement être obtenues par regroupement. On dit alors qu'il y a un processus d'apprentissage. Il s'agit d'une tâche d'apprentissage supervisé où la sortie a des étiquettes définies (valeur discrète). Il peut s'agir d'une classification binaire ou multi-classe. Dans la classification binaire, le modèle prédit 0 ou 1 ; oui ou non, mais dans le cas de la classification multi-classe, le modèle prédit plus d'une classe.

II.4.3.1. La classification binaire

Chapitre II : l'Apprentissage approfondi.

La classification binaire est un problème de classification dans lequel l'espace des étiquettes est binaire, c'est-à-dire $y = \{0,1\}$. Il s'agit d'un type de tâche de classification qui prédit l'une des deux classes mutuellement exclusives. Par exemple, un modèle d'apprentissage automatique qui classe les e-mails comme "indésirables" ou "légitimes".

D'autres exemples de classification binaire :

- Identifier si une peinture a été peinte par Picasso ou non.
- Identifier si une image contient ou non une girafe.
- Identifier si une molécule peut traiter la dépression.
- Identifier si une transaction financière est frauduleuse.

II.4.3.2. Multi-class classification

Un problème de classification dans lequel l'espace des étiquettes est discret et fini, c'est-à-dire $y = \{1,2, \dots, c\}$ est appelé un problème de classification multi-classe. c représente le nombre de classes. Voici quelques exemples de problèmes de classification multi-classe :

- Identifier dans quelle langue un texte est écrit.
- Identifier lequel des 10 chiffres arabes est un nombre écrit à la main.
- Identifier une expression faciale à partir d'une liste prédéfinie de possibilités (colère, tristesse, joie, etc.).
- Identifier à quelle espèce appartient une plante.
- Identifier les objets présents dans une photographie.

II.4.4. Conclusion

Le deep learning a marqué une avancée significative dans le domaine de l'intelligence artificielle, en exploitant la puissance des réseaux de neurones artificiels pour résoudre des tâches complexes. Parmi ses nombreuses applications, le traitement d'image a bénéficié de progrès remarquables grâce aux réseaux de neurones convolutifs (CNN), permettant des niveaux de précision et de performance sans précédent. La classification d'images, en particulier, a été révolutionnée par ces technologies, facilitant l'identification et l'étiquetage automatiques des objets avec une grande précision. Ces innovations

Chapitre II : l'Apprentissage profond.

ont transformé divers secteurs, de la reconnaissance faciale à l'imagerie médicale et à la conduite autonome, rendant les systèmes de traitement d'image plus intelligents et plus efficaces. Le deep learning continue ainsi d'ouvrir de nouvelles perspectives et d'amplifier les capacités des technologies modernes.

Chapitre III

III.1. Introduction

L'importance de la production agricole pour le développement économique est indéniable, mais les cultures sont susceptibles d'être infectées par des agents pathogènes pendant leur croissance, ce qui peut réduire la production ou causer la mort des plantes. Pour minimiser les pertes économiques, un diagnostic précis des maladies des plantes est crucial et l'intelligence artificielle est un outil largement utilisé à cette fin. Les mesures de gestion et de contrôle des maladies, y compris la surveillance régulière des cultures et un diagnostic précis, sont essentielles pour réduire l'impact négatif des maladies des plantes sur la production alimentaire et la productivité économique.

Dans ce chapitre, nous aborderons le domaine de l'agronomie, en mettant l'accent sur les plantes et les diverses maladies qui les affectent.

III.2. L'Agronomie

L'agronomie est la science de l'agriculture en général - qui étudie les opérations de production et les personnes qui les mettent en œuvre [26].

Au sens restreint, l'agronomie est consacrée à l'ensemble des aspects de la production de végétaux [26].

Au sens large, l'agronomie inclut des notions de zootechnie (science des pratiques d'élevage), de pédologie (science des sols), d'écologie (science des interactions des êtres-vivants avec leurs milieux), d'économie, de foresterie, etc.[26].

C'est une science passionnante qui se trouve à l'interface de nombreuses problématiques (production alimentaire, gestion des ressources et des écosystèmes, impacts environnementaux de l'agriculture, ...), qui mobilise des compétences d'observation, d'échanges et de modélisation notamment, et qui est en interaction constante avec nombres disciplines (géographie, sociologie, ...)[26].

Plus concrètement, l'agronomie s'intéresse :

- à la sélection et à la culture des végétaux : utilisés pour nourrir les hommes et animaux, pour se vêtir, comme source d'énergie, ... [26]

Chapitre III : Agronomie et détection des maladies des plantes.

- aux interactions entre ces plantes et les différents composants de l'agro-écosystème : (sol, atmosphère, prédateurs, auxiliaires, aquifères, ...) pour favoriser la croissance des végétaux, diminuer les pollutions, maintenir le potentiel de production, ... [26]
- aux pratiques et techniques de culture : (par exemple dates et conditions de semis des céréales, techniques de taille des fruitiers, fréquence et volumes d'irrigation de la vigne, ...) [26]
- aux outils et matériels utilisés : (tracteurs et outils de travail du sol, machines de récolte et de vendange, matériel de traitement, installation de séchage, tri et stockage des récoltes, ...) [26]
- à la gestion des plantes adventices, des maladies et des ravageurs : par différentes méthodes de lutte (mécanique, chimique, biologique, ...) [26]
- aux modalités de renouvellement de la fertilité du sol, etc [26].

III.3. L'Agriculture

Au sens restreint, Larousse définit l'agriculture comme "l'ensemble des travaux dont le sol fait l'objet en vue d'une production végétale" [26].

Mais le terme désigne plus largement toutes les activités liées à la production de plantes : travail du sol certes, mais aussi désherbage, gestion des prédateurs et maladies, récolte, sélection des variétés les plus adaptées, aménagements des parcelles et des abords, gestion de l'eau par drainage ou irrigation, transformation éventuelle et commercialisation des productions, etc [26].

Et cela concerne toutes les plantes : comestibles par les humains, utilisées en tant que fourrage pour les animaux, à destination médicinales aromatiques et à parfum, pour la production énergétique via méthanisation ou "biocarburants" [26].

Enfin, au sens large - et presque par abus de langage - le terme agriculture inclut aussi les pratiques d'élevage [26].

III.3.1. L'Agro écologie

L'agroécologie est un modèle d'agriculture écologiquement et socialement plus responsable, qui tend vers une alimentation et une gestion des ressources plus durables. Elle repose notamment sur une moindre utilisation d'intrants (engrais minéraux et pesticides notamment), et sur des pratiques favorisant les

Chapitre III : Agronomie et détection des maladies des plantes.

régulations biologiques (rotations culturales longues, haies, associations de cultures, ...)[26].

D'après le dictionnaire d'Agro Ecologie, l'agro écologie n'est pas qu'un modèle d'agriculture, mais aussi un mouvement social et un domaine scientifique en construction (considéré par certains comme indépendant, par d'autres comme partie du domaine scientifique de l'agronomie)[26].

III.3.2. L'Agroforesterie

L'agroforesterie est une pratique qui consiste à cultiver des espaces qui sont également arborés. De multiples systèmes d'agroforesterie existent, de l'arbre isolé conservé dans une parcelle, à l'implantation et l'entretien de haies multi spécifiques, en passant par les systèmes de plantation d'arbres de la même espèce en rangs avec culture des intégrants (céréales et noyers, pâturages arborés, ...) [26].

Les avantages attendus de la présence d'arbres sont multiples : contribution au renouvellement de la fertilité des sols (remontée d'éléments nutritifs depuis les horizons profonds du sol), diversité des habitats et donc des auxiliaires de culture, effet brise-vent, ombrage, diversité des productions (cultures, mais aussi fruits, bois, voire feuillage parfois utilisé comme fourrage pour les animaux)[26].

III.4. Plante

Les plantes sont des organismes photosynthétiques et autotrophes, caractérisés par des cellules végétales. Elles forment l'un des règnes des Eucaryotes .Ce règne est un groupe monophylétique comprenant les plantes terrestres[26].

Une plante est composée de 3 grandes parties : racines, tiges et feuilles. La façon dont sont ordonnées ces 3 parties conditionne le port de la plante. La reproduction est assurée par les fleurs, qui peuvent être groupées en inflorescence. Les fruits, issus de la fécondation des fleurs, ont des formes très différentes selon les plantes.

Les classifications végétales sont toutes basées sur ces différents critères anatomiques qui ont évolué au cours des temps [31] .



Figure 33 : représentant des plantes.

III. 3.1. Les maladies des plantes

Une feuille jaunie n'est peut-être pas grand-chose mais en regardant de plus près et en ayant les bons gestes, vous pouvez identifier et donc éviter certaines maladies ainsi que leur propagation [28].

Les maladies des plantes sont soit causées par un organisme vivant (biotique), soit produites par des impacts environnementaux (abiotiques) tels que la grêle, les gelées de printemps, les conditions météorologiques, les brûlures dues aux produits chimiques, etc. Ces dernières sont moins dangereuses et peuvent être évitées car elles sont non infectieuses et non transmissibles [58]. D'autre part, les maladies biotiques sont les plus dangereuses et causent les plus grands dommages aux cultures. Elles sont classées en trois catégories principales, à savoir :

- ✓ **Maladies fongiques** : Elles sont causées par des champignons ou des organismes similaires, et sont responsables d'environ 85% des maladies des plantes. Les spores fongiques sont très petites et légères, ce qui signifie qu'elles peuvent se déplacer dans l'air pour infecter d'autres plantes ou arbres.
- ✓ **Maladies bactériennes** : Elles sont causées par environ 200 types de bactéries, et peuvent se propager par les insectes, les éclaboussures d'eau, d'autres plantes ou outils malades.
- ✓ **Maladies virales** : Elles sont causées par des virus et sont considérées comme le type le plus rare de maladies des plantes. Cependant, une fois infectées, il n'existe aucun traitement chimique pour éliminer un virus et

Chapitre III : Agronomie et détection des maladies des plantes.

toutes les plantes suspectes doivent être retirées pour arrêter l'infection. Ils doivent pénétrer physiquement dans la plante et les porteurs les plus courants sont les insectes [55].

