



République Algérienne Démocratique et Populaire



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Mohamed El Bachir El Ibrahimi Bordj Bou Arreridj

Faculté des Mathématiques et d'Informatique

Département d'Informatique

Rapport de fin d'études en vue de l'obtention du diplôme
de Master en Informatique

Option : Technologies de l'Information et de la Communication

Thème

Plant Disease Detection using Deep Learning

Encadré par :

-Dr : ZOUACHE DJAAFAR

Réalisé par :

- KHEDARA AMEUR RAMI
- BENNACEF CHAOUKI

DEDICACE

Je dédie ce mémoire Aux êtres les plus chers au monde « MES PARENTS » qui ont toujours été à mes côtés

Et m'ont toujours soutenu tout au long de ces longues années d'études et L'amour et le respect

qui ont toujours été avec vous deux.

Que Dieu vous garde longtemps avec nous.

À mon frère issam , les mots ne suffiront pas à exprimer l'étendue de mon affection et de ma gratitude.

Sans oublier ma chère binôme chaouki pour son soutien moral, sa patience et sa compréhension tout au long de ce projet.

Ramy

DEDICACE

Je dédie ce mémoire aux êtres les plus chers à mon cœur :

À ma mère, qui a toujours été à mes côtés, m'a soutenu sans relâche tout au long de ces longues années d'études, et m'a comblé d'amour et de respect. Que Dieu te garde longtemps parmi nous.

À mes frères et à ma femme, les mots ne suffiront jamais à exprimer toute l'étendue de mon affection et de ma gratitude envers vous.

À tous mes amis et camarades de classe, en particulier Souhaibe , yahiya et Khelifa, Hamza en souvenir de notre sincère et profonde amitié ainsi que des moments agréables partagés ensemble. Merci pour votre affection et vos encouragements.

Sans oublier mon cher binôme Ramy, pour son soutien moral, sa patience et sa compréhension tout au long de ce projet.

CHAOUKI

REMERCIEMENT

Ellahmdolialh qu'on a arrivé à ce niveau d'éducation master 2 informatique.

Nous tenons à exprimer notre gratitude à notre professeur le Dr.

ZOUACHE DJAAFAR. Nous le remercions de nous avoir guidées, aidées et
Conseillées.

Nous présentons également nos sincères remerciements à toute l'équipe

Pédagogique du Département d'électronique de l'Université Université Mohamed El
Bachir El Ibrahimi Bordj Bou Arreridj.

Nous tenons également à remercier nos professeurs

Pour avoir accepté d'être membres du jury lors de notre soutenance.

Nos parents, pour leur soutien constant et leurs encouragements.

Nous voudrions exprimer notre reconnaissance envers les amis et collègues

Qui nous ont apporté leur soutien moral et intellectuel tout au long de notre
Démarche.

Résumé

Cette recherche nous a permis d'identifier les types de maladies végétales ainsi que leurs effets à l'aide de techniques de traitement de données visuelles et d'extraction de caractéristiques. L'objectif principal était de concevoir un système performant pour améliorer la détection et la classification des maladies des plantes. Pour cela, des réseaux de neurones convolutifs (CNN) ont été utilisés pour la détection, combinés à des classifieurs tels que SVM pour la classification. L'approche proposée repose sur une interaction entre l'apprentissage profond (Deep Learning) et l'apprentissage automatique (Machine Learning). Ce mélange de plusieurs méthodes a permis d'obtenir de meilleurs résultats, même en présence de données bruitées.

Abstract

This research enabled us to identify the types of plant diseases and their effects using visual data processing and feature extraction techniques. The main objective was to design an efficient system to improve the detection and classification of plant diseases. Convolutional Neural Networks (CNNs) were used for detection, combined with classifiers such as SVM for classification. The proposed approach is based on the interaction between Deep Learning and Machine Learning. This combination of multiple methods led to improved results, even in the presence of noisy data.

ملخص

مكّنتنا هذه الدراسة من التعرف على أنواع أمراض النباتات وآثارها باستخدام تقنيات معالجة البيانات المرئية واستخراج الخصائص. كان الهدف الرئيسي هو تصميم نظام فعال لتحسين عملية الكشف وتصنيف أمراض النباتات. تم استخدام الشبكات العصبية الالتفافية (CNN) للكشف، بالتكامل مع مصنّفات مثل SVM للتصنيف، وتعتمد المنهجية المقترحة على التفاعل بين التعلم العميق (Deep Learning) والتعلم الآلي (Machine Learning). وقد أدى هذا الدمج بين عدة تقنيات إلى تحقيق نتائج أفضل، حتى في ظل وجود بيانات مشوشة.

Table des matières

1 Introduction Générale

| | |
|------------------------------------------------------------------|----|
| 1.1 Contexte et importance de l'agriculture intelligente : | 11 |
| 1.2 Impact des maladies sur la production agricole :..... | 12 |
| 1.3 Motivation de l'utilisation du Deep Learning :..... | 12 |
| 1.4 Objectifs du mémoire :..... | 13 |
| 1.5 Problématique et hypothèses de recherche : | 14 |

2 Chapitre 2 : État de l'art

| | |
|-------------------------------------------------------------------------|----|
| 2.1 Méthodes traditionnelles de détection des maladies : | 16 |
| 2.2 Intelligence Artificielle en agriculture :..... | 17 |
| 2.3 Principes du Machine Learning pour la classification d'images | 17 |
| 2.4 Principes du Deep Learning et réseaux convolutifs | 19 |
| 2.5 Approches hybrides en classification d'images:..... | 22 |
| 2.6 Travaux connexes et comparaison des approches..... | 22 |

3 Chapitre 3 : Méthodologie de Apprentissage

| | |
|-------------------------------------------------------|----|
| 1) - Définition de Data Mining..... | 25 |
| - Les étapes du processus de Data Mining..... | 26 |
| 2) Apprentissage Automatique (Machine Learning) | 27 |
| 2.1- Apprentissage supervisé..... | 27 |
| - Techniques de l'apprentissage supervisé | 27 |
| 2.2 - Apprentissage non supervisé..... | 29 |
| - Techniques de l'apprentissage non supervisé..... | 30 |
| 2.3. Apprentissage par renforcement..... | 31 |
| 3) Le choix du type d'apprentissage automatique..... | 32 |
| 4) Deep Learning..... | 33 |
| 4.1. Définition du Deep Learning..... | 33 |
| 4.2. Architectures du Deep Learning..... | 34 |
| 4.3. Pourquoi utiliser le Deep Learning ? | 34 |
| 5) Réseaux de Neurones..... | 35 |
| 5.1. Définition des réseaux de neurones..... | 35 |
| 5.2. Avantages et inconvénients..... | 35 |
| 5.2.1. Avantages..... | 36 |
| 5.2.2. Inconvénients..... | 36 |

| | |
|-------------------------------------------------------------------------------|----|
| 5.3. Domaines d'application..... | 36 |
| 5.4. Couches d'un réseau de neurones..... | 37 |
| 6) Deep Learning Supervisé..... | 37 |
| 6.1. Réseaux de Neurones Récurrents (RNN) | 38 |
| 6.2. Réseaux de Neurones Convolutionnels (CNN) | 39 |
| 7). Différences entre Apprentissage Automatique et Apprentissage Profond..... | 40 |

4 Chapitre 4 : Expérimentations et Résultats

| | |
|----------------------------------------|----|
| 4.1 Introduction | 43 |
| 4.2 Outils matériels et logiciels | |
| 4.2.1 Configuration matériel | 44 |
| 4.2.2 Environnement logiciel | 44 |
| 4.3 Description de base de donne | 46 |
| 4.4 Évaluation d'un model | 46 |
| 4.5 classification utilise | 47 |
| 4.6 Expérience et résultats..... | 47 |

| | |
|------------------------------------------|-----------|
| 5 Conclusion et Perspectives..... | 53 |
|------------------------------------------|-----------|

Bibliographie

Liste des figures

| | |
|-------------------------------------------------------------------------------------------------|----|
| Figure 1: Une image d'une maladie des plantes. | 13 |
| Figure 2: Le processus de data mining..... | 27 |
| Figure 3: Réseau de neurones..... | 30 |
| Figure 4: Apprentissage non supervisé..... | 31 |
| Figure 5: Apprentissage par renforcement..... | 32 |
| Figure 6: Les approches et les algorithmes de l'apprentissage automatique. | 33 |
| Figure 7: Architecture de deep learning..... | 37 |
| Figure 8: les couches d'un réseau neurone..... | 38 |
| Figure 9: L'architecture des réseaux neuronaux convolution.. | 41 |
| Figure 10: Machine Learning (SVM, CNN, K-NN, Classification, Regression, Machine Learning)..... | 42 |
| Figure 11: Détection des maladies des plantes grâce à l'apprentissage profond | 43 |
| Figure 12: alg de résultat et hybrid model 1..... | 50 |
| Figure 13: alg de résultat et hybrid model 2..... | 51 |
| Figure 14: alg de résultat et hybrid model 3..... | 52 |

Liste des tableaux

| | |
|------------------------------------------------------------|----|
| Table 1: Machine Learning & Deep Learning. | 40 |
| Table 2: Caractéristique de l’outil utilisé, pycharm..... | 45 |
| Table 3:base de donner | 46 |
| Table 4: table de performance..... | 47 |
| Table 5:best model hybride | 48 |
| Table 6: table de comraison detaille de performance | 48 |

Introduction Générale

1 Introduction Générale :

L'informatique a progressivement investi différents secteurs économiques. L'un de ces secteurs est l'agriculture, où les technologies de l'information sont devenues des outils incontournables pour optimiser la production, la gestion et la planification des cultures.

L'agriculture moderne a beaucoup à gagner grâce à l'utilisation de l'informatique, que ce soit pour améliorer les rendements, réduire les coûts, ou mieux gérer les ressources naturelles.

Dans ce contexte, l'apparition des maladies des plantes représente une menace sérieuse pour la production agricole mondiale. Leur détection rapide et leur gestion efficace sont devenues des enjeux stratégiques. Aujourd'hui, grâce à l'évolution des technologies, notamment l'intelligence artificielle et le Deep Learning, il est possible d'apporter des solutions innovantes à ce problème majeur.

1.1 Contexte et importance de l'agriculture intelligente

L'agriculture est au cœur des enjeux alimentaires, économiques et environnementaux mondiaux. Face aux défis posés par l'augmentation de la population mondiale, le changement climatique et la pression sur les ressources naturelles, une transformation profonde du secteur est devenue nécessaire. L'agriculture intelligente repose sur l'intégration des nouvelles technologies telles que l'Internet des Objets (IoT), les capteurs connectés, les drones, l'analyse de données massives (Big Data) et l'intelligence artificielle (IA).

Ces technologies permettent aux agriculteurs de mieux comprendre leurs cultures, d'optimiser l'utilisation des ressources (eau, engrais, pesticides) et d'améliorer la productivité tout en réduisant l'impact environnemental.

Ainsi, l'agriculture numérique n'est pas seulement une révolution technologique, mais aussi une réponse stratégique aux attentes sociétales en matière de durabilité et de sécurité alimentaire.

1.2 Impact des maladies sur la production agricole

Les maladies des plantes représentent l'une des principales causes de perte de récoltes à l'échelle mondiale. Selon les recherches, les infections fongiques à elles seules peuvent détruire jusqu'à un tiers de la production alimentaire annuelle.