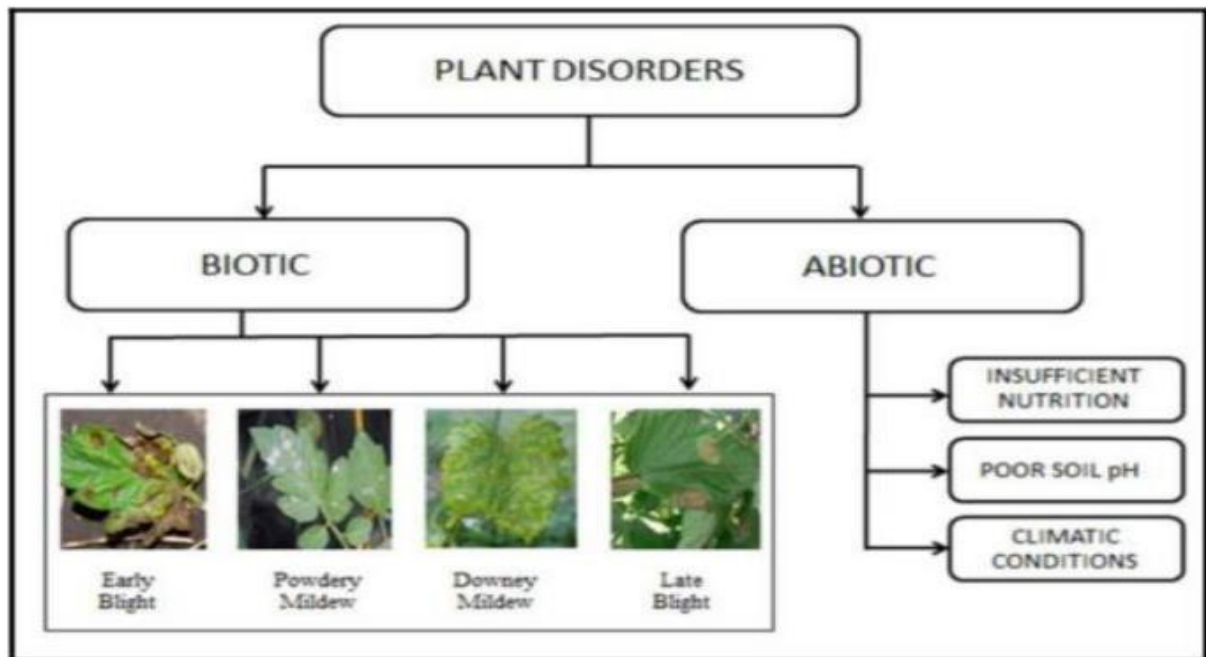


Figure 34 : les types de maladies.

Les plantes sont menacées par des maladies causées par des microorganismes : virus, bactéries ou encore champignons. Ces maladies causent d'importantes pertes de rendement, sur les cultures vivrières, fruitières, légumières et ornementales, en particulier dans les zones tropicale et tempérée chaude. Ce sont parfois des récoltes, voire des filières tout entières, qui sont anéanties. Et de nouvelles maladies émergent régulièrement, à cause de mutations des agents pathogènes, ou encore de leur adaptation à de nouveaux environnements [25]. Nous avons regroupé les principales maladies qui affectent plantes, arbres fruitiers, rosiers ou encore légumes.

III.3.1.1. Alternariose

- **Principales plantes touchées** : carottes – tomates – pomme de terre – tournesol.
- **Description** : brunissement des feuilles et des fruits ainsi que la pourriture des tubercules.
- **Cause** : Maladie fongique causée par un champignon alernia ou ulocladium suite à une atmosphère trop humide (condensation sous tunnel plastique ou la rosée en plein champ).

- **Solution** : jeter les plants affectés et ne pas les composter. Aérer le sol et les cultures et réduire l'humidité en aérant les abris[4].



Figure 35 : ALTERNARIOSE[4].

III.3.1.2. Anthracnose

- **Principales plantes touchées** : arbres, arbustes d'ornements, fruitiers.
- **Description** : apparition en hiver de tâches brunes avec des points noirs sur les feuilles et des grains violacés.
- **Cause** : infection par un champignon. Ce champignon se développe dans des environnements dans des terres humides.
- **Solution** : arracher les feuilles et fruits atteints et incinerez les. Vous pouvez utiliser du purin de consoude ou une solution à base d'ortie ou d'ail [28].



Figure 36 : Anthracnose [4].

III.3.1.3. Brûlure

- **Principales plantes touchées** : général au niveau des plantes.
- **Description** : tâche brune apparaissant surtout au début du printemps. Les fleurs se flétrissent et noircissent soudainement.
- **Cause** : mauvais placement des plantes et condition trop humide ou pluvieuse avec des températures variant entre 18°C et 25°C.
- **Solution** : trop souvent la plante est au mauvais endroit. Déplacer votre plante ou protégez-la éventuellement par un arbre plus grand, une fougère haute ou tout autre plante qui pourrait servir de parasol naturel [28].



Figure 37 : Brûlure [4].

III.3.1.4. Eclatement ou fissuration des fruits

- **Principales plantes touchées** : tomates et fruits à noyau (cerise, prune)
- **Description** : le fruit tend à éclater ou à se fendre
- **Cause** : trop d'alternance de période sèche et humide qui conduisent à une trop grande distorsion de la peau des fruits qui tendent à éclater lors d'une trop grande irrigation ou averse
- **Solution** : arrosez régulièrement la plante quand elle est à ce stade pour éviter un stress physiologique. Une réduction de la charge des arbres (par taille sélective) diminue les risques. Dans les régions à fortes précipitations en fin de saison, sélectionnez les espèces résistantes à de tels changements [28].



Figure 38 : Eclatement ou fissuration des fruits [4].

III.3.1.5. Fonte des semis :

- **Principales plantes touchées :** semis.
- **Description :** affaissement des semis .
- **Cause :** Maladie fongique causée par des champignons.
- **Solution :** utilisez un terreau neuf et arrosez avec de l'eau du robinet. Gardez les plants dans un endroit bien aéré [28].



Figure 39 : Fonte des semis[4].

III.3.1.6. Hernie du chou

- **Principales plantes touchées** : brassicacées et très particulièrement le chou.
- **Description** : défaut ou retard de croissance, jaunissement des feuilles
- **Cause** : maladie cryptogamique qui cause des excroissances sur les racines principales et sur le collet.
- **Solution** : pratiquez la rotation des cultures et cultivez des variétés résistantes [28].



Figure 40 : Hernie du chou [4].

III.3.1.7. Mildiou

- **Principales plantes touchées** : général. Le plus connu : vigne, pomme de terre, tomate.
- **Description** : tâche brune sur le feuillage ou moisissure blanche et cotonneuse suivi d'un flétrissement de feuille.
- **Cause** : Maladie provoquée par des pseudo-champignon dont l'apparition vient lors de temps humide ou lors d'arrosage sur les feuilles.
- **Solution** : améliorer la circulation de l'air et éviter de mouiller les feuilles lors de l'arrosage. Aérer les cultures et éliminer les plants atteints ou

traiter avec du purin d'ail. Pailler vos cultures car le paillage réduira les risques de propagation [28].



Figure 41 : Mildiou [4].

III.3.1.8. Moniliose

- **Principales plantes touchées** : fruitiers
- **Description** : commence par un dessèchement des feuilles et un dépérissement des rameaux. Survient ensuite une momification des fruits sur la branche avec présence de pourriture blanche sur le fruit
- **Cause** : Maladie cryptogamique causée par un champignon *Monilia fructigena* et *Monilia laxa* qui infecte les fleurs, les feuilles ou les fruits. La maladie apparaît quand la pluie arrive au moment de la floraison
- **Solution** : éliminer les fruits malades et protéger des oiseaux. Eclaircissez vos arbres si trop de fruits sont présents au printemps pour éviter que les fruits se touchent et se contaminent. Désinfectez vos outils lors des tailles des fruits. Vous pouvez utiliser une infusion de raifort ou de prêle en prévention [28].



Figure 42 : Moniliose [4].

III.3.1.9. Montaison

- **Principales plantes touchées** : légumes.
- **Description** : les plantes fleurissent et montent en graines trop rapidement
- **Cause** : Température trop élevée pour la saison ou une forte sécheresse. Le non respect des dates de semis et de mauvais arrosages peuvent en être aussi la cause.
- **Solution** : arroser régulièrement et vérifier les dates de semis[28].



Figure 43 : Montaison[4].

III.3.1.10. Nécrose apicale

- **Principales plantes touchées** : tomates –
- **Description** : tache noire au sommet des légumes/fruits.
- **Cause** : Maladie causée par une mauvaise assimilation du calcium due à des différences d'humidité du sol.
- **Solution** : Arrosez plus régulièrement et vérifiez l'humidité de la terre pour qu'elle reste constante. En préventif, apportez du compost à votre terre pour l'enrichir [28].



Figure 44 : Nécrose apicale [4].

III.3.1.11. Oïdium

- **Principales plantes touchées** : chêne, érable, cognassier, pommier, aubépine, légumes (betterave, carotte, tomate...)
- **Description** : tâche blanche sur les feuilles et les tiges qui ressemblent à une poudre blanche. Les feuilles ont tendance à se gondoler.
- **Cause** : maladie cryptogamique arrivant par temps sec. Arrive souvent en mai.
- **Solution** : arroser les plantes au pied et couper les parties atteintes. Traiter légèrement avec une solution à base d'eau de javel diluée. Traitement à faire sans soleil et en isolant la plante à traiter en l'entourant d'une bâche. Il faut empêcher la pénétration du traitement dans le sol [28].



Figure 45 : Oïdium[4].

III.3.1.12. Phytophthora :

- **Principales plantes touchées** : pomme de terre, fraisier, genévrier, thuyas, pommier
- **Description** : des feuilles deviennent marron de façon homogène.
- **Cause** : infection par un champignon. Celui-ci arrive par des blessures aux racines et remonte dans la plante. Un sol trop engorgé favorise le développement de ce champignon.
- **Solution** : il n'existe malheureusement aucun traitement. Il faut arracher la plante et enlever la terre aux alentours et laisser aérer le trou. Améliorez le drainage de votre terrain peut permettre d'éviter une telle contamination [28].



Figure 46 : Phytophthora[4].

III.3.1.13. Pourriture grise – botrytis

- **Principales plantes touchées** : fruitiers et rosier principalement mais touche de façon générale les plantes, fruits ou légumes.
- **Description** : apparition de feutrage brun ou de pourritures grises sur tout ou partie de la plante, fruit ou légume
- **Cause** : Maladie cryptogamique causée par champignon (botrytis) en situation humide et s'aggrave en période chaude avec risque de pourriture acide.
- **Solution** : couper les parties atteintes et préparez le sol correctement en désherbant soigneusement pour éviter de garder trop d'humidité dans le sol. N'apportez pas trop d'engrais azoté. Vous pouvez utiliser du purin d'ortie ou une solution de savon noir[28].



Figure 47 : Pourriture grise – botrytis [4].

III.3.1.14. Rouille

- **Principales plantes touchées** : général : arbustes, arbres, fleurs, légumes ou fruitiers
- **Description** : tâche brun-oranger sur la partie inférieure des feuilles et des auréoles rougeâtres ou jaunâtres sur la partie supérieure.
- **Cause** : maladie cryptogamique, elle cause des dommages esthétiques et un affaiblissement du végétal. Les temps pluvieux ou des arrosages répétés ainsi que les engrais trop azotés peuvent en être la Cause
- **Solution** : éliminer les parties atteintes et enlever les débris. Vous pouvez utiliser du purin de prêle ou d'ortie [28].



Figure 48 : Rouille[4].

III.3.1.15. Virose

- **Principales plantes touchées** : tulipe, concombre, tomate, pomme de terre..
- **Description** : les feuilles jaunissent et s'assèchent. Les fruits ne mûrissent pas ou l'arbre ne produit pas de fruit. Dans certains cas la plante n'arrive pas à fleurir.
- **Cause** : infection par une famille de virus véhiculé par les pucerons et ravageurs suceurs et piqueurs. Ces maladies apparaissent dans des endroits peu entretenus ou exposé à de nombreux insectes.
- **Solution** : arracher les plants atteints quand la maladie est là. En prévention, amener de la biodiversité dans vos jardins en acceptant coccinelles, chrysopes. Vous pouvez aussi traiter vos plants exposés à de

nombreux insectes à des purins d'ortie, d'absinthe de lavande ou de fougère [28].



Figure 49 : Virose [4].

III.4. Détection des maladies des plantes

La détection des maladies des plantes est un domaine crucial de l'agriculture et de la botanique, visant à identifier, diagnostiquer et traiter les maladies pour minimiser les pertes de récolte et garantir une production agricole saine.

Parmi les définitions que nous avons trouvées dans la littérature, celle donnée par [9] décrit succinctement ce qu'est un système de prédiction des maladies agricoles : " C'est un outil de gestion utilisé pour prédire l'apparition ou la détérioration des maladies des plantes cultivées ". Les producteurs utilisent ces systèmes pour prendre des décisions économiques sur les traitements de contrôle des maladies. Les systèmes posent généralement aux producteurs une série de questions sur la sensibilité de la culture hôte et font des recommandations en conjonction avec les conditions météorologiques actuelles et prévisibles. Généralement, les recommandations visent à déterminer le besoin pour le traitement de la maladie associée.

Selon cette définition, la tâche principale d'un système de diagnostic des maladies des plantes est de détecter de manière adéquate l'apparition de maladies à l'avance en passant par plusieurs étapes comme l'indique la figure ci-dessous, afin que les producteurs puissent prendre des décisions correctes sur l'application de produits phytosanitaires. Dans ce qui suit, nous verrons les bases, les conditions préalables et les processus des systèmes de diagnostic des maladies des plantes.

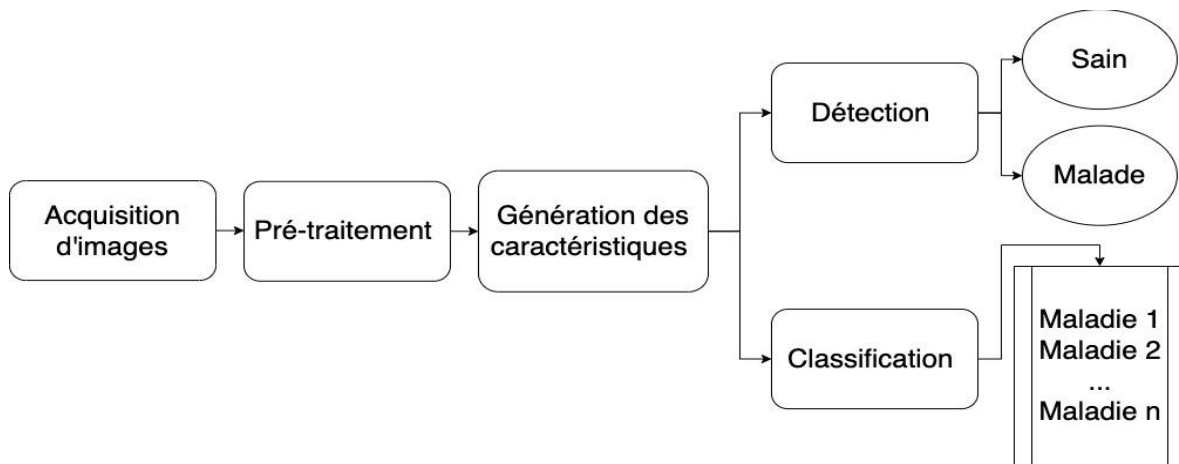


Figure 50 : Schéma d'un système de diagnostic des maladies des plantes.

III.5. Caractéristiques du système de diagnostic des maladies des plantes

Selon Lucas et al.,[42] un système de prédiction est dit efficace s'il présente les caractéristiques essentielles suivantes :

- **Fiabilité** : Utiliser des données environnementales fiables, c'est à dire collecter des facteurs climatiques tels que la température ou l'humidité de façon précise.
- **Simplicité** : Le système doit fournir une interface conviviale pour une utilisation facile exploité à grande échelle par les agriculteurs. Importance : La maladie traitée doit avoir une importance économique sur la culture et être assez sporadique c.-à-d. la possibilité d'un traitement momentané n'est pas applicable.
- **Utilité** : Le système de diagnostic doit être utile c'est à dire, il permet de décharger les producteurs de plusieurs activités de surveillance de la culture en offrant les recommandations nécessaires à l'application des produits chimiques et au contrôle des maladies au moment convenable.
- **Disponibilité** : Les données de l'élément d'interaction doivent être disponibles en temps réel (types de plantes, variétés de plantes, données climatiques, etc.)
- **Rentable** : Le système de diagnostic doit être abordable en termes de coût techniques et de gestion des maladies disponibles.

III.6. Etude de cas

Dans cette étude, nous nous concentrerons sur une plante en particulier qui est la salade. La salade est un terme générique désignant en jardinage et horticulture diverses sortes de feuilles, c'est-à-dire de plantes potagères dont les feuilles, consommées crues, entrent dans la composition d'un mets froid dont elles ont pris le nom, la « salade » [27] .

Voici les principales maladies qui touchent les salades :

- Le mildiou de la salade.
- La pourriture grise ou botrytis.
- L'antracnose.
- Le sclérotiniose des salades.
- Le rhizoctone brun de la salade [30].



Figure 51 : maladies et ravageurs des salades [7].

III.7. Conclusion

En conclusion, nous avons présenté un aperçu des plantes, de leurs divers usages, et de l'importance des maladies des plantes pour la sécurité alimentaire mondiale. Nous avons donné des exemples de maladies des plantes notables et de leur impact sur les cultures. De plus, nous avons examiné la détection et la gestion des maladies des plantes. Enfin, nous avons présenté une étude de cas sur les maladies de la salade.

Chapitre IV

IV.1. Introduction

Après avoir présenté les concepts généraux du traitement d'images et de la vision par ordinateur, en particulier la classification d'images et les techniques d'apprentissage profond, ce chapitre est consacré à la présentation des outils et des bibliothèques utilisés dans nos expériences, ainsi qu'à une modeste discussion sur les résultats obtenus.

IV.2. Les outils de développements

IV.2.1. Python

Python est un langage de programmation facile à apprendre et puissant. Il dispose de structures de données de haut niveau efficaces et d'une approche simple mais efficace de la programmation orientée objet. La syntaxe élégante de Python, son typage dynamique, ainsi que sa nature interprétée, en font un langage idéal pour le scripting et le développement rapide d'applications dans de nombreux domaines sur la plupart des plateformes .

IV.2.2. Anaconda

Est une plateforme de distribution Python avec plus de 20 millions d'utilisateurs mondiaux, basés sur un écosystème entièrement open source. Anaconda inclut Jupyter, qui est essentiellement un IDE et un serveur pour exécuter votre ordinateur portable. Jupyter prend actuellement en charge plus de 40 langages informatiques. Ces fameux cahiers sont très prisés par la communauté des data scientists, Contient du code et des éléments de présentation tels que des images où Des mots, réunis en un seul endroit. Google Colab.

Chapitre IV : Implémentation et réalisation.

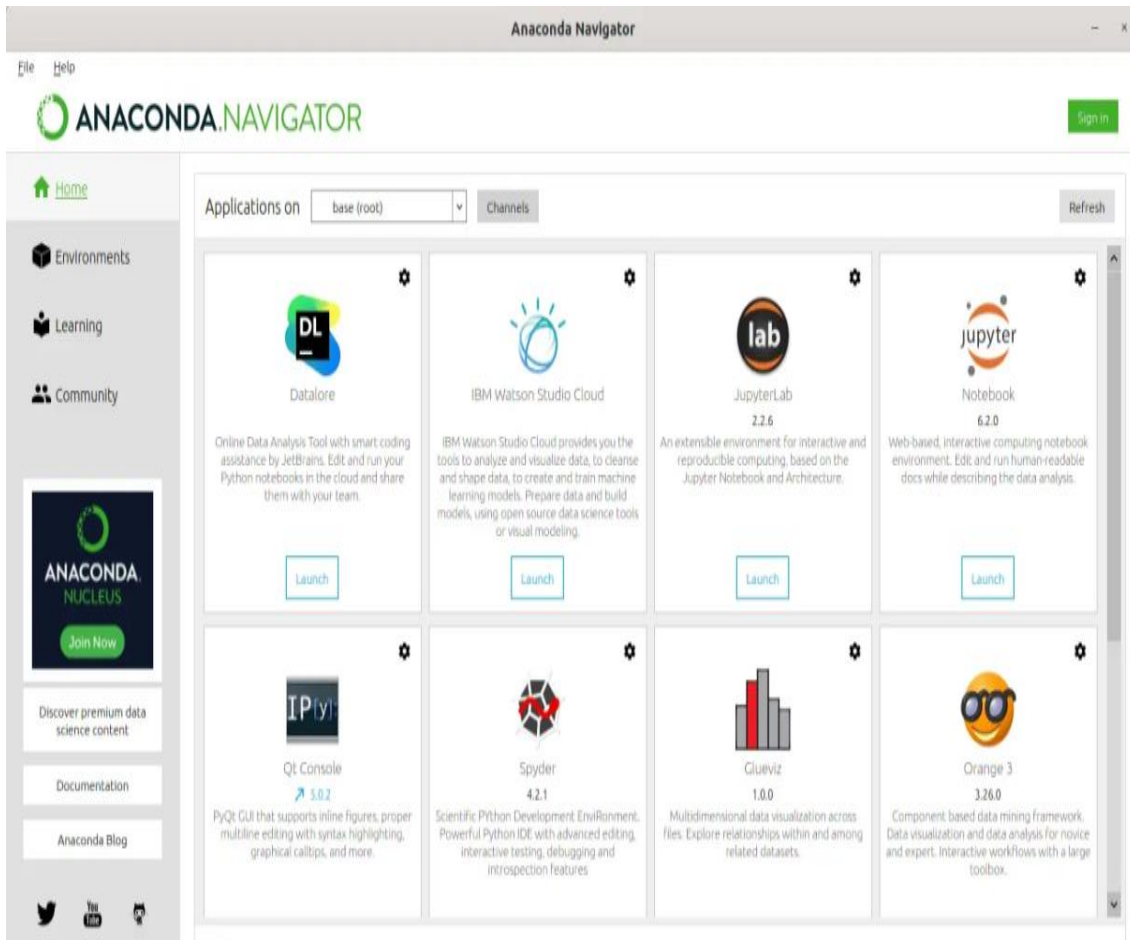


Figure 52: ANACONDA NAVIGATEUR.