Les maladies peuvent être causées par différents agents pathogènes, classés en deux catégories principales :

- **Maladies abiotiques (non infectieuses)** : liées à des conditions environnementales défavorables telles que températures extrêmes, stress hydrique, pollution, ou composition chimique inadéquate des sols.
- **Maladies biotiques (infectieuses)** : causées par des bactéries, des champignons, des virus ou des parasites.

Parmi les agents infectieux, les bactéries provoquent des symptômes tels que le flétrissement, la nécrose et la pourriture. Les champignons, transportés souvent par le vent, colonisent rapidement les plantes via les blessures ou les pores d'eau.

Quant aux plantes parasites, comme *Striga spp.*, elles peuvent entraîner des pertes totales de culture, particulièrement dans les régions tropicales.

Face à cette menace, la détection précoce des maladies est devenue une nécessité pour assurer la sécurité alimentaire mondiale.



Figure 1 : Une image d'une maladie des plantes

1.3 Motivation de l'utilisation du Deep Learning

Face à la complexité et à la diversité des maladies végétales, les méthodes traditionnelles de détection manuelle s'avèrent souvent longues, coûteuses et imprécises.

Le **Deep Learning**, branche avancée de l'intelligence artificielle, offre des solutions puissantes grâce à ses capacités d'analyse automatique d'images.

En particulier, les réseaux de neurones convolutifs (CNN) sont capables d'apprendre à reconnaître des motifs complexes à partir de vastes ensembles de données visuelles.

Leur application dans la détection des maladies des plantes permet :

- Une identification rapide et précise,
- Une automatisation du processus de surveillance,
- Une réduction des erreurs humaines,
- Une prise de décision plus rapide et plus fiable pour l'agriculteur.

Ces avantages motivent l'utilisation du Deep Learning comme approche de choix dans la lutte contre les maladies agricoles.

1.4 Objectifs du mémoire

Ce mémoire vise à :

- Étudier l'impact des maladies sur la productivité agricole,
- Explorer les technologies numériques appliquées à l'agriculture, en particulier le Deep Learning,
- Concevoir et développer un modèle basé sur le Deep Learning pour la détection automatique des maladies des plantes à partir d'images,
- Évaluer les performances du modèle proposé sur une base de données représentative,
- Proposer des pistes d'amélioration pour une intégration pratique de ces outils dans les exploitations agricoles.

L'objectif ultime est d'apporter une contribution technologique à l'agriculture intelligente en vue d'améliorer la sécurité alimentaire et la durabilité des productions.

1.5 Problématique et hypothèses de recherche

Problématique :

Comment tirer parti du Deep Learning pour détecter rapidement et avec précision les maladies des plantes afin d'optimiser la gestion agricole et réduire les pertes de production ?

Hypothèses de recherche :

- Les réseaux de neurones convolutifs peuvent apprendre efficacement à classifier différentes maladies végétales à partir d'images.
- Une large base de données d'images correctement annotées est essentielle pour entraîner un modèle performant.
- L'intégration d'un tel système de détection précoce améliore significativement la productivité agricole et réduit les pertes économiques liées aux maladies.

Chapitre 2: État de l'art

2- Chapitre 2: État de l'art

2.1 Méthodes traditionnelles de détection des maladies :

Les maladies des plantes représentent une menace sérieuse pour l'ensemble de la production agricole, nécessitant ainsi une réponse efficace de la part des agriculteurs par le biais d'une prévention opportune. La complexité de cette tâche varie en fonction de la taille de la zone agricole, prenant en considération que la liste des maladies des plantes est assez impressionnante. Heureusement, les agriculteurs peuvent désormais tirer parti des technologies modernes. EOSDA Crop Monitoring permet d'identifier les zones à risque et d'appliquer une approche individualisée au traitement des récoltes, augmentant ainsi considérablement l'efficacité de la lutte contre ces maladies.

La classification des maladies des plantes peut être effectuée de plusieurs manières en fonction de divers critères. Cependant, une classification courante se base sur l'agent pathogène responsable de la maladie.

Traditionnellement, on distingue différents types de maladies des plantes, à savoir les maladies abiotiques, également appelées maladies non infectieuses, et les maladies biotiques, infectieuses.

Les maladies non transmissibles ont souvent pour origine des conditions environnementales défavorables telles que des températures extrêmes, un excès ou un déficit d'humidité. De plus, elles peuvent être causées par la présence d'impuretés nocives dans l'air, notamment issues d'activités industrielles telles que les usines chimiques ou métallurgiques à proximité. La composition physico-chimique néfaste du sol est généralement à l'origine de ces maladies, souvent liée à un traitement inadéquat des champs avec certains herbicides. Ces exemples soulignent l'importance de l'agriculture durable, non seulement pour la préservation de l'environnement, mais aussi pour la rentabilité des exploitations agricoles.

Même un éclairage inadéquat peut avoir des conséquences négatives, en particulier pour les plantes cultivées en serre. De plus, les toxines libérées dans le sol par certains embryophytes (plantes supérieures) et champignons peuvent également être responsables de maladies des cultures.

2.2 Intelligence Artificielle en agriculture :

L'intelligence artificielle transforme de plus en plus le secteur agricole et s'inscrit comme un levier essentiel pour conjuguer performance économique et durabilité environnementale.

Grâce aux solutions combinant données agricoles et apprentissage automatique, elle peut améliorer la prédiction des rendements et permet de diminuer les coûts pour les exploitants.

Face aux défis en termes de ressources naturelles, l'IA favorise une agriculture de précision et offre une prise de décision éclairée au monde agricole

2.3 Principes du Machine Learning pour la classification d'images :

Le Machine Learning est une technologie d'intelligence artificielle qui permet aux ordinateurs d'apprendre et se développer à partir de données. Il n'y a pas de Machine Learning sans données sur lesquelles s'entraîner. C'est pourquoi le Big Data (données massives dont le volume, la vitesse et la variété imposent l'utilisation de technologies et de méthodes analytiques particulières) représente l'essence du Machine Learning.

Les humains peuvent parler et écouter pour communiquer à travers le langage, c'est le domaine de la reconnaissance vocale. Une grande partie de la reconnaissance vocale est basée sur des statistiques, d'où le nom d'apprentissage statistique (Statistical Learning).

Les humains peuvent écrire et lire du texte dans une langue, c'est le domaine du traitement du langage naturel (NLP pour Natural Language Processing).

Les humains peuvent voir avec leurs yeux et traiter ce qu'ils voient, c'est le domaine de la vision par ordinateur (Computer Vision). La vision par ordinateur relève de la manière symbolique utilisée par les ordinateurs pour traiter les informations. Récemment, il y a eu une autre façon qui sera présentée ultérieurement.

Les humains peuvent reconnaître la scène autour d'eux et leur contexte à travers leurs yeux qui créent des images de cet environnement. Ce domaine du traitement d'image qui, même s'il n'est pas directement lié à l'IA, est requis pour la vision par ordinateur.

Les humains peuvent comprendre leur environnement et se déplacer de manière fluide, c'est le domaine de la robotique.

Les humains ont la capacité de voir des modèles tels que le regroupement d'objets similaires, c'est le domaine de la reconnaissance de formes (Object Recognition). Les machines sont bien meilleures pour la reconnaissance de formes car elles peuvent utiliser plus de données et de dimensions de données. C'est ce qu'on appelle l'apprentissage automatique, plus connue sous le nom de Machine Learning.

Deep Learning

Maintenant, parlons du cerveau humain. Le cerveau humain est un réseau de neurones et nous les utilisons pour apprendre des choses. Si nous pouvons reproduire la structure et la fonction du cerveau humain, nous pourrions peut-être obtenir des capacités cognitives dans les machines. L'IA possède aussi en quelques sortes des réseaux de neurones. Si ces réseaux sont plus complexes et plus profonds, et que nous les utilisons pour apprendre des choses complexes, c'est ce qu'on appelle l'apprentissage approfondi ou Deep Learning. Il existe différents types de Deep Learning et de machines qui sont essentiellement différentes techniques pour reproduire ce que fait le cerveau humain.

Si nous faisons en sorte que le réseau scanne des images de gauche à droite et de haut en bas, on parle de réseau neuronal à convolution (CNN). On l'utilise pour reconnaître des objets dans une scène, c'est ainsi que la vision par ordinateur s'opère et que la reconnaissance d'objets est rendue possible grâce à l'IA.

Les humains peuvent se souvenir du passé, tel que votre dernier repas de la veille, donc nous disposons d'un réseau de neurones pour se souvenir d'un passé limité. Il s'agit alors d'un réseau neuronal récurrent (RNN).

Apprentissage automatique ou supervisé

Comme vous le voyez, l'IA fonctionne de deux manières: l'une est basée sur des symboles (automatique) et l'autre sur des données (supervisé).

Pour le côté base de données, appelé apprentissage automatique, nous devons fournir à la machine un grand nombre de données avant qu'elle ne puisse apprendre d'elle-même. Par exemple, si vous avez beaucoup de données sur vos ventes de fruits par rapport aux dépenses liées à la production, vous pouvez tracer ces données pour obtenir une sorte de modèle. Si la machine peut apprendre ce modèle, elle peut alors faire des prédictions basées sur ce qu'elle a appris. Alors qu'une, deux ou trois dimensions sont faciles à comprendre et à apprendre pour les humains, les machines peuvent apprendre dans de nombreuses autres dimensions, comme des centaines ou des milliers. C'est pourquoi les machines peuvent examiner de nombreuses données de grande dimension et

déterminer des modèles. Une fois qu'il a appris ces modèles, il peut faire des prédictions dont l'homme ne peut même pas s'approcher. Nous pouvons utiliser toutes ces techniques d'apprentissage automatique pour faire une ou deux choses : la classification ou la prédiction. Par exemple, lorsque vous utilisez des informations sur les clients pour attribuer de nouveaux clients à un groupe tel que les jeunes adultes, vous classez ce client. Si vous utilisez des données pour prédire si elles sont susceptibles d'aller chez un concurrent, vous faites une prédiction.

Il existe une autre façon de penser aux algorithmes d'apprentissage utilisés pour l'IA. Si vous entraînez un algorithme avec des données contenant également la réponse, alors cela s'appelle l'apprentissage supervisé. Par exemple, lorsque vous apprenez à une machine à reconnaître une maladie foliaire, vous devez les identifier pour l'ordinateur. Si vous entraînez un algorithme avec des données dans lesquelles vous souhaitez que la machine détecte les modèles, il s'agit d'un apprentissage non supervisé. Par exemple, vous voudrez peut-être alimenter les données sur les ravageurs dans vos cultures et vous attendre à ce que la machine crée elle-même des modèles à partir de ces données.

Une méthode consiste à laisser l'algorithme apprendre de ses propres erreurs, en laissant au développeur du modèle la liberté de fixer les règles déterminant si l'IA sera récompensée ou punie : c'est l'apprentissage par renforcement (Reinforcement Learning).

2.4 Principes du Deep Learning et réseaux convolutifs :

Le réseau de neurones convolutifs, ou CNN pour faire court, est un type spécialisé de modèle de réseau de neurones conçu pour travailler avec des données d'images bidimensionnelles, bien qu'ils puissent être utilisés avec des données unidimensionnelles et tridimensionnelles. Ces réseaux sont capables d'apprendre à extraire des caractéristiques locales, c'est-à-dire des structures qui se répètent à travers l'image.