IV.2.3. Google Colaboratory

Colaboratory, ou "Colab" pour faire court, est un produit de Google Research. Colab permet à quiconque d'écrire et d'exécuter du code Python arbitraire via le navigateur, et est particulièrement bien adapté à l'apprentissage automatique, à l'analyse de données et à l'éducation. Plus techniquement, Colab est un service de notebook Jupyter hébergé qui ne nécessite aucune configuration pour être utilisé, tout en offrant un accès gratuit à des ressources de calcul, y compris des GPUs.

Chapitre IV : Implémentation et réalisation.

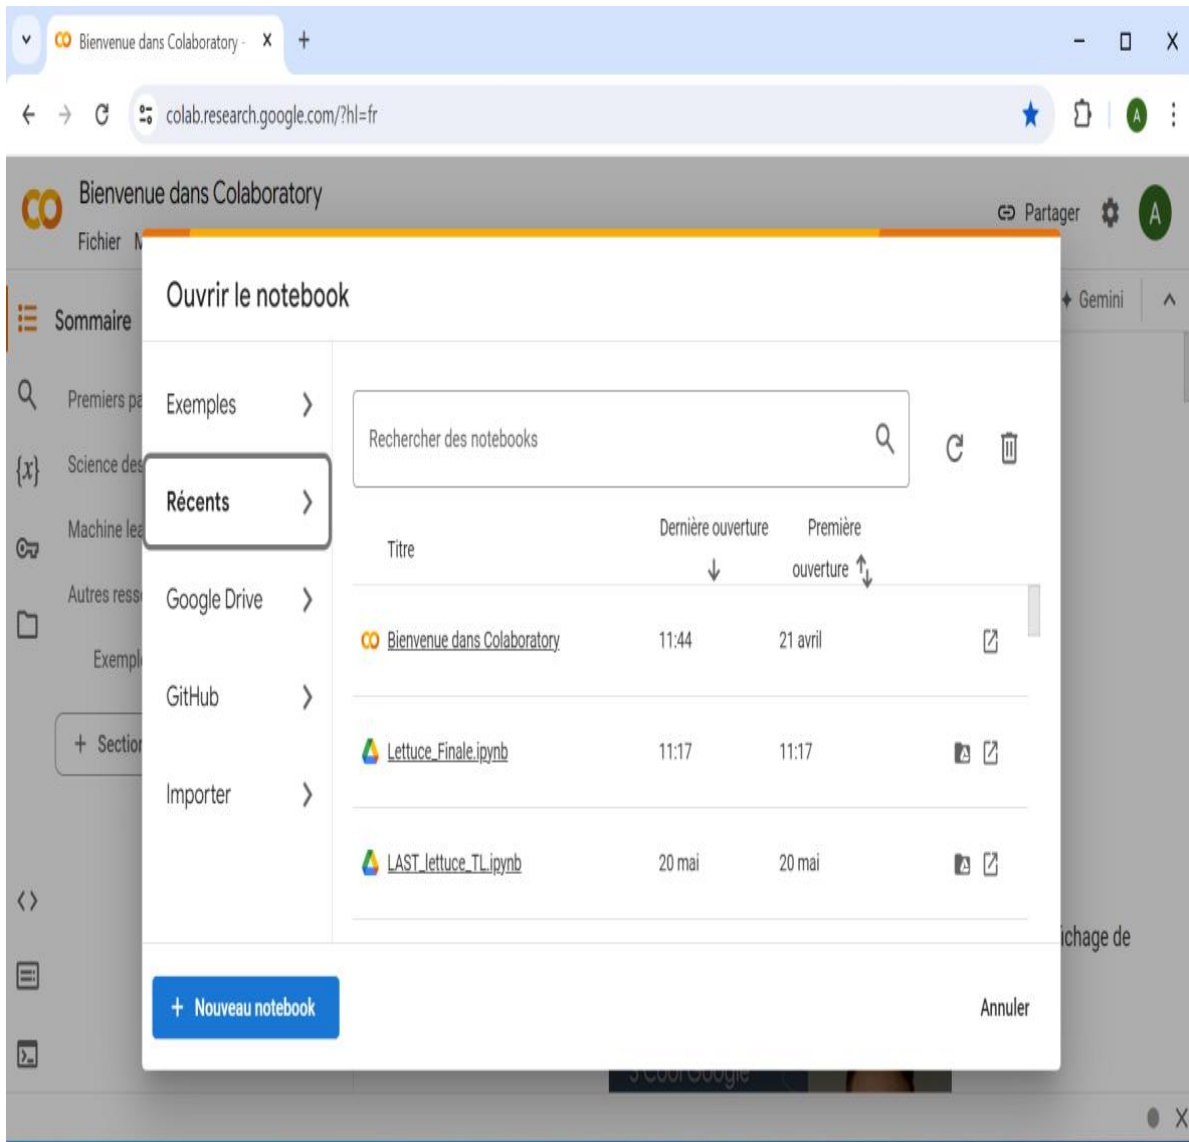


Figure 53: GOOGLE Collaboratory.

IV.3. Bibliothèques utilisées

IV.3.1. TensorFlow

TensorFlow est une plateforme open source de bout en bout pour l'apprentissage automatique. Elle possède un écosystème complet et flexible d'outils, de bibliothèques et de ressources communautaires permettant aux chercheurs de faire progresser l'état de l'art en apprentissage automatique et aux développeurs de créer et de déployer facilement des applications alimentées par l'apprentissage automatique .

IV.3.2. Keras

Keras est une API de deeplearning écrite en Python, fonctionnant au-dessus de la plateforme d'apprentissage automatique TensorFlow. Elle a été développée avec un accent sur l'expérimentation rapide. La capacité de passer de l'idée au résultat le plus rapidement possible est essentielle pour mener à bien des recherches de qualité.

IV.3.3. OpenCV

OpenCV (Open Source Computer Vision Library) est une bibliothèque logicielle open source dédiée à la vision par ordinateur et à l'apprentissage automatique. OpenCV a été créée pour fournir une infrastructure commune aux applications de vision par ordinateur et pour accélérer l'utilisation de la perception machine dans les produits commerciaux. Étant sous licence BSD, OpenCV permet aux entreprises d'utiliser et de modifier facilement le code.

La bibliothèque contient plus de 2500 algorithmes optimisés, comprenant un ensemble complet d'algorithmes de vision par ordinateur et d'apprentissage automatique, allant des classiques aux plus avancés. Ces algorithmes peuvent être utilisés pour détecter et reconnaître des visages, identifier des objets, classifier des actions humaines dans des vidéos, suivre les mouvements de caméra, suivre des objets en mouvement, extraire des modèles 3D d'objets, produire des nuages de points 3D à partir de caméras stéréo, assembler des images pour produire une image haute résolution d'une scène entière, trouver des images similaires dans une base de données d'images, supprimer les yeux rouges des photos prises avec un flash, suivre les mouvements des yeux, reconnaître des paysages et établir des marqueurs pour les superposer avec la réalité augmentée, etc. OpenCV compte plus de 47 000 utilisateurs dans sa communauté et un nombre estimé de téléchargements dépassant les 18 millions. La bibliothèque est largement utilisée par des entreprises, des groupes de recherche et des organismes gouvernementaux.

Chapitre IV : Implémentation et réalisation.

IV.3.4. Numpy

La bibliothèque Numpy (Numerical Python) est une bibliothèque populaire en Python qui fournit des structures de données et des fonctions pour manipuler efficacement des tableaux multidimensionnels. Il est largement utilisé dans les domaines scientifiques et numériques tels que le calcul mathématique, le fonctionnement des tableaux, l'algèbre linéaire, le traitement du signal et la simulation.

IV.3.4. Pandas

Pandas est une bibliothèque open source de manipulation et d'analyse de données pour le langage de programmation Python. Elle offre des structures de données flexibles et expressives, principalement les DataFrames et les Series, qui facilitent la manipulation de données tabulaires et de séries temporelles. Pandas est particulièrement utile pour nettoyer, transformer et analyser des données, grâce à ses fonctionnalités puissantes pour la sélection, le filtrage, l'agrégation et la visualisation des données.

IV.4. Lettuce plant diseasedataset

Le jeu de données sur les maladies des plants de laitue disponible sur Kaggle contient 2813 images réparties en trois catégories : "Bactérienne", "Fongique" et "Saine". Les images sont organisées dans trois dossiers distincts : "train" (entraînement), "valid" (validation) et "test". Chaque catégorie de maladie a des images associées qui montrent des symptômes spécifiques, tandis que les images de laitue saine montrent des plantes sans signes de maladie. Ce jeu de données est utile pour l'entraînement et l'évaluation de modèles de reconnaissance des maladies des plants de laitue.

Chapitre IV : Implémentation et réalisation.

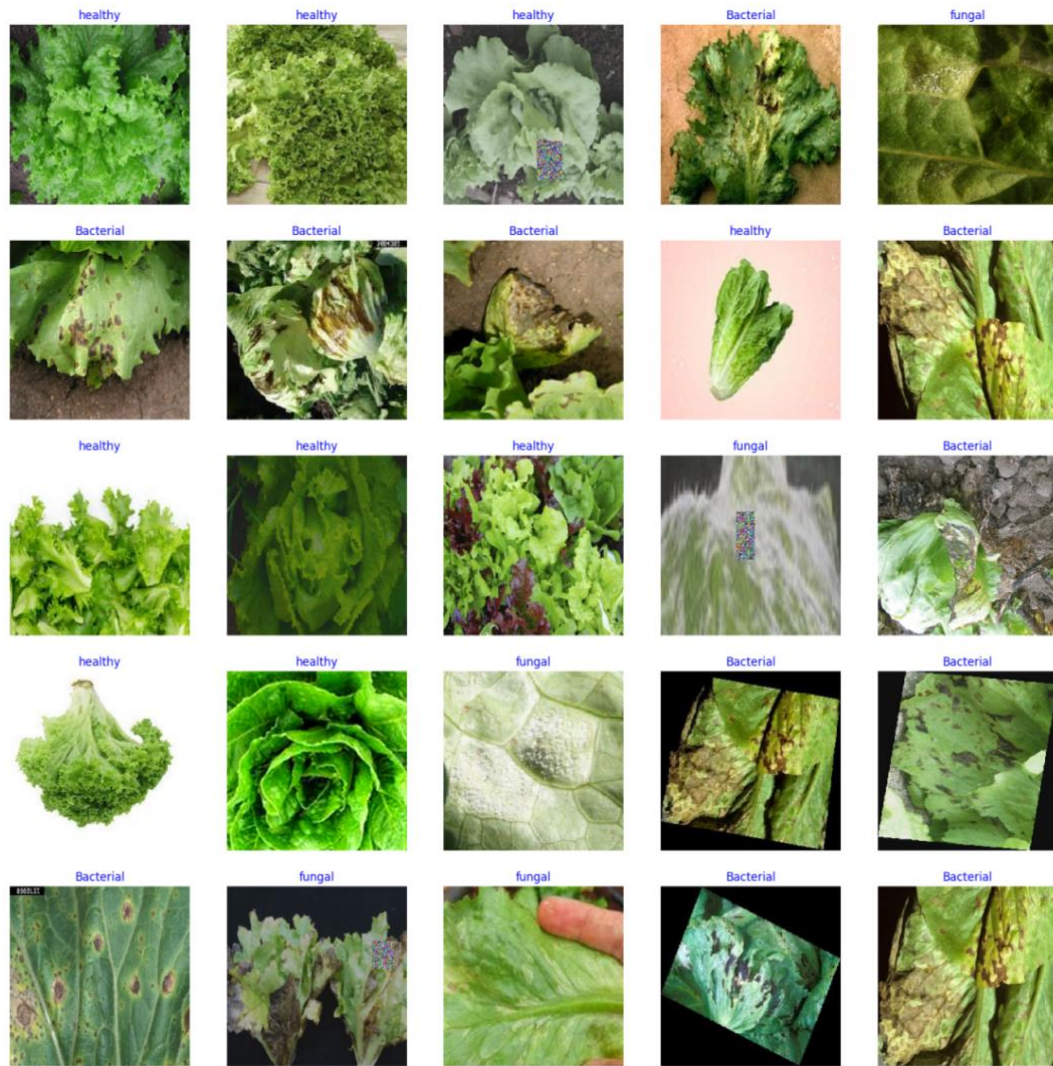


Figure 54: Lettuce plant disease data set.

IV.4.1. Data augmentation (Image Data Generator)

La data augmentation est une technique couramment utilisée en apprentissage automatique, particulièrement dans les tâches de vision par ordinateur telles que la classification d'images, la détection d'objets et la segmentation. Elle consiste à générer de nouveaux échantillons d'entraînement en appliquant diverses transformations aux données existantes, telles que la rotation, le redimensionnement, le retournement, le recadrage et la modification de la luminosité ou du contraste. Cela permet d'augmenter la diversité de l'ensemble d'entraînement et peut améliorer la généralisation et la robustesse du modèle entraîné.

La classe Image Data Generator est un outil puissant fourni par des bibliothèques telles que TensorFlow et Keras pour effectuer la data

Chapitre IV : Implémentation et réalisation.

augmentation. Elle vous permet de créer un générateur qui génère automatiquement des lots de données d'images augmentées à la volée pendant l'entraînement.

```
▶ train_dir = '/content/lettuce-plant-disease-dataset/lettuce/train'
  test_dir = '/content/lettuce-plant-disease-dataset/lettuce/test'

try:
    # Get splitted data
    train_df, valid_df, test_df = split_data(train_dir, test_dir)

    # Get Generators
    batch_size = 40
    train_gen, valid_gen, test_gen = create_gens(train_df, valid_df, test_df, batch_size)

except:
    print('Invalid Input')
```

Figure 55: data augmentation.

IV.4.2. Data Distribution




Figure 56: Data distribution.

Chapitre IV : Implémentation et réalisation.

- **Les classes**

0: Bacterial: Les bactéries pathogènes peuvent contaminer les salades à différents stades, depuis la production jusqu'à la consommation

1: Fungal: Les maladies fongiques dans les salades sont généralement moins courantes que les maladies bactériennes, mais elles peuvent toujours poser un risque pour la santé, en particulier si les salades sont mal gérées ou si les ingrédients sont contaminés.

2: Healthy: Une salade santé peut être composée d'une variété d'ingrédients frais, colorés et nutritifs.

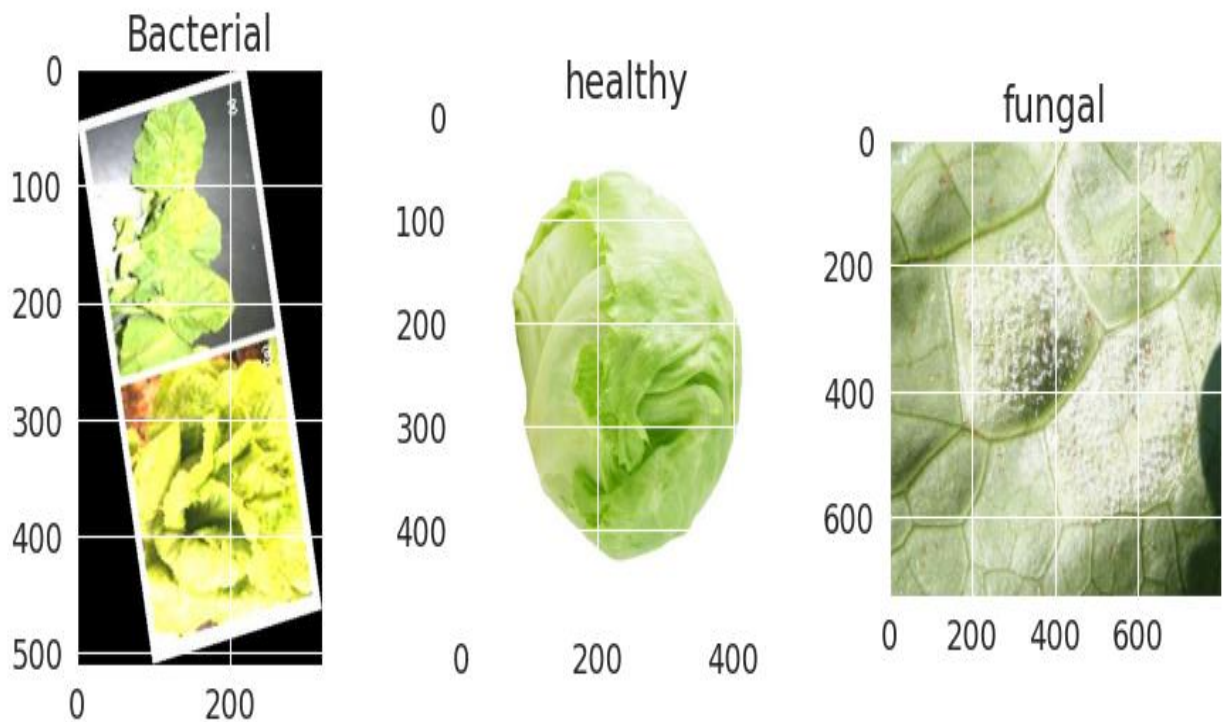


Figure 57: Les classes.

Chapitre IV : Implémentation et réalisation.

IV.4.2.1. Image preprocessing (Image enhancement)

Utilisées pour améliorer la qualité ou les caractéristiques d'une image avant qu'elle ne soit alimentée dans un modèle d'apprentissage automatique pour l'entraînement ou l'inférence. Ces techniques visent à améliorer les caractéristiques de l'image, à supprimer le bruit, à améliorer le contraste ou à ajuster les couleurs pour rendre l'image plus adaptée à l'analyse par le modèle.

IV.4.2.2. Image Enhancement

Elle applique des améliorations à l'image dupliquée en utilisant trois méthodes d'amélioration d'images PIL : Couleur, Contraste et Netteté. Ces améliorations visent à améliorer respectivement la couleur, le contraste et la netteté de l'image.

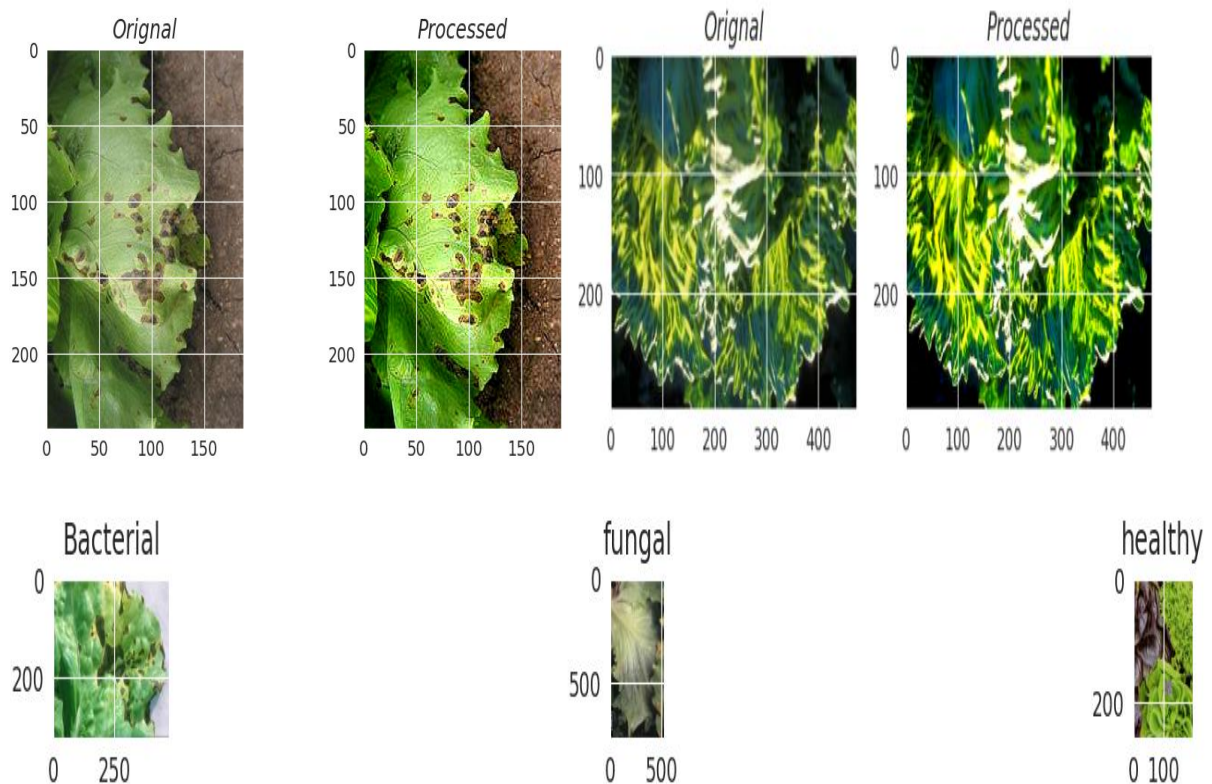


Figure 58:Image enchancement.