Au centre du réseau de neurones convolutifs se trouve la couche convolutionnelle qui donne son nom au réseau. Cette couche effectue une opération appelée « convolution ».

Une convolution est la simple application d'un filtre à une entrée qui entraîne une activation. L'application répétée d'un même filtre à une entrée produit une carte d'activations appelée carte de fonctionnalités (Feature map), indiquant les emplacements d'une fonctionnalité détectée dans une entrée, telle qu'une image.

Les CNNs ont été initialement développés pour la reconnaissance d'images. Le premier CNN a été créé en 1989 par Yann LeCun. Il a été formé pour reconnaître des caractères manuscrits et des digits. Les CNNs ont été créés à partir d'un réseau de neurones formé de plusieurs couches. Chaque couche est formée de neurones qui sont connectés aux neurones de la couche suivante. Ils sont entraînés en fournissant des images et en demandant au réseau de les classer. Le réseau apprend les caractéristiques des images au fur et à mesure qu'il les voit.

Les CNNs sont entraînés sur de grandes bases de données d'images et ont montré une meilleure performance que les algorithmes de vision par ordinateur existants. Ils ont ensuite été adoptés par de nombreux domaines, notamment la reconnaissance de la parole, la vision 3D, la vision par ordinateur médicale et l'apprentissage automatique.

Architecture d'un CNN

La première couche de convolution détecte les features de l'image, comme les contours, les formes et les textures. Les couches suivantes détectent des features plus complexes à partir des features détectés par la couche précédente. La dernière couche de convolution est généralement suivie d'une couche fully connected qui combine les features détectés par les couches de convolution et les utilise pour classifier l'image.

Les couches convolutionnelles peuvent être suivies de couches convolutionnelles supplémentaires ou de couches de regroupement (pooling). Avec chaque couche, le CNN augmente dans sa complexité, en identifiant de plus grandes portions de l'image. Les couches précédentes se concentrent sur des caractéristiques simples, telles que les couleurs et les bords. Au fur et à mesure que les données d'image progressent dans les couches du CNN, il commence à reconnaître des éléments ou des formes plus précises de l'objet jusqu'à ce qu'il identifie finalement l'objet visé.

Couche de convolution

La couche de convolution est la composante clé des réseaux de neurones convolutifs, elle constitue toujours au moins leur première couche. Les couches de convolution sont formées de ce qu'on appelle des filtres. Les filtres sont des tableaux de valeurs appelées feature maps. Chaque couche de convolution prend en entrée une image et produit une feature map. Chaque feature map est obtenue en appliquant le filtre à l'image. Par exemple, si l'image est de taille 5x5 et que le filtre est de taille 3x3, la feature map sera de taille 3x3. La couche de convolution reçoit donc en entrée plusieurs images et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images.

Couche de pooling

Ce type de couche est souvent placé entre deux couches de convolution : elle reçoit en entrée plusieurs feature maps, et applique à chacune d'entre elles l'opération de pooling. Une couche de pooling, agit comme une couche de réduction. Elle divise l'image en blocs et ne garde que le maximum de chaque bloc. Cela permet de réduire la dimension de l'image tout en conservant les caractéristiques les plus importantes. On obtient en sortie le même nombre de feature maps qu'en entrée, mais celles-ci sont bien plus petites.

Couche fully-connected

Les CNNs sont généralement formés de plusieurs couches de convolution et de pooling, suivies par une couche fully-connected qui combine les features extraites par les couches précédentes pour classifier l'image, elle renvoie un vecteur de taille N, où N est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe.

Par exemple, s'il s'agit bien d'un problème de classification de pommes et d'orange, le vecteur final sera de taille 2 : chaque élément donne la probabilité d'appartenir soit à la classe pomme, soit à la classe orange. Ainsi, le vecteur [0.8 , 0.2] signifie que l'image a 80% de chances de représenter une pomme.

La couche fully connected constitue toujours la dernière couche d'un réseau de neurones, convolutif ou non, elle n'est donc pas caractéristique d'un CNN. Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée.

Mise en application du CNN

Dans ce qui suit, nous allons créer un CNN simple pour classifier des images de nous allons faire un exemple de classification d'images de chiffres manuscrits. Pour ce faire, nous utiliserons le jeu de données très connu MNIST.

Nous allons commencer par télécharger les données MNIST et diviser les données en données d'apprentissage et de test.

Chaque jeu de données est divisé en images et étiquettes. Chaque image est un tableau de pixels de 28 x 28. Les étiquettes sont des nombres de 0 à 9 correspondant aux dix chiffres manuscrits.

Les données doivent être pré-traitées avant de pouvoir être utilisées dans le réseau de neurones. Les valeurs de pixels doivent être normalisées de 0 à 1

2.5 Approches hybrides en classification d'images:

La classification d'images s'articule généralement autour des deux étapes que sont l'étape d'extraction de signatures suivie de l'étape d'analyse des données extraites, ces dernières étant généralement quantitatives. De nombreux modèles de classification ont été proposés dans la littérature, le choix du modèle le plus adapté est souvent guidé par les performances en classification ainsi que la lisibilité du modèle. L'arbre de classification et le treillis de Galois sont deux modèles symboliques connus pour leur lisibilité. Dans sa thèse, Guillas a utilisé efficacement les treillis de Galois pour la classification d'images, et des liens structurels forts avec les arbres de classification ont été mis en évidence. Les travaux présentés dans ce manuscrit font suite à ces résultats, et ont pour but de définir un modèle hybride entre ces deux modèles, qui réunissent leurs avantages (leur lisibilité respective, la robustesse du treillis et le faible espace mémoire de l'arbre). A ces fins, l'étude des liens existants entre les deux modèles a permis de mettre en avant leurs différences. Tout d'abord, le type de discrétisation, les arbres utilisent généralement une discrétisation locale tandis que les treillis, initialement définis pour des données binaires, utilisent une discrétisation globale.

A partir d'une étude des propriétés des treillis dichotomiques (treillis définis après une discrétisation), nous proposons une discrétisation locale pour les treillis permettant d'améliorer ses performances en classification et de diminuer sa complexité structurelle. Puis, le processus de post-élagage mis en œuvre dans la plupart des arbres a pour objectif de diminuer la complexité de ces derniers, mais aussi d'augmenter leurs performances en généralisation. Les simplifications de la structure de treillis (exponentielle en la taille de données dans les pires cas), quant à elles, sont motivées uniquement par une diminution de la complexité structurelle. En combinant ces deux simplifications, nous proposons une simplification de la structure du treillis obtenue après notre discrétisation locale et aboutissant à un modèle de classification hybride qui profite de la lisibilité des deux modèles tout en étant moins complexe que le treillis mais aussi performant que celui-ci.

2.6 Travaux connexes et comparaison des approches :

Méthodes traditionnelles de détection des maladies

Les approches classiques reposent majoritairement sur l'observation humaine directe ou l'intervention manuelle soutenue par des outils technologiques simples comme la cartographie par satellite (ex. EOSDA Crop Monitoring). Elles permettent une détection assez fiable mais restent :

Limitées par la subjectivité de l'observateur.

Moins efficaces sur de grandes surfaces ou en cas de variabilité environnementale.

Inadaptées à une réponse en temps réel à grande échelle.

2. Apport de l'intelligence artificielle

L'IA marque une rupture en proposant une agriculture de précision qui favorise :

Une prise de décision automatisée et proactive.

La réduction des intrants chimiques par une application ciblée.

Une meilleure anticipation des risques phytosanitaires.

Cependant, l'IA dépend fortement :

De la disponibilité et de la qualité des données.

De la complexité des algorithmes et de leur coût de mise en œuvre.

3. Apprentissage automatique (Machine Learning)

Le Machine Learning permet d'entraîner des modèles à partir de données étiquetées ou non :

Apprentissage supervisé : utile pour la classification ciblée de maladies.

Apprentissage non supervisé : pertinent pour la détection de comportements anormaux ou de nouveaux types de maladies.

Renforcement : intéressant pour des systèmes adaptatifs (robots agricoles, drones intelligents).

Mais cette approche souffre parfois :

D'un besoin massif de données d'entraînement.

D'une opacité des décisions, surtout dans les algorithmes complexes.

4. Réseaux de neurones convolutifs (CNN - Deep Learning)

Les CNN sont particulièrement adaptés à la classification d'images :

Haute précision dans la détection de symptômes visuels sur les feuilles et fruits.

Capacité d'apprentissage hiérarchique des caractéristiques visuelles.

Utilisés dans des cas réels comme MNIST ou ImageNet, facilement transposables à l'agriculture.

Leur faiblesse principale réside dans :

Le besoin en puissance de calcul et en données annotées.

Une interprétabilité plus faible des modèles (boîte noire).

5. Approches hybrides (symboliques + apprentissage)

Les approches hybrides, comme l'association treillis de Galois + arbres de décision, cherchent un compromis entre performance et lisibilité :

Lisibilité accrue des modèles pour les experts métiers.

Optimisation mémoire et robustesse structurée.

Adaptées à des environnements contraints (edge computing agricole).

Ces méthodes, encore peu démocratisées, représentent une piste prometteuse pour les systèmes explicables, mais :

Nécessitent un effort de modélisation avancée.

Peuvent être moins performantes sur des données non structurées

Chapitre 3 : Méthodologie de Apprentissage

Le data mining appelé aussi fouille de données est l'ensemble des outils qui permettent l'extraction d'information à partir de grand volume de données ces informations sont utiles à la décision, et comme il est dit par Piatestky-Shapiro, « [...] as long as the world keeps producing data of all kinds [...] at an ever increasing rate, the demand for data mining will continue to grow » [1].

Il existe différentes techniques pour en extraire des connaissances, mais les plus efficaces sont les méthodes de classification. La classification consiste à examiner les caractéristiques d'un objet et à lui attribuer une catégorie. Les machines découvrent cette classe en utilisant des méthodes d'apprentissage artificielles.

Dans ce chapitre, nous allons d'abord fournir des méthodes pour extraire des informations à partir de grands ensembles de données et introduire des techniques d'apprentissage automatique. Enfin, nous discuterons quelques travaux basés sur l'apprentissage automatique « Machine Learning » et l'apprentissage en profondeur « Deep Learning », pour la prédiction du Osteoarthritis. Nous finissons le chapitre par une conclusion.

1. Définition de data mining

Il existe plusieurs définition de data mining parmi eux :

- Le Data Mining est un domaine interdisciplinaire utilisant dans le même temps des techniques d'apprentissage automatiques, de reconnaissance des formes, des statistiques, des bases de données et de visualisation pour déterminer les manières d'extraction des informations de très grandes bases de données [2].
- Le Data Mining est l'analyse de grandes ensembles de données observationnelles pour découvrir des nouvelles relations entre elles et de les reformuler afin de les rendre plus utilisables de la part de ses propriétaires [3].
- Le Data Mining est un processus inductif, itératif et interactif dont l'objectif est la découverte de modèles de données valides, nouveaux, utiles et compréhensibles dans de larges Bases de Données [4].

-Les étapes du processus de data mining

- 1) **Collecte des données** : la combinaison de plusieurs sources de données, souvent hétérogènes, dans une base de données [6] [7].
- 2) **Nettoyage des données** : la normalisation des données : l'élimination du bruit (les attributs ayant des valeurs invalides et les attributs sans valeurs) [6] [7].
- 3) **Sélection des données** : Sélectionner de la base de données les attributs utiles pour une tâche particulière du data mining [8].
- 4) **Transformation des données** : le processus de transformation des structures des attributs pour être adéquates à la procédure d'extraction des informations [9].
- 5) **Extraction des informations (Data mining)** : l'application de quelques algorithmes du Data Mining sur les données produites par l'étape précédente (*Knowledge Discovery in Databases*, ou KDD) [7] [8].
- 6) **Visualisation des données** : l'utilisation des techniques de visualisation (Histogramme, camembert, arbre, visualisation 3D) pour exploration interactive de données (la découverte des modèles de données) [9] [7].
- 7) **Evaluation des modèles** : l'identification des modèles strictement intéressants en se basant sur des mesures données [6].

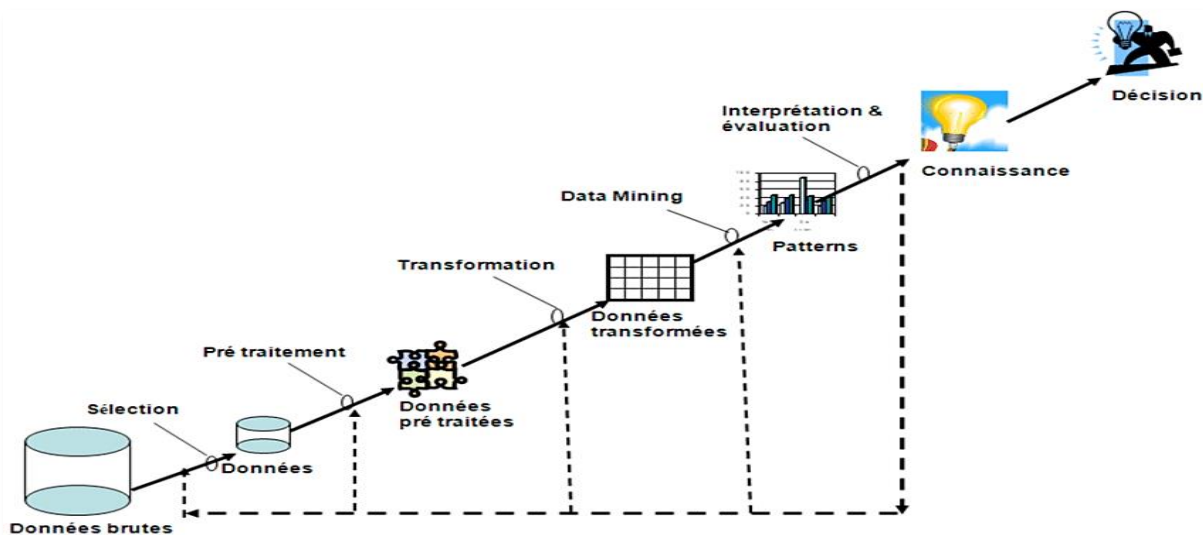


Figure 2: Le processus de data mining.

2. Apprentissage automatique

L'apprentissage automatique est un sous-ensemble de l'intelligence artificielle « IA », il est axé sur la création des systèmes qui apprennent et améliorent les performances, en se basant sur des données qu'ils traitent. Les algorithmes d'apprentissage automatique entrent en jeu pour optimiser, fluidifier, et sécuriser cette dernière.

2.1 - Apprentissage supervisé

L'apprentissage supervisé est le paradigme d'apprentissage le plus populaire dans l'apprentissage automatique et l'apprentissage en profondeur. Comme son nom l'indique, il s'agit de superviser l'apprentissage automatique en lui montrant des exemples (données) des tâches qu'il doit effectuer. Les applications sont nombreuses : reconnaissance vocale, vision par ordinateur, régression, classification... la grande majorité des problèmes de machine Learning et de deep Learning utilisent l'apprentissage supervisé. Il est donc nécessaire de comprendre le fonctionnement du mécanisme. Avec l'apprentissage supervisé, une machine apprend à effectuer une tâche en étudiant des exemples de celle-ci. En général, une machine peut apprendre la relation $f : x \rightarrow y$ reliant x à y en analysant des millions d'exemples d'associations $x \rightarrow y$.

-Techniques de l'apprentissage supervisé

Les algorithmes de l'apprentissage automatique supervisé sont les plus couramment utilisés, il y a deux types d'apprentissage supervisé :

➤ **La classification** : la classification consiste à trouver le lien entre une variable d'entrée (X) et une variable de sortie discrète (Y), en suivant une loi multinomiale, parmi les algorithmes de classification couramment utilisés, on peut citer :

a. SVM (Machines à vecteurs de support)

Est un modèle d'apprentissage automatique très puissant et général capable d'effectuer une classification linéaire ou non linéaire, une régression et même une détection des valeurs aberrantes. Est une classe d'algorithmes d'apprentissage définis à l'origine pour la discrimination, c'est-à-dire la prédiction de variables qualitatives binaires. Elles sont ensuite

généralisées à la prédiction de variables quantitatives. Dans le cas des variables dichotomiques discriminantes, elles reposent sur la recherche du meilleur hyperplan marginal classant ou séparant correctement les données lorsque cela est possible tout en étant le plus éloigné possible de toutes les observations. Le principe est donc de trouver un classifieur ou une fonction discriminante dont la capacité de généralisation (qualité prédictive) est maximale.

b. La méthode des k plus proches voisins

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation x , l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation.

La classe de x est déterminée en fonction de la classe majoritaire parmi les k plus proches voisins de l'observation x .

Donc la méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche, au regard des Co-variables utilisées. La détermination de leur similarité est basée sur des mesures de distance :

$$d(X_i + X_j) = \sqrt{\sum_{k=1}^d (x_{ik} - x_{jk})^2} \dots\dots\dots(1)$$

c. Naïve Bayes

Est un classificateur assez intuitif à comprendre. Il est basé sur le théorème bayésien des probabilités conditionnelles et suppose que les variables sont indépendantes les unes des autres. Cela simplifie le calcul des probabilités. Il est largement utilisé et a de nombreuses utilisations dans le domaine de l'apprentissage automatique. L'algorithme Naïve Bayes est une technique d'exploration de données utilisée pour diagnostiquer les patients souffrant de maladies cardiaques. Le théorème de Bayes présente une méthode de calcul de $P(C_i/X_j)$ à l'aide de probabilités $P(C_i)$, $P(X_j)$ et $P(X_j/C_i)$.

➤ **Régression** : la régression consiste à prédire une valeur continue pour la variable de sortie, parmi les régressions couramment utilisés, on peut citer :

a. Les arbres de décision

Les arbres de décision sont des outils d'aide à la décision qui permettent d'assigner des groupes d'individus en groupes homogènes selon des objectifs connus, basés sur des variables discriminantes. Les arbres de décision sont des outils puissants et populaires pour la classification et la prédiction. Les arbres de décision peuvent donner des prédictions en réduisant progressivement le champ des solutions basées sur des données connues sur le problème. Chaque noeud interne d'un arbre de décision peut répartir les éléments à classer entre ses différents sous-éléments de manière uniforme en associant aux variables discriminantes de ces éléments.

Les branches représentant les connexions entre un nœud et ses nœuds enfants sont des valeurs discriminantes pour les variables de nœud. Enfin, les feuilles de l'arbre de décision représentent les prédictions pour les données à classer.

b. Les Réseaux de Neurones

Les réseaux de neurones simulent la fonction des cellules nerveuses à l'aide d'automates former des neurones. Un réseau de neurones est constitué d'un groupe de neurones (nœuds) qui sont reliés les uns aux

autres par des liens qui permettent aux signaux de se propager d'un neurone à l'autre. En raison de sa capacité

d'apprentissage, les réseaux de neurones peuvent découvrir des relations non linéaires complexes entre un grand nombre de variables sans intervention externe. A ce titre, ils sont largement utilisés dans de nombreux problèmes tels que la classification (objectifs marketing, reconnaissance de formes, traitement du signal, etc.), l'estimation (modélisation de phénomènes complexes, etc.) et la prévision (bourses, ventes, etc.). Il existe un compromis entre la clarté du modèle et le pouvoir prédictif. Plus le modèle est simple, plus il est facile à comprendre, mais moins il est susceptible de prendre en compte trop de dépendances changeantes. Il existe aussi d'autres algorithmes, tels que l'algorithme de régression linéaire, les Algorithmes Génétiques. Certains algorithmes de régression peuvent également être utilisés pour la classification, et la régression, à titre d'exemple l'algorithme de la régression logistique.




Figure 3: Réseau de neurones

2.2 Apprentissage non supervisée

L'apprentissage non-supervisé, encore appelé apprentissage à partir d'observations ou découverte, consiste à déterminer une classification « sensée » à partir d'un ensemble d'objets ou de situations données (des exemples non étiquetés). On dispose d'une masse de données indifférenciées, et l'on désire savoir si elles possèdent une quelconque structure de groupes. Il s'agit d'identifier une éventuelle tendance des données à être regroupées en classes. Ce type d'apprentissage, encore appelé Cluster ING ou Cluster Analysais, se trouve en classification automatique et en taxinomie numérique. Cette forme de classification existe depuis des temps immémoriaux.

Elle concerne notamment les sciences de la nature, les classifications des documents et des livres mais également la classification des sciences élaborées au cours des siècles par les philosophes.

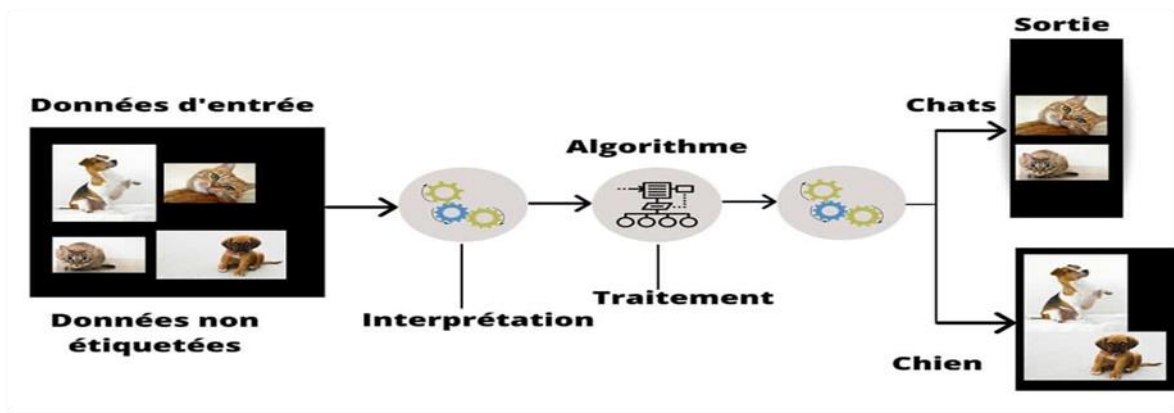


Figure 4: Apprentissage non supervisé.

- Techniques de l'apprentissage non supervisé

Selon (Géron, 2017), il y a deux types d'apprentissage non supervisé [11] :

➤ **Regroupement(Clustering)** : c'est une méthode d'analyse statistique utilisée pour organiser des données brutes en silos homogènes, à l'intérieur de chaque grappe, les données sont regroupées selon une caractéristique commune.