Chapitre IV : Implémentation et réalisation.

Représentation visuelle d'une image sélectionnée aléatoirement dans chaque catégorie du répertoire train_dir, permettant une comparaison facile des images de différentes catégories.

- Notre Model(CNN)

- Couches convolutives (Conv2D) : ces couches extraient les caractéristiques de l'image d'entrée. Ils utilisent une fenêtre coulissante (le filtre) pour détecter des motifs comme les bords
- Couches de regroupement (MaxPooling2D) : ces couches souséchantillonnent les cartes de caractéristiques, réduisant ainsi le nombre de paramètres et rendant le réseau plus robuste aux petits changements d'entrée.
- Aplatir la couche : transforme la sortie multidimensionnelle des couches convolutives en
- Couches denses : effectuez des opérations entièrement connectées, en combinant les caractéristiques de toutes les couches précédentes pour effectuer la classification finale.

Layer (type)	Output Shape	Param #
conv2d_8 (Conv2D)	(None, 220, 220, 64)	4864
max_pooling2d_8 (MaxPooling2D)	(None, 110, 110, 64)	0
conv2d_9 (Conv2D)	(None, 106, 106, 32)	51232
max_pooling2d_9 (MaxPooling2D)	(None, 53, 53, 32)	0
flatten_4 (Flatten)	(None, 89888)	0
dense_12 (Dense)	(None, 1024)	92046336
dense_13 (Dense)	(None, 128)	131200
dense_14 (Dense)	(None, 3)	387

Figure 59:Architecture de notre modèle.

Chapitre IV : Implémentation et réalisation.

- **Résultat du « Train et Validation » obtenus**

L'image montre la perte et la précision de la formation et de la validation d'un réseau neuronal. Le réseau a été formé pendant 5 époques. La perte d'entraînement a diminué de manière significative au cours des deux premières époques, après quoi elle est restée relativement constante. La perte de validation a également diminué au cours des deux premières époques, mais a ensuite commencé à augmenter légèrement. La précision de l'entraînement a augmenté de manière significative au cours des deux premières époques, après quoi elle est restée relativement constante. La précision de la validation a augmenté de manière significative au cours des deux premières époques, puis a commencé à diminuer légèrement. Dans l'ensemble, le réseau semble avoir été suradapté aux données d'entraînement après les deux premières époques. La meilleure époque pour le réseau est l'époque 2, car la perte de validation et la précision sont les plus élevées à cette époque.

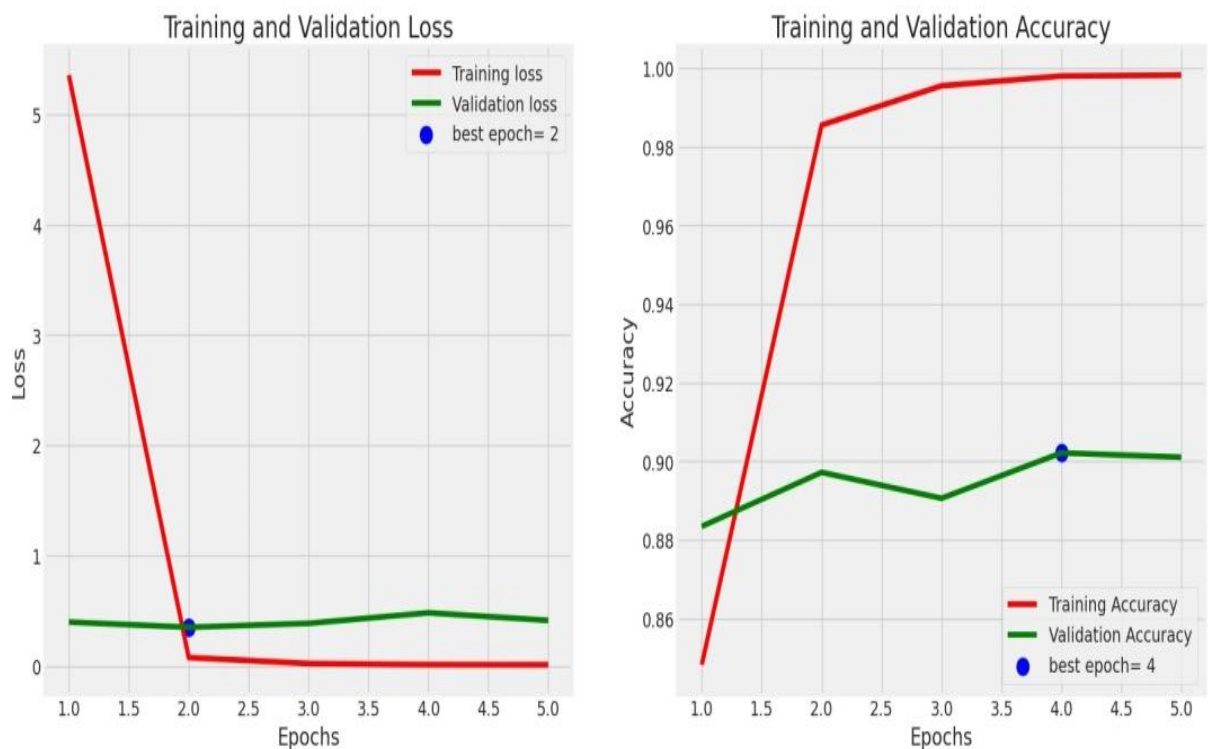


Figure 60: Résultat train et validation.

Chapitre IV : Implémentation et réalisation.

- **Résultat Obtenus après l'évaluation du notre model**

Le modèle a une précision de formation élevée (0,9952) et une précision de validation (0,8964). Cependant, la précision du test est bien inférieure (0,6725), ce qui indique un problème de surapprentissage important.

```
48/113 [=====>.....] - ETA: 26s - loss: 0.0255 - accuracy: 0.9952WARNING:tensorflow:Your in
113/113 [=====] - 19s 168ms/step - loss: 0.0255 - accuracy: 0.9952
12/113 [==>.....] - ETA: 38s - loss: 0.3567 - accuracy: 0.8964WARNING:tensorflow:Your in
113/113 [=====] - 5s 38ms/step - loss: 0.3567 - accuracy: 0.8964
113/113 [=====] - 1s 11ms/step - loss: 4.1830 - accuracy: 0.6726
Best Model Results
Train Loss: 0.025455292314291
Train Accuracy: 0.9952355623245239
-----
Validation Loss: 0.35674744844436646
Validation Accuracy: 0.8964059352874756
-----
Test Loss: 4.183006286621094
Test Accuracy: 0.6725663542747498
```

Figure 61:Résultat Obtenus après l'évaluation du notre model.

- Prédiction d'une image aléatoire :




Figure 62: Predicted class: Bacterial.

Le texte indique que cette image a été sélectionnée au hasard et que le modèle a correctement prédit qu'il s'agissait d'un échantillon bactérien.

- **La matrice de confusion**

Une matrice de confusion est une table utilisée en apprentissage automatique pour décrire la performance d'un modèle de classification. Elle présente un résumé des prédictions par rapport aux étiquettes réelles pour un problème de classification.

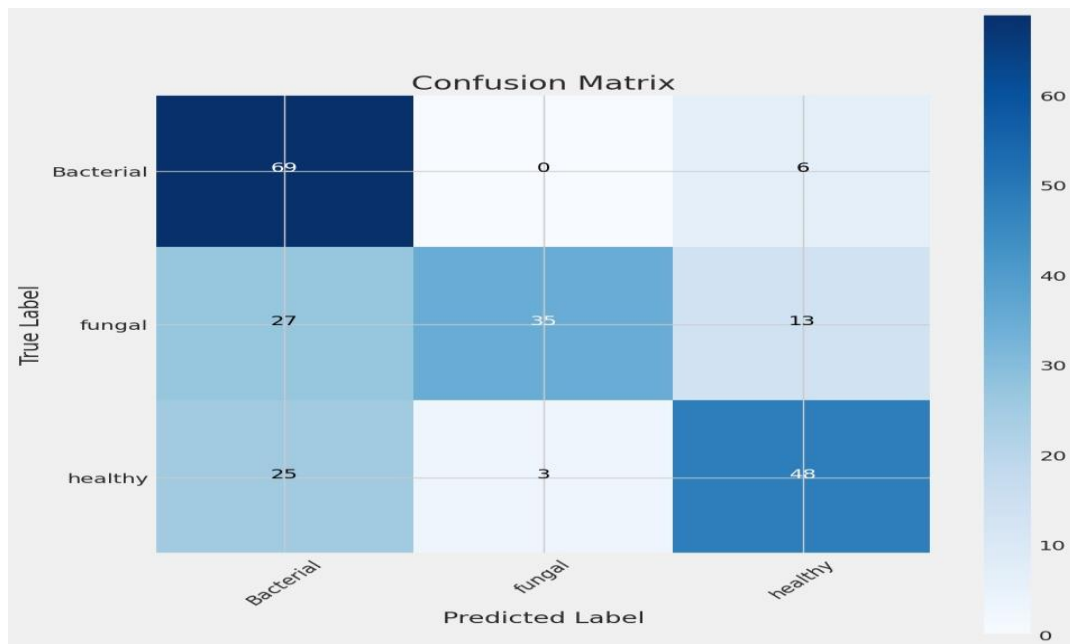


Figure 63: Matrice de confusion pour CNN.