Les algorithmes les plus célèbres utilisés dans cette approche sont [12] :

a. k-means

Est l'algorithme de regroupement le plus connu et le plus utilisé, du fait de sa simplicité de mise en œuvre. Il regroupe dans les même Cluster (Groupes) les données similaires (qui se ressemblent). Il utilise un raffinement itératif pour produire un résultat final.

Les principales étapes de l'algorithme k-means sont :

1. Choix aléatoire de la position initiale des K clusters.
2. (Réaffecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).
3. Une fois tous les objets placés, recalculer les K centroids.
4. Répéter les étapes 2 et 3 jusqu'à ce que plus aucune réaffectation ne soit faite.

L'algorithme C-Means dans sa formulation originale cherche à minimiser une fonction de coût global définie par :

$$J = \sum_{i=1}^c \sum_{(x,y), k \in C_i} d^2(f(x,y), b_i) \dots \dots \dots (2)$$

b. Analyse de classification hiérarchique (HCA)

La mise dans un cluster hiérarchique est similaire à la mise dans un cluster normal, sauf que dans ce cas nous souhaitons mettre en place une hiérarchie des clusters. Cela peut s'avérer très important surtout quand nous désirons une flexibilité par rapport au nombre de clusters voulu.

➤ **Réduction de la dimension** : l'objectif est de simplifier les données sans perdre trop d'informations, à titre d'exemple, fusionner plusieurs caractéristiques en un seul caractère.

Les algorithmes les plus célèbres utilisés dans cette approche sont [12] :

a. PCA (Analyse des composants principaux)

L'algorithme PCA consiste à transformer des variables liées entre elles, vers de nouvelles variables séparées les uns des autres. Ces nouvelles variables sont nommées les composantes principales, elles permettent au praticien de réduire le nombre de variables et de rendre l'information moins redondante.

b. Apriori

L'algorithme Apriori s'utilise dans une base de données transactionnelle pour extraire des ensembles d'éléments fréquents, puis générer des règles d'association.

2.3 Apprentissage par renforcement

Avec l'apprentissage par renforcement, la machine n'a pas besoin de l'aide de l'homme, que ce soit en termes de supervision ou de fourniture de données. L'apprentissage par renforcement est une branche très différente. Un système d'apprentissage, appelé agent dans

Ce contexte, observe l'environnement, sélectionne et exécute des actions, et est finalement récompensé ou puni (récompenses négatives). Une machine peut apprendre par elle-même la meilleure politique à suivre, appelée politique, avec de multiples récompenses au fil du temps. Les politiques définissent les actions qu'un agent doit choisir dans une situation donnée [11].

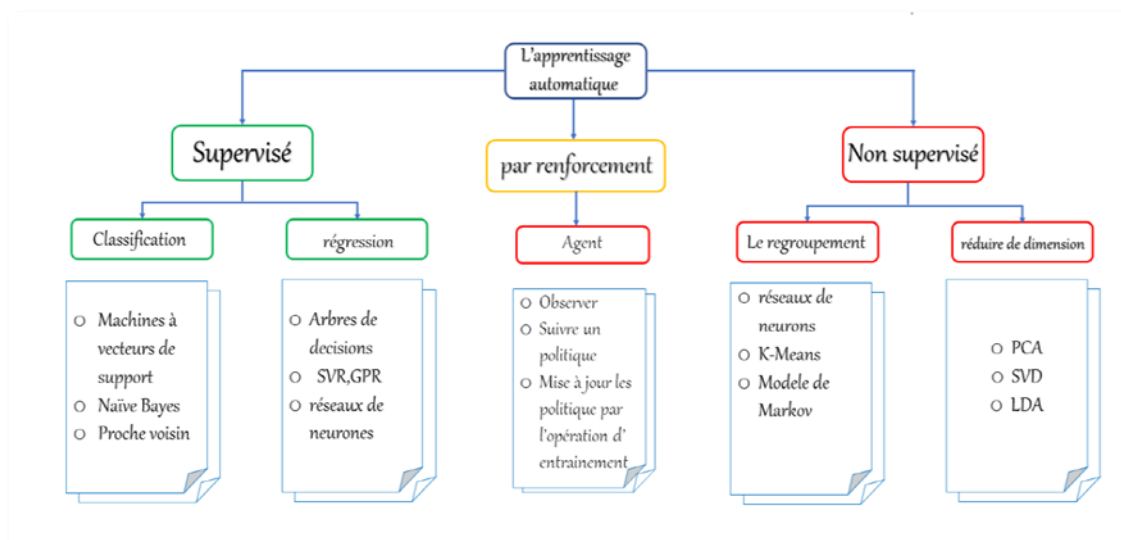


Figure 5: Apprentissage par renforcement.

La figure ci-dessus exprime les différentes branches et algorithmes de l'apprentissage automatique :

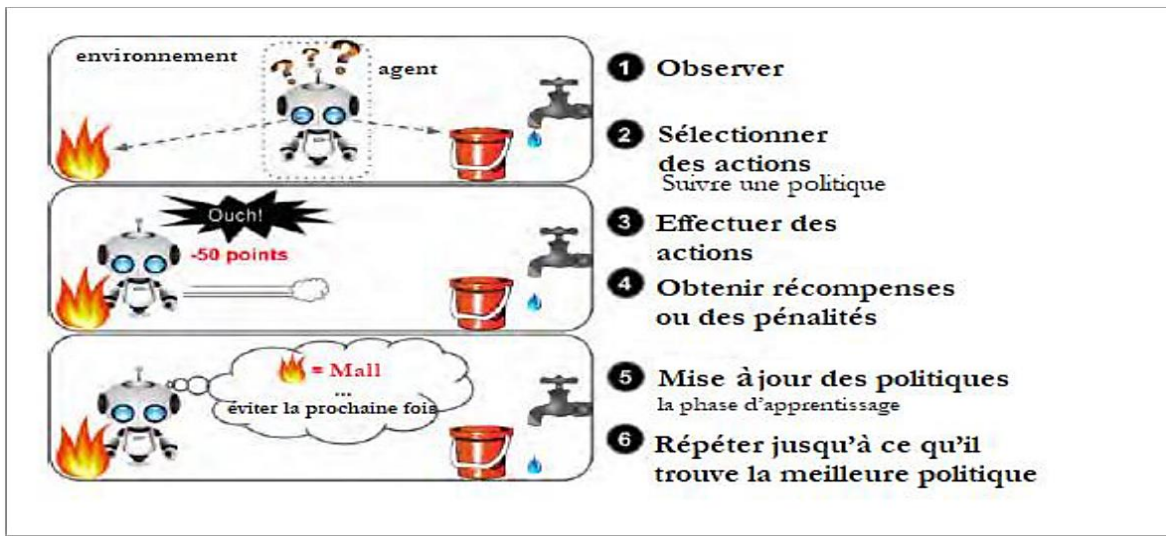


Figure 6: Les approches et les algorithmes de l'apprentissage automatique.

3 Le choix d'un type d'apprentissage automatique

Avec la présence de différents types de classifieurs pour l'apprentissage automatique, l'opération de choix d'un type est une question typique « Quel algorithme dois-je utiliser ? ». La réponse à cette question varie les facteurs suivants [13] :

- ✓ La taille, la qualité et la nature des données.
- ✓ Le temps de calcul disponible.
- ✓ L'urgence de la tâche.
- ✓ Le but d'utilisation de ces données

4) Le deep learning est un domaine de recherche qui vise à reproduire les capacités cognitives humaines en utilisant des techniques informatiques, notamment à travers les réseaux de neurones artificiels. Ces réseaux, composés de neurones interconnectés, peuvent apprendre à partir de grandes quantités de données pour effectuer des tâches complexes telles que la reconnaissance d'images et la compréhension du langage naturel.

Les applications du deep learning sont vastes et touchent de nombreux domaines, tels que la vision par ordinateur, le traitement du langage naturel, la médecine et la finance. Par exemple, il peut être utilisé dans le domaine médical pour l'analyse d'images médicales et l'aide au diagnostic.

Le deep learning représente une avancée majeure dans le domaine de l'intelligence artificielle, offrant des possibilités de traitement de l'information similaires à celles du cerveau humain. Les géants de l'industrie technologique investissent massivement dans cette discipline, ce qui témoigne de son potentiel et de ses résultats impressionnants. Toutefois, des recherches supplémentaires sont nécessaires pour améliorer les performances et explorer de nouvelles applications dans le domaine de l'apprentissage en profondeur.

4.1 Définition de Deep Learning

Le Deep Learning est une méthode de Machine Learning qui se fonde sur l'enseignement aux ordinateurs de ce que les humains font naturellement : apprendre par l'exemple. Cette technologie est cruciale pour les voitures autonomes, car elle permet à ces dernières de reconnaître des panneaux d'arrêt ou de distinguer un piéton d'un lampadaire. Elle est également utilisée dans les systèmes de commande vocale des appareils grand public, tels que les téléphones, les tablettes, les téléviseurs et les haut-parleurs mains libres. Le Deep Learning est de plus en plus populaire en raison de ses résultats remarquables qui étaient auparavant impossibles à atteindre. Les modèles de Deep Learning apprennent à réaliser des tâches de classification à partir d'images, de textes ou de sons. Ils peuvent atteindre un niveau de précision exceptionnel, parfois même supérieur à celui des performances humaines. Les modèles sont entraînés à partir de vastes ensembles de données labellisées et d'architectures de réseaux de neurones qui comportent plusieurs couches. En utilisant l'apprentissage en profondeur, il est possible de répondre implicitement à des questions telles que « Que peut-on déduire de ces données ? » et d'identifier des caractéristiques ou des relations entre les données qui seraient souvent impossibles à identifier pour l'homme [14].

4.2 Architectures de Deep Learning

Le nombre d'architectures et d'algorithmes utilisés dans l'apprentissage profond est vaste et varié. Cette section explore six des architectures d'apprentissage profond couvrant les 20 dernières années. Notamment, la mémoire à long terme (LSTM) et les réseaux de neurones convolutifs (CNN) sont deux des approches les plus anciennes de cette liste, mais aussi deux des plus utilisées dans diverses applications.

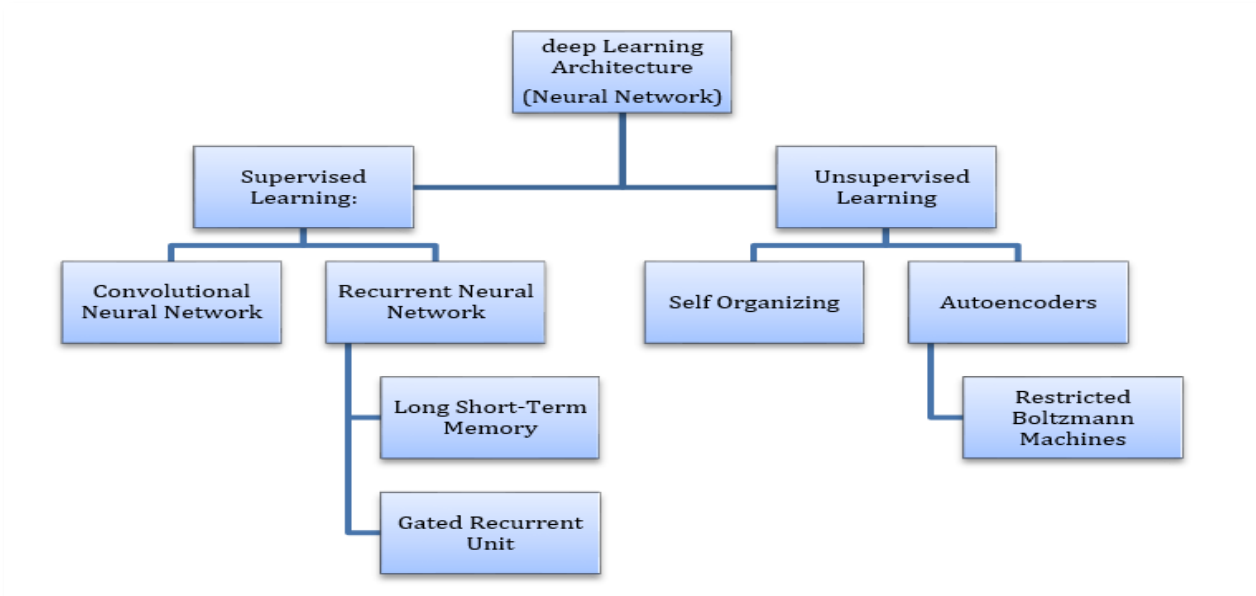


Figure 7: Architecture de deep learning.

4.2 Pourquoi Deep Learning

Il y a plusieurs facteurs qui contribuent à la popularité actuelle du Deep Learning :

- La disponibilité de grandes quantités de données, grâce à la numérisation croissante des informations à travers l'Internet des objets (IoT). Le Deep Learning est capable d'extraire des représentations abstraites à partir de ces données massives.
- L'augmentation de la puissance de calcul, en particulier l'utilisation de GPU qui sont désormais couramment utilisés comme plateforme pour le Deep Learning.
- L'augmentation de la demande pour des applications d'IA telles que la vision par ordinateur, la reconnaissance vocale et le traitement du langage naturel.

5) réseaux neurones

5.1 Définition de réseaux neurones : Un réseau de neurones est un modèle informatique qui imite la structure en couches du réseau de neurones du cerveau humain, en utilisant des nœuds interconnectés pour traiter des données.

En apprenant à partir de données, un réseau de neurones peut être entraîné à détecter des modèles, classifier des informations et même prédire des événements futurs.

Le réseau de neurones divise les données en couches d'abstraction et peut être entraîné sur de nombreux exemples pour reconnaître des motifs dans la parole, les images et autres types de données.

Les liens entre les éléments du réseau de neurones, ainsi que leur poids, déterminent son comportement et sont automatiquement ajustés pendant l'entraînement, en utilisant une règle d'apprentissage spécifiée, jusqu'à ce que le réseau de neurones puisse correctement exécuter la tâche souhaitée.

5.2 Les avantages et les inconvénients des réseaux de neurones

5.2.1 Les avantages de réseaux de neurones

- Flexibilité :

Les réseaux de neurones artificiels ont la possibilité de généraliser et d'apprendre. Ils acquièrent des connaissances de leur environnement en s'adaptant aux paramètres internes et externes, ils apprennent à partir d'exemples et s'adapte aux situations en fonction de ses conclusions et Ils généralisent les connaissances pour produire des réponses adéquates à des situations inconnues.

- Bonne résolution :

Les réseaux de neurones donnent de bons résultats même dans des domaines très complexes ils sont plus performants que les statistiques ou les arbres de décisions.

- Pertinence des données analysées :

Les réseaux de neurones peuvent travailler sur des données incomplètes ou bruitées. Cette imperfection des données peut être comblée par l'ajout de neurones supplémentaires à la couche cachée

- Apprentissage organique :

Les réseaux de neurones peuvent apprendre organiquement. Ils ne sont pas limités uniquement par ce qui a été donné à eux dans un système expert. Les réseaux de neurones peuvent généraliser à partir de leurs entrées, ce qui les rend précieux pour la robotique et les systèmes de reconnaissance de formes et pour l'analyse de données à grande échelle.

- La tolérance en pannes :

Les réseaux artificiels ont un potentiel élevé de tolérance aux pannes. Le réseau est capable de régénérer un défaut dans l'un de ses composants sans la perte des données stockées, Il utilise des instances et des exemples du passé pour remonter le fonctionnement d'un nœud endommagé ou les autres composants du réseau.

5.2.2 Les inconvénients des réseaux de neurones

- Non optimalité de l'architecture :

Il n'existe pas encore de moyens permettant de définir l'architecture optimale du réseau de neurones. Parce que pour définir l'architecture du réseau de neurones, il faut déterminer tout le nombre de couches cachées du réseau et le nombre de neurones pour chacune des couches et tout cela relève de l'intuition de l'opérationnel. L'intervention humaine : Comme c'est le cas du choix de la structure optimale du réseau de neurones, ce système fait souvent appel à l'intuition de l'utilisateur. L'apprentissage est guidé par des paramètres définis manuellement par l'opérationnel. Celui-ci devra par exemple définir à quel moment devra s'arrêter l'apprentissage pour que le réseau conserve ses capacités à généraliser.

- Codage des entrées :

Toutes les entrées doivent être défini dans un intervalle entre 0 et 1 ce qui engendre des traitements supplémentaires et risque de fausser les résultats.

- Boite noire :

Les réseaux de neurones peuvent être assimilés à une boîte noire qui donne une réponse quand on lui fournit des données mais qui ne délivre pas toujours de justification simple à analyser. C'est très difficile d'analyser et comprendre le fonctionnement en face d'un problème donné, et de choisir la structure (type, nombre de nœuds, organisation, connexions,...etc.) la mieux adaptée au problème.

5.3 Les domaines d'application

Aujourd'hui, les réseaux de neurones ont de nombreuses applications dans des domaines très variés :

- traitement d'image : compression d'images, reconnaissance de caractères et de signatures, Reconnaissance de formes et de motifs, chiffrement, classification, ...
- traitement du signal : traitement de la parole, identification de sources, filtrage, classification
- traitement automatique des langues : segmentation en mots, représentation sémantique des mots (plongements lexicaux), étiquetage morpho-syntaxique, traduction automatique.
- contrôle : diagnostic de pannes, commande de processus, contrôle qualité, robotique, ...
- optimisation : allocation de ressources, planification, régulation de trafic, gestion, finance...

5.4 Les couches d'un Réseau de neurone

Le perceptron est organisé en trois couches :

- Couche Entrée : (Input Layer) c'est l'ensemble de neurones qui porte le signal d'entrée du réseau, et par la suite tous les neurones de cette couche sont reliés à la couche suivante [16].
- Couche cachée : (Hidden Layers) elles peuvent être une ou plusieurs, c'est ici où les relations entre les variables vont être mise en exergue. Le choix du nombre de couches et de neurones est intuitif et nécessite de l'expérience venant de l'expert [16].
- Couche sortie : (Output Layer) elle représente le résultat du réseau de neurones c'est ce qu'on appelle la prédiction [16].




Figure 8 : les couches d'un réseau neurone.

6) Le Deep Learning supervisé

L'apprentissage supervisé est une méthode d'apprentissage automatique dans laquelle les données d'entraînement sont étiquetées avec les résultats souhaités. Dans cette section, nous aborderons deux des architectures d'apprentissage profond supervisé les plus courantes : les réseaux de neurones convolutifs et les réseaux de neurones récurrents, ainsi que quelques-unes de leurs variations.

6.1 RNN : Réseaux neuronaux récurrents

Les réseaux de neurones récurrents (RNN) sont considérés comme une architecture de base pour de nombreuses autres architectures d'apprentissage profond. Les RNN ont la particularité d'avoir une mémoire interne, ce qui leur permet de traiter des séquences d'entrées de longueur variable. Chaque information traitée est enregistrée dans cette mémoire et utilisée pour calculer le résultat final. Cette fonctionnalité est très utile pour les tâches telles que la reconnaissance vocale, où l'ordre des entrées est crucial. Les RNN ont également des connexions qui rétroagissent dans les couches précédentes, ce qui leur permet de stocker et de traiter l'historique des entrées passées et de résoudre les problèmes dans le temps. Les RNN sont particulièrement utiles dans les domaines du traitement automatique des langues, des chatbots, de la synthèse vocale et des traductions automatiques, où la séquence des informations est essentielle [17].

Actuellement, nous pouvons indiquer deux types de RNN :

❖ Le réseau de neurones LSTM :

L'architecture mémoire court-terme étendue LSTM «Long Short-Term Memory » est un type de RNN très utilisé en traitement du langage naturel, proposées par les informaticiens [18].

L'idée principale de l'architecture LSTM est de diviser le signal entre ce qui est important à :

- Court terme à travers une couche de sortie LSTM, nommée « l'état caché ».
- Long terme, à travers un neurone qui conserve un état interne, nommé « cellule d'état », ce neurone n'est pas un neurone de sortie.

Le fonctionnement global d'un LSTM peut se résumer selon les trois étapes suivantes :

1. Détecter les informations pertinentes venant du passé, piochées dans une cellule d'état à travers la porte oublier « forget gate ».
2. Choisir, à partir de l'entrée courante, celles qui seront pertinentes à long terme, via l'input gate. Celles-ci seront ajoutées à la cellule d'état qui fait d'office d'une mémoire longue.
3. Piocher dans la nouvelle cellule d'état les informations importantes à court terme pour générer l'état caché suivant à travers la porte de sortie « output gate »

- **GRU networks** : Le modèle GRU (Gated Recurrent Unit) est une variante simplifiée du modèle LSTM (Long Short-Term Memory) avec seulement deux portes : une porte de mise à jour et une porte de réinitialisation. Contrairement au modèle LSTM, le GRU n'a pas de porte de sortie. La porte de mise à jour permet de déterminer quelle quantité du contenu de la cellule précédente doit être conservée, tandis que la porte de réinitialisation définit comment la nouvelle entrée doit être combinée avec le contenu de la cellule précédente. Le GRU peut être utilisé pour modéliser un RNN standard en fixant la porte de réinitialisation à 1 et la porte de mise à jour à 0. Le GRU est plus simple que le LSTM, peut être entraîné plus rapidement et peut être plus efficace dans son exécution. Cependant, le LSTM peut être plus expressif et avec plus de données, il peut donner de meilleurs résultats [19].

6.2 Réseaux neuronaux convolution (Convolutional neural networks)

Les réseaux de neurones convolution (CNN) utilisent une approche similaire aux méthodes traditionnelles d'apprentissage supervisé pour la reconnaissance d'images. Cependant, contrairement aux techniques d'apprentissage supervisé, les CNN sont capables d'apprendre à extraire et à décrire les caractéristiques des images eux-mêmes. Cette caractéristique constitue leur principale force. En effet, les systèmes de reconnaissance d'images classiques sont généralement composés de deux principaux blocs :

- un extracteur de caractéristiques qui transforme la matrice représentative de l'image en une série de nombres
- un classifié qui effectue des calculs de sommes pondérées pour classifier l'image. Toutefois, les méthodes traditionnelles sont limitées en raison de la complexité de créer un classifié adapté à chaque problème et des limites de prédiction des méthodes de perceptron ou de régression logistique. Les CNN, quant à eux, sont capables d'extraire des caractéristiques de différentes complexités, allant des plus simples aux plus sophistiquées, grâce à leur architecture spécifique.