IV.5. Transfer Learning

Le transfert d'apprentissage (transfer learning) est une technique de machine learning où un modèle préalablement entraîné sur une tâche est réutilisé comme point de départ pour une autre tâche similaire. Cette méthode est particulièrement utile lorsque les données disponibles pour la nouvelle tâche sont limitées. En transférant les connaissances d'un modèle bien entraîné, on peut améliorer les performances et accélérer le processus d'entraînement pour la nouvelle tâche. Le transfert d'apprentissage est couramment utilisé dans la vision par ordinateur et le traitement du langage naturel.

IV.5.1. Avantages du transfert d'apprentissage

1. Réduction du temps d'entraînement : Le modèle démarre avec des poids préalablement appris, réduisant le temps nécessaire pour converger.
2. Meilleure performance : Les modèles bénéficient des connaissances acquises sur des ensembles de données plus vastes et variés.
3. Moins de données nécessaires : Permettent d'obtenir de bons résultats même avec des ensembles de données limités pour la nouvelle tâche.

IV.5.2. Exemple d'application

Un modèle pré-entraîné sur ImageNet, un grand ensemble de données d'images, peut être ajusté pour reconnaître des maladies sur des plants de laitue en ajoutant quelques couches spécifiques à cette tâche et en ré-entraîner le modèle sur un plus petit ensemble de données contenant des images de laitue.

Pour notre étude on a VGG16 et InceptionV3 :

VGG16 et InceptionV3 sont deux architectures de réseaux de neurones convolutionnels (CNN) largement utilisées pour des tâches de vision par ordinateur, comme la classification d'images et la détection d'objets.

- **VGG16**

- **Architecture** : Proposée par l'Université d'Oxford, VGG16 est connue pour sa simplicité avec 16 couches de convolution suivies de couches de pooling et entièrement connectées.

- **Caractéristiques**

- Utilise des filtres 3x3 dans les couches de convolution.
- A des couches entièrement connectées à la fin pour la classification.
- Modèle profond mais simple à comprendre et à implémenter.

- **Le résultat du « Train and Validation » de VGG16**

Les graphiques montrent la perte et la précision de la formation et de la validation pour un modèle sur 10 époques. Le modèle semble converger à mesure que la perte diminue et que la précision augmente. La meilleure époque est l'époque 9, où la précision de validation est la plus élevée.

Chapitre IV : Implémentation et réalisation.




Figure 64:Le résultat du « Train and Validation » de VGG16.

- VGG16 évaluation

48/113 [=====>.....] - ETA: 27s - loss: 0.0328 - accuracy: 0.9915

113/113 [=====] - 20s 176ms/step - loss: 0.0328 - accuracy: 0.9915

12/113 [==>.....] - ETA: 40s - loss: 0.1428 - accuracy: 0.9556

113/113 [=====] - 5s 40ms/step - loss: 0.1428 - accuracy: 0.9556

113/113 [=====] - 3s 16ms/step - loss: 1.7562 - accuracy: 0.7566.

- VGG16 Model Results

Train Loss: 0.032806236296892166

Train Accuracy: 0.9915298819541931

Validation Loss: 0.1428484469652176

Validation Accuracy: 0.9556025266647339

Test Loss: 1.7561537027359009

Test Accuracy: 0.756637156009674

Chapitre IV : Implémentation et réalisation.

- InceptionV3

- Architecture : Développée par Google, InceptionV3 fait partie de la famille des réseaux Inception (aussi connue sous le nom de GoogLeNet).

- Caractéristiques :

- Utilise des modules Inception qui permettent de capturer des informations à différentes échelles de manière efficace.

- Combine des convolutions de différentes tailles (1x1, 3x3, 5x5) dans un même module.

- Plus complexe que VGG16, mais généralement plus efficace en termes de précision et de performance.

-Résultat du « Train et Validation » InceptionV3

La perte de validation diminue au cours de la première époque puis reste assez stable pour le reste des époques. La précision de la formation augmente au cours des 4 époques, tandis que la précision de la validation diminue au cours des 2 premières époques, puis augmente régulièrement pour les époques restantes.



Figure 65: Résultat du « Train et Validation » InceptionV3.

Chapitre IV : Implémentation et réalisation.

- Applications

Les deux modèles sont couramment utilisés pour :

- Transfert d'apprentissage : En réutilisant des poids pré-entraînés sur de grands ensembles de données comme Image Net.
- Détection d'objets : En ajoutant des couches spécifiques pour des tâches de détection.
- Segmentation d'images : En adaptant les modèles pour des tâches de segmentation.

• Accuracy Comparaison




Figure 66: Accuracy Comparaison.

Dans notre étude comparative, nous avons évalué les performances de trois modèles de réseaux de neurones convolutionnels (CNN) sur un jeu de données de maladies des plants de laitue : notre modèle CNN personnalisé, InceptionV3 pré-entraîné et VGG16 pré-entraîné.

- Résultats des modèles

- Notre modèle CNN : Précision de 0.85.
- InceptionV3 :Précision de 0.66.
- VGG16 : Précision de 0.96.

- Analyse des résultats

1. Performance de VGG16 :

- Précision élevée : Avec une précision de 0.96, VGG16 surpasse significativement les autres modèles. Cela montre la puissance de ce modèle pré-entraîné pour la tâche spécifique de détection des maladies des plants de laitue.

- Explication : VGG16, grâce à sa profondeur et à ses filtres bien optimisés, capte efficacement les caractéristiques discriminatives des images de maladies de laitue.

2. Performance d'InceptionV3

- Précision plus faible : InceptionV3 a une précision de 0.66, ce qui est inférieur à celle de notre modèle CNN et de VGG16.

- **Explication** : La complexité des modules Inception pourrait nécessiter plus de données d'entraînement ou une meilleure adaptation des hyperparamètres pour cette tâche spécifique.

3. Performance de notre modèle CNN :

- Précision modérée : Avec une précision de 0.85, notre modèle CNN personnalisé se situe entre InceptionV3 et VGG16.

- Explication : Bien que performant, notre modèle pourrait bénéficier d'un entraînement sur des ensembles de données plus vastes ou de l'incorporation de techniques d'optimisation avancées.

IV.6.Conclusion

L'étude montre que les modèles pré-entraînés comme VGG16 peuvent offrir des avantages significatifs en termes de précision pour la détection des maladies des plantes de laitue par rapport aux modèles CNN personnalisés. Toutefois, l'adaptation et l'optimisation des modèles pré-entraînés sont cruciales pour maximiser leurs performances sur des tâches spécifiques

Conclusion général

Conclusion général.

La classification des images agricoles par apprentissage profond représente une avancée significative dans l'agriculture de précision et la gestion des cultures. À travers ce mémoire, nous avons exploré les nombreux défis et opportunités associés à l'application de ces technologies dans le secteur agricole, avec un focus particulier sur la détection des maladies des plantes.

Les résultats obtenus démontrent que les réseaux neuronaux profonds, grâce à leur capacité à apprendre des caractéristiques complexes et abstraites à partir d'images, sont particulièrement adaptés pour la classification des cultures et la détection des maladies. La précision, la rapidité et la robustesse de ces modèles permettent non seulement d'améliorer la gestion des cultures mais aussi de prendre des décisions éclairées en matière de traitement des ravageurs, d'optimisation des rendements et de gestion durable des ressources.

L'intégration de l'intelligence artificielle dans les systèmes de surveillance agricoles ouvre de nouvelles perspectives pour les producteurs, notamment en rendant ces technologies plus accessibles, abordables et faciles à utiliser. Dans le cadre de cette recherche, nous avons développé un système capable de classifier les maladies des plantes en trois catégories : bactériennes, fongiques ou saines. Ce système, en se basant sur des techniques d'apprentissage profond, a démontré une capacité à collecter, traiter et classifier efficacement les données, offrant ainsi une solution prometteuse pour la surveillance et la gestion des maladies dans les cultures de salade.

En conclusion, l'adoption des technologies d'apprentissage profond dans l'agriculture promet de transformer ce secteur en offrant des outils puissants pour améliorer la durabilité, l'efficacité et la rentabilité. Les avancées réalisées dans cette thèse montrent que, bien que des défis subsistent, les opportunités offertes par ces technologies sont immenses et continueront de croître avec les progrès continus dans le domaine de l'intelligence artificielle. La mise en œuvre et l'optimisation de ces systèmes représentent un pas en avant vers une agriculture plus intelligente et durable.

Les Références Bibliographiques

- [1]. A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [2]. A. Rad, R. Safabakhsh, N. Qaragozlou, and M. Zaheri, “Fast iris and pupil localization and eyelid removal using gradient vector pairs and certainty factors,” in *The Irish Machine Vision and Image Processing Conf*, 2004, pp. 82–91.
- [3]. A. Waibel, T. Hanazawa, G. Hinton, K. Shikano, and K. J. Lang, “Phoneme recognition using time-delay neural networks,” *IEEE Trans. Acoust., Speech, Signal Processing*, vol. 37, no. 3, pp. 328–339, Mar. 1989, doi: 10.1109/29.21701.
- [4]. Abdelrahman Osman. *Machine Learning (in Arabic)*. 4 2018.
- [5]. Abhishek Wasnik. *K-nearest neighbors from scratch with python*, 12 2020.
- [6]. Anna Korhonen, David Traum, and Lluís Màrquez. *Proceedings of the 57th annual meeting of the association for computational linguistics*.
- [7]. Antoine Crochet-Damais. *Apprentissage supervisé : définition et exemples d’algorithme*, 2 2022.
- [8]. B. A. Olshausen and D. J. Field, “Emergence of simple-cell receptive field properties by learning a sparse code for natural images,” *Nature*, vol. 381, no. 6583, pp. 607–609, Jun. 1996, doi: 10.1038/381607a0.
- [9]. C. Hilario, J. M. Collado, J. M. Armingol, and A. de la Escalera, “Pedestrian Detection for Intelligent Vehicles Based on Active Contour Models and Stereo Vision,” in *Computer Aided Systems Theory – EUROCAST 2005*, Berlin, Heidelberg, 2005, pp. 537–542, doi: 10.1007/11556985_70.
- [10]. C. Szegedy et al., “Going deeper with convolutions,” in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, Jun. 2015, pp. 1–9, doi: 10.1109/CVPR.2015.7298594.
- [11]. Chloé-Agathe Azencott. *Introduction au machine learning*. 2023.
- [12]. D. Amodei et al., “Deep Speech 2: End-to-End Speech Recognition in English and Mandarin,” *arXiv:1512.02595 [cs]*, Dec. 2015, Accessed: Sep. 17, 2020. [Online]. Available: <http://arxiv.org/abs/1512.02595> .
- [13]. D. E. Dudgeon and R. M. Mersereau, *Multidimensional digital signal processing*. Englewood Cliffs, NJ: Prentice-Hall, 1984.
- [14]. Damon MN 2 Aminot I 1. *Régression logistique : intérêt dans l’analyse de données*

relatives aux pratiques médicales. 2002.