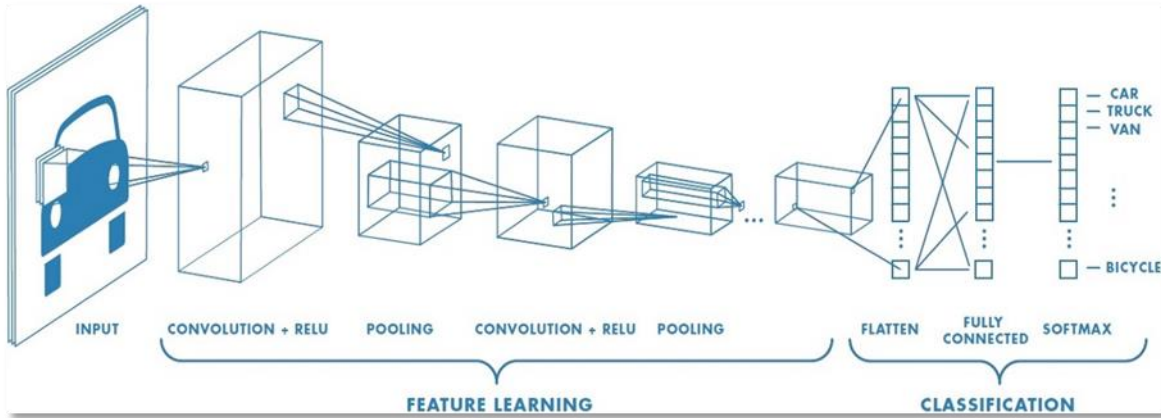


Figure 9: L'architecture des réseaux neuronaux convolution.

7) Différence entre l'apprentissage automatique et l'apprentissage profond

| Machine Learning | Deep Learning |
|----------------------------------------------------------------------------------------------------|--------------------------------------------------|
| Travaille sur une petite quantité de données pour plus de précision. | Travaille sur une grande quantité de données. |
| Dépend d'une machine bas de gamme. | Fortement dépendant d'une machine haut de gamme. |
| Divise les tâches en sous-tâches, les résout individuellement et combine finalement les résultats. | Résout le problème de bout en bout. |
| La formation prend moins de temps. | Le temps de formation est plus long |
| Le temps de test peut augmenter. | Moins de temps pour tester les données. |

Table 1: Machine Learning & Deep Learning.

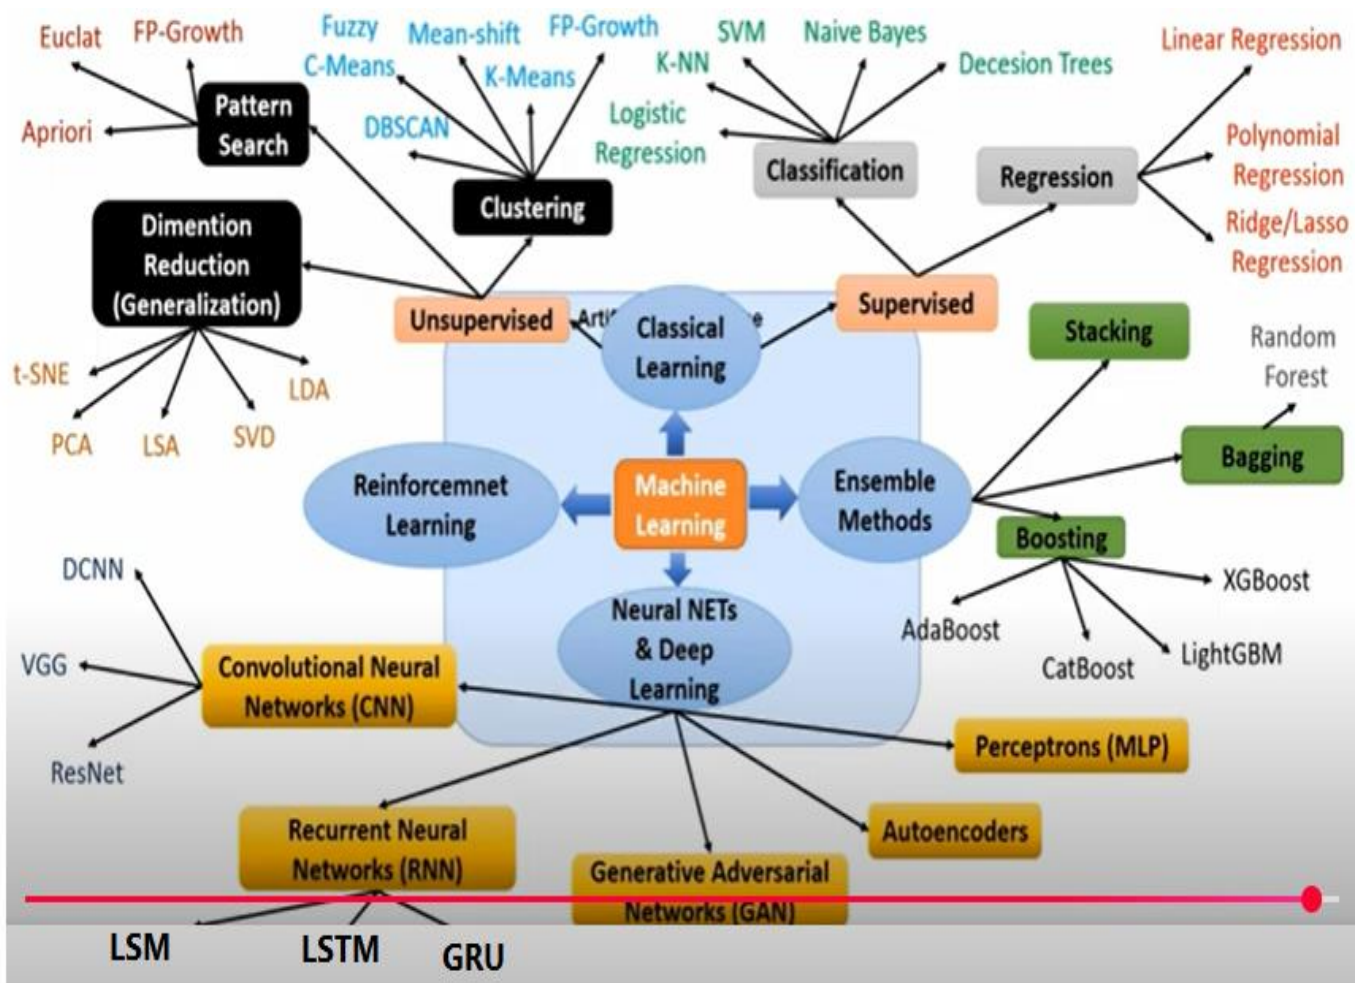


Figure 10: Machine Learning (SVM, CNN, K-NN, Classification, Regression, Machine Learning)

Chapitre 4 : Expérimentations et Résultats

4- Chapitre 4

Introduction

Ce chapitre est dédié à l'expérimentation dans le cadre de notre étude sur la mémoire. Nous débutons en présentant les outils utilisés pour le développement du projet, y compris le choix du langage de programmation et le matériel spécifique utilisé. Ensuite, nous décrivons en détail le processus de classification que nous avons appliqué, ainsi que les différentes expériences menées sur nos données. Les résultats obtenus sont ensuite présentés et analysés en profondeur. Nous mettons en lumière les principales observations et discutons de leurs implications pour notre étude. Enfin, nous concluons le chapitre en proposant une synthèse des résultats et en fournissant des réflexions approfondies sur leurs implications et leur contribution à notre recherche.

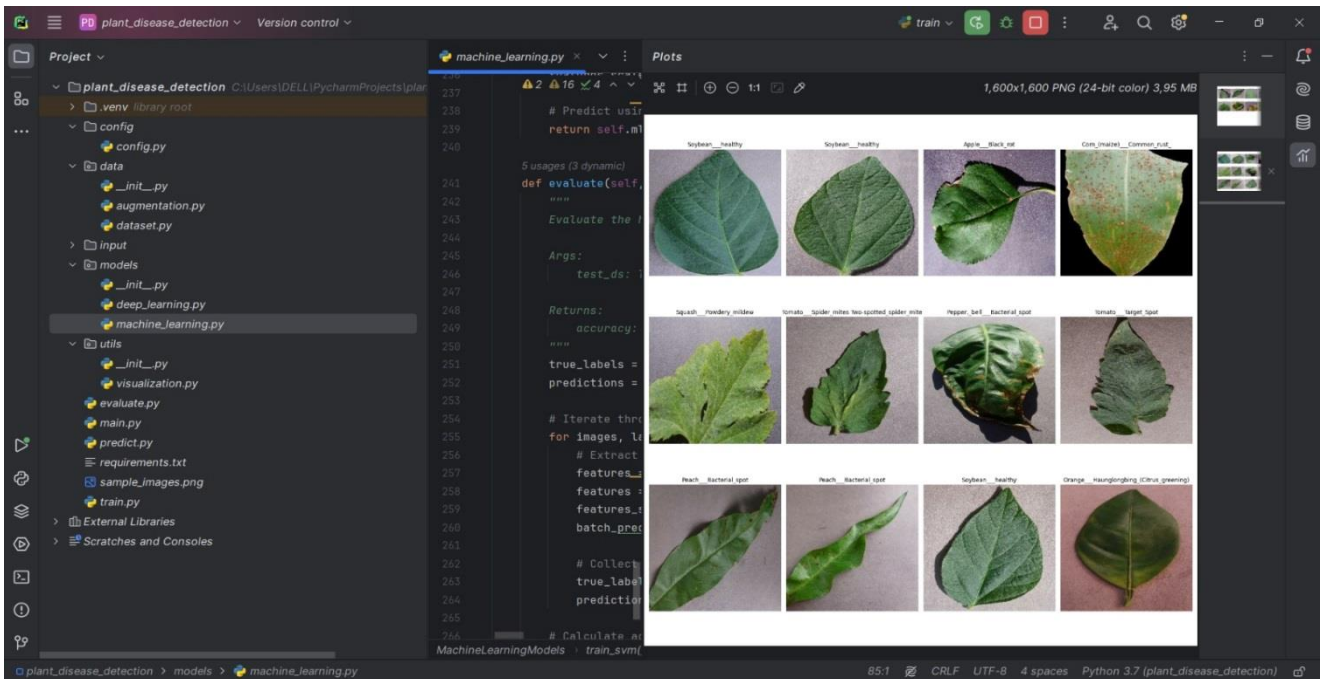


Figure 11: Détection des maladies des plantes grâce à l'apprentissage profond

1. Outils matériels et logiciels

1.1 Configuration matériels

Ce travail a été implémenté sur un PC, caractérisé comme suit :

- **Un Processeur** : Intel(R) Core(TM) I5-37200U CPU @ 2.50GHz 2.71GHz
- **Une RAM** : 8 GO.
- **Sous un système d'exploitation** 64 bits.


1.2 Environnement logiciel

Pour le développement de notre application, on a choisi comme outil de développement, PyCharm est un environnement de développement intégré utilisé pour programmer en Python. Il permet l'analyse de code et contient un débogueur graphique. Il permet également la gestion des tests unitaires, l'intégration de logiciel de gestion de versions, et supporte le développement web avec Django.

Développé par l'entreprise tchèque JetBrains, c'est un logiciel multi-plateforme qui fonctionne sous Windows, macOS et Linux. Il est décliné en édition professionnelle, diffusé sous licence propriétaire, et en édition communautaire diffusé sous licence Apache.