[15].David J. Hand. Measuring classifier performance: A coherent alternative to the area under the roc curve. *Machine Learning*, 77, 2009.

[16].Deep Learning Techniques for Biomedical and Health Informatics, 2020.

[17].Denny's Blog. Understanding convolutional neural networks for nlp, 11 2015.

[18].DJEMAA_MAHIR_F1_1688406111.pdf

[19].Eve Mathieu-dupas. Algorithme des k plus proches voisins pondérés (wknn) et application en diagnostic. 42èmes Journées de Statistique, 2010.

[20].F.Suard, A. Rakotomamonjy, A. Bensrhair, and A. Broggi, "Pedestrian Detection using Infrared images and Histograms of Oriented Gradients," in 2006 IEEE Intelligent Vehicles Symposium, Jun. 2006, pp. 206–212, doi: 10.1109/IVS.2006.1689629.

[21].G. Guo and M. J. Jones, "Iris Extraction Based on Intensity Gradient and Texture Difference," in 2008 IEEE Workshop on Applications of Computer Vision, Jan. 2008, pp. 1–6, doi: 10.1109/WACV.2008.4544018.

[22].H. Shao, T. Svoboda, and L. Gool, "ZuBuD Zurich Buildings Database for Image Based Recognition," 2003. <https://www.semanticscholar.org/paper/ZuBuD-Zurich-Buildings-Database-for-Image-Based-ShaoSvoboda/24356cca82b4040b616e895ecfb0b5c6386f5e84> (accessed Sep. 17, 2020).

[23].Hausmane Issarane. 5 algorithmes d'apprentissage supervisé, 2 2019.

[24].Hervé Frezza-Buet. Machines à vecteurs supports : Didacticiel. Supélec (Support de cours), 2013.

[25].<http://www.agriculture-biodiversite-oi.org/Nature-agriculture/Nouvelles-du-terrain/Dossiers-thematiques/Fiches-plantes-maladies-insectes/Les-maladies-des-plantes>

[26]. <https://agronomie.asso.fr/lagronomie/definitions>[Accès le 30 mai 2024].

[27]. [https://fr.wikipedia.org/wiki/Salade_\(plante\)](https://fr.wikipedia.org/wiki/Salade_(plante))

[28].<https://greenastic.com/fiche/principales-maladies-plantes/>

[29].<https://hub.packtpub.com/top-5-deep-learning-architectures>

[30].<https://www.promessedefleurs.com/conseil-plantes-jardin/ficheconseil/maladies-et-ravageurs-des-salades/>

[31].<https://www.tela-botanica.org/ressources/ressources-pedagogiques/un-aperçu-de-botanique/>

- [32].Introduction à l'Intelligence Artificielle GI 2020: M. Benbrahim.
- [33].K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian, "Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering," *IEEE Trans. on Image Process.*, vol. 16, no. 8, pp. 2080–2095, Aug. 2007, doi: 10.1109/TIP.2007.901238.
- [34].K. H. G., .Mohd. M. M., . A. H., and . S. R., "Scale Invariant Feature Transform Technique for Weed Classification in Oil Palm Plantation," *J. of Applied Sciences*, vol. 8, no. 7, pp. 1179–1187, Jul. 2008, doi: 10.3923/jas.2008.1179.1187.
- [35].K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," arXiv:1512.03385 [cs], Dec. 2015, Accessed: Sep. 17, 2020. [Online]. Available: <http://arxiv.org/abs/1512.03385> .
- [36].K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural Networks*, vol. 4, no. 2, pp. 251–257, 1991, doi: 10.1016/0893-6080(91)90009-T.
- [37].Keysers Daniel, Dahmen Jörg, and Ney Hermann, *Invariant Classification of Red Blood Cells: A Comparison of Different Approaches. Bildverarbeitung für die Medizin*, 2001.
- [38].Kostadin Dabov, Alessandro Foi, Vladimir Katkovnik, and Karen Egiazarian, "Bm3d image denoising with shape-adaptive principal component analysis," *Inria*, Apr. 2009.
- [39].Kristina P. Sinaga and Miin Shen Yang. Unsupervised k-means clustering algorithm. *IEEE Access*, 8, 2020.
- [40].L. Lam, S.-W. Lee, and C. Y. Suen, "Thinning methodologies—a comprehensive survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 14, no. 9, pp. 869–885, Sep. 1992, doi: 10.1109/34.161346.
- [41]. La Classification d'images d'insectes ravageurs en utilisant le Deep Learning Réalisé par : LOUNIS Katia MOUSSI Dahbia Encadré par Promotrice: Mme AOUDJIT. R Co-promotrice: Mme AIT ISSAD. H 2019-2020
- [42].LUCAS, George B ; CAMPBELL, C Lee ; LUCAS, Leon T. *Introduction to plant diseases : identification and management*. Springer Science & Business Media, 1992.
- [43].M. Rodriguez-Damian, E. Cernadas, A. Formella and R. Sa-Otero, "Pollen classification using brightness-based and shape-based descriptors," *Proceedings of the 17th International Conference on Pattern Recognition*, 2004. ICPR 2004., Cambridge, 2004, pp. 212-215 Vol.2, doi: 10.1109/ICPR.2004.1334098. .
- [44].MOUHOUBI Azzeddine Mounir et GHEFFARI Mohamed Abdelfattah. *Analyse de sentiments dans la langue arabe en utilisant différentes d'approches*. 11 2020

- [45].Ø. Due Trier, A. K. Jain, and T. Taxt, “Feature extraction methods for character recognition-A survey,” *Pattern Recognition*, vol. 29, no. 4, pp. 641–662, Apr. 1996, doi: 10.1016/0031-3203(95)00118-2.
- [46].O. M. Parkhi, A. Vedaldi, and A. Zisserman, “Deep Face Recognition,” in *Proceedings of the British Machine Vision Conference 2015*, Swansea, 2015, p. 41.1-41.12, doi: 10.5244/C.29.41.
- [47].P Ramachandran, B Zoph, and Q V Le. Searching for activation functions.arxivprepr.arXiv preprint arXiv:1710.05941, 2017.
- [48].P. Bolon et al., *Analyse d’images : Filtrage et segmentation*. MASSON, 1995. [88] - N. Otsu, “A Threshold Selection Method from Gray-Level Histograms,” *IEEE Trans. Syst., Man, Cybern.*, vol. 9, no. 1, pp. 62–66,
- [49].P. Negri, X. Clady, S. M. Hanif, and L. Prevost, “A Cascade of Boosted Generative and Discriminative Classifiers for Vehicle Detection,” *EURASIP J. Adv. Signal Process.*, vol. 2008, no. 1, p. 782432, Dec. 2008, doi: 10.1155/2008/782432.
- [50].P. Viola and M. J. Jones, “Robust Real-Time Face Detection,” *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, May 2004, doi: 10.1023/B:VISI.0000013087.49260.fb.
- [51].P. Viola and M. Jones, “Rapid object detection using a boosted cascade of simple features,” in *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, Dec. 2001, vol. 1, p. I–I, doi: 10.1109/CVPR.2001.990517.
- [52].R. C. Gonzalez and R. E. Woods, *Digital image processing*, 2nd ed. Upper Saddle River, N.J: Prentice Hall, 2002.
- [53].R. Collobert and J. Weston, “A unified architecture for natural language processing: deep neural networks with multitask learning,” in *Proceedings of the 25th international conference on Machine learning - ICML '08*, Helsinki, Finland, 2008, pp. 160–167, doi: 10.1145/1390156.1390177.
- [54].R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*, 2nd ed. New York: Wiley, 2001.
- [55].RATHOD, ArtiN ; TANAWAL, Bhavesh ; SHAH, Vatsal. Image processing techniques for detection of leaf disease. *International Journal of Advanced Research in Computer Science and Software Engineering*. 2013, t. 3, no 11.
- [56].Ricco Rakotomalala. Arbres de décision. Modulad, 200

- [57]. Ruibo Wang and Jihong Li. Bayes test of precision, recall, and f1 measure for comparison of two natural language processing models. 2020.
- [58].SANKARAN, Sindhuja ; MISHRA, Ashish ; EHSANI, Reza ; DAVIS, Cristina. A review of advanced techniques for detecting plant diseases.Computers and electronics in agriculture. 2010, t. 72, no 1, p. 1-13.
- [59].Shenglei Chen, Geoffrey I. Webb, Linyuan Liu, and XinMa.Anovelselective naïve bayes algorithm.Knowledge-BasedSystems, 192, 2020.
- [60].SofieneAlouini and Sofia Calcagno.Les réseaux de neurones récurrents : des rnn simples aux lstm, 10 2
- [61]. Suard Frédéric., “Méthodes à noyaux pour la détection de piétons. ,” Phd, LITIS - INSA of Rouen, France, 2006.
- [62].T. Mäenpää, J. Viertola, and M. Pietikäinen, “OptimisingColour and Texture Features for Real-time Visual Inspection,” *Patt. Analy. App.*, vol. 6, no. 3, pp. 169–175, Dec. 2003, doi: 10.1007/s10044-002-0179-1.
- [63].T. Maenpaa, M. Pietikainen, and J. Viertola, “Separatingcolor and pattern information for color texture discrimination,” in *Object recognition supported by user interaction for service robots*, Quebec City, Que., Canada, 2002, vol. 1, pp. 668–671, doi: 10.1109/ICPR.2002.1044840.
- [64].W. James Murdoch, Chandan Singh, Karl Kumbier, Reza Abbasi-Asl, and Bin Yu.Definitions, methods, and applications in interpretable machine learning.Proceedings of the National Academy of Sciences of the United States of America, 116, 2019.
- [65].Y. B. Lauziere, D. Gingras, and F. P. Ferrie, “A model-based road sign identification system,” in *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, Kauai, HI, USA, 2001, vol. 1, p. I-1163–I-1170, doi: 10.1109/CVPR.2001.990662.
- [66].Y. LeCun et al., “BackpropagationApplied to Handwritten Zip Code Recognition,” *Neural Computation*, vol. 1, no. 4, pp. 541–551, Dec. 1989, doi: 10.1162/neco.1989.1.4.541.
- [67].ZaïaneOsmar, AntonieLuiza, and Coman, Alexandru, “Mammography Classification By an Association Rule-based Classifier,” in *Proceedings of the Third International Workshop on Multimedia Data Mining, MDM/KDD’2002*, July 23rd, 2002, Edmonton, University of Alberta, Canada, 2002, pp. 62–69.