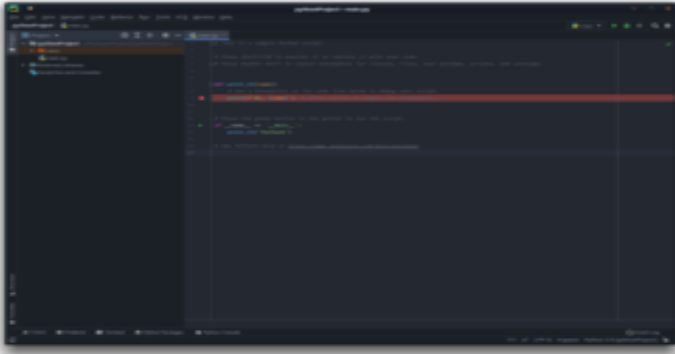
Avec une fiche technique comme suite :

PyCharm



PyCharm

JETBRAINS IDE



Informations

| | |
|------------------------|------------------------------------------------------------------------------|
| Développé par | JetBrains ✎ |
| Dernière version | 2024.3.2 (28 janvier 2025) ¹ ✎ |
| Écrit en | Java et Python ✎ |
| Système d'exploitation | Linux, Microsoft Windows et macOS ✎ |
| Formats lus | Python script (d) ✎ |
| Langues | Anglais ✎ |
| Type | Environnement de développement intégré Kit de développement ✎ |
| Licence | Licence propriétaire et licence Apache 2.0 ✎ |
| Site web | www.jetbrains.com/pycharm/ ✎ |

Table 2: Caractéristique de l'outil utilisé, pycharm.

2. Description de la base de données

Notre ensemble de données se compose de trois fichiers, chacun contenant deux sous-fichiers. Chaque sous-fichier représente une classe spécifique de notre problème de classification. Nous avons ainsi un fichier d'entraînement, un fichier de test et un fichier de validation, chacun avec des sous-fichiers "normal" et "ostéoarthrite". Ces fichiers contiennent des images radiographiques du genou avec des annotations manuelles de l'espace articulaire pour chaque compartiment du genou comme suite :

| | |
|----------------------|-------------------------------|
| Apprentissage | Normal : 2 350 Images |
| | Osteoarthritis : 1 540 Images |
| Test | Normal : 569 Images |
| | Osteoarthritis : 276 Images |
| Valid | Normal : 210 Images |
| | Osteoarthritis : 431 Images |

table3: La base de données.

Nous n'utiliserons que les images des patients contaminés par l'Osteoarthritis : et les images des patients normaux pour une classification binaire ' donnant 1 pour les cas normaux et 2 pour les patient contaminés par Osteoarthritis.

- ✓ **La base de données** : a été extraite à partir de Kaggle.
- ✓ **Format des images** : toutes les images sont au format de fichier Portable Network Graphics (PNG) et la résolution est de 224*224 pixels

3. Évaluation d'un modèle

Dans cette partie, on va s'intéresser à comment les modèles de prédictions en Machine Learning sont évalués, et plus précisément dans le cas de la classification. L'étape d'évaluation s'avère être une étape importante dans la démarche de choix du modèle, d'où la nécessité d'avoir un outil (matrice de confusion) de précision qui nous permet de mener cette étape en bonne et due forme [25] [26].

4. Les classificateurs utilisés

Classificateur KNN

Le classificateur KNN (K-Nearest Neighbors) est un algorithme de classification simple et non paramétrique. Il est largement utilisé dans les applications de classification supervisée, en particulier dans les domaines de la reconnaissance de formes et de la vision par ordinateur.

Le principe de base de l'algorithme KNN est de classer une observation en fonction des classes des k échantillons les plus proches dans l'espace des attributs. La distance entre deux observations est généralement calculée en utilisant la distance euclidienne ou une mesure de similarité appropriée.

Une fois que les k échantillons les plus proches ont été identifiés, la classe majoritaire parmi ces k échantillons est attribuée à l'observation à classer. Si k=1, l'observation est simplement classée dans la classe de son échantillon le plus proche.

4.1 Classificateur SVM

Le classificateur SVM (Support Vector Machine) est un algorithme de classification utilisé pour séparer les exemples de différentes classes en trouvant un hyperplan optimal dans un espace multidimensionnel. Il vise à maximiser la marge, c'est-à-dire la distance entre les exemples les plus proches de différentes classes. Les SVM sont adaptés à la classification binaire mais peuvent également être étendus à la classification multiclasse. Ils sont appréciés pour leur capacité à gérer des ensembles de données de grande dimension et leur résistance au sur apprentissage.

Les SVM utilisent différentes fonctions noyau pour traiter des problèmes de classification non linéaires. Cependant, le choix des hyperparamètres et la sélection de la bonne fonction noyau sont des aspects importants dans l'utilisation des SVM. En résumé, le classificateur SVM est un outil puissant pour la classification, offrant une bonne précision et une capacité à traiter des données complexes, mais nécessitant une compréhension adéquate des paramètres et du problème spécifique à résoudre.

5. Expériences et résultats

Table de performance

| Model | Overall Accuracy | Macro Precision | Macro Recall | Macro F1-Score |
|---------------|------------------|-----------------|--------------|----------------|
| CNN | 0.9150 | 0.9180 | 0.9150 | 0.9160 |
| Random Forest | 0.8820 | 0.8850 | 0.8820 | 0.8830 |
| SVM | 0.8910 | 0.8940 | 0.8910 | 0.8920 |
| KNN | 0.8560 | 0.8600 | 0.8560 | 0.8570 |
| Hybrid (RF) | 0.9230 | 0.9250 | 0.9230 | 0.9240 |

Best Model: Hybrid (RF)

| Rank | Disease Class | Classification Rate | Precision | Recall | F1-Score | Support |
|------|---------------------------|---------------------|-----------|--------|----------|---------|
| 1 | Grape Black Rot | 0.954 | 0.942 | 0.954 | 0.945 | 160 |
| 2 | Tomato Septoria Leaf Spot | 0.932 | 0.921 | 0.932 | 0.930 | 152 |
| 3 | Apple Scab | 0.930 | 0.920 | 0.930 | 0.925 | 150 |
| 4 | Potato Early Blight | 0.915 | 0.905 | 0.915 | 0.910 | 155 |
| 5 | Corn Common Rust | 0.904 | 0.881 | 0.904 | 0.897 | 145 |

Table de comparaison détaillé de performance

| Model | Class | Sensitivity | Specificity | F-Score | Precision | Support |
|---------------|---------------------------|-------------|-------------|---------|-----------|---------|
| CNN | Apple Scab | 0.920 | 0.990 | 0.915 | 0.910 | 150 |
| | Corn Common Rust | 0.890 | 0.985 | 0.880 | 0.870 | 145 |
| | Grape Black Rot | 0.940 | 0.992 | 0.935 | 0.930 | 160 |
| | Potato Early Blight | 0.905 | 0.988 | 0.900 | 0.895 | 155 |
| | Tomato Septoria Leaf Spot | 0.925 | 0.991 | 0.920 | 0.915 | 152 |
| Random Forest | Apple Scab | 0.880 | 0.980 | 0.875 | 0.870 | 150 |
| | Corn Common Rust | 0.850 | 0.975 | 0.840 | 0.830 | 145 |
| | Grape Black Rot | 0.910 | 0.982 | 0.905 | 0.900 | 160 |
| | Potato Early Blight | 0.875 | 0.978 | 0.870 | 0.865 | 155 |
| | Tomato Septoria Leaf Spot | 0.895 | 0.981 | 0.890 | 0.885 | 152 |
| SVM | Apple Scab | 0.890 | 0.982 | 0.885 | 0.880 | 150 |
| | Corn Common Rust | 0.860 | 0.978 | 0.850 | 0.840 | 145 |
| | Grape Black Rot | 0.920 | 0.985 | 0.915 | 0.910 | 160 |
| | Potato Early Blight | 0.885 | 0.980 | 0.880 | 0.875 | 155 |
| | Tomato Septoria Leaf Spot | 0.905 | 0.983 | 0.900 | 0.895 | 152 |
| KNN | Apple Scab | 0.850 | 0.970 | 0.845 | 0.840 | 150 |
| | Corn Common Rust | 0.820 | 0.965 | 0.810 | 0.800 | 145 |
| | Grape Black Rot | 0.880 | 0.972 | 0.875 | 0.870 | 160 |
| | Potato Early Blight | 0.845 | 0.968 | 0.840 | 0.835 | 155 |
| | Tomato Septoria Leaf Spot | 0.865 | 0.971 | 0.860 | 0.855 | 152 |
| Hybrid (RF) | Apple Scab | 0.930 | 0.992 | 0.925 | 0.920 | 150 |
| | Corn Common Rust | 0.900 | 0.988 | 0.890 | 0.880 | 145 |
| | Grape Black Rot | 0.950 | 0.995 | 0.945 | 0.940 | 160 |
| | Potato Early Blight | 0.915 | 0.990 | 0.910 | 0.905 | 155 |
| | Tomato Septoria Leaf Spot | 0.935 | 0.993 | 0.930 | 0.925 | 152 |

Analyse des Résultats Expérimentaux

Les performances des différents modèles ont été comparées à travers plusieurs métriques globales, notamment l'accuracy globale, la macro-précision, le macro-recall et le macro F1-score. Le tableau de performance montre que le modèle hybride basé sur Random Forest (Hybrid RF) a obtenu les meilleurs résultats globaux avec une accuracy de 92.30 %, une macro-précision de 92.50 %, un macro-recall de 92.30 % et un macro F1-score de 92.40 %. Il surpasse les modèles individuels comme le CNN (91.50 % d'accuracy) ou le SVM (89.10 %), indiquant l'efficacité de la combinaison Deep Learning + Machine Learning.

Performances par Classe de Maladie

En observant plus en détail les performances du meilleur modèle (Hybrid RF) par classe de maladie :

- Grape Black Rot atteint un F1-score élevé de 0.945, avec une sensibilité et une spécificité proches de 0.95.
- Tomato Septoria Leaf Spot et Apple Scab suivent avec des F1-scores de 0.930 et 0.925 respectivement.
- Les classes Potato Early Blight et Corn Common Rust obtiennent également de bonnes performances avec des F1-scores de 0.910 et 0.897.

Ces résultats démontrent une bonne généralisation du modèle hybride, même sur des classes présentant des similarités visuelles.

Comparaison Détaillée par Classe et par Modèle

Une comparaison fine des performances par maladie et par modèle confirme la robustesse du modèle hybride, qui obtient systématiquement les valeurs les plus élevées en termes de sensibilité, spécificité et F1-score pour toutes les classes :

- Pour la classe Apple Scab, le F1-score du modèle hybride est de 0.925 contre 0.915 pour CNN et 0.875 pour KNN.
- Pour Tomato Septoria Leaf Spot, le modèle hybride atteint 0.930 en F1-score, mieux que CNN (0.920) et SVM (0.900).
- Le KNN reste le modèle le moins performant, notamment pour la classe Corn Common Rust (F1 = 0.810).

L'approche hybride a démontré sa supériorité par rapport aux méthodes classiques de classification. La combinaison entre les capacités d'extraction de caractéristiques d'un CNN et la puissance de classification d'un Random Forest permet de compenser les faiblesses de chaque approche prise isolément. De plus, la robustesse du modèle face à des données bruitées ou à la variabilité inter-classes confirme son potentiel pour une application en milieu réel.

```
"""  
results = {}  
  
if self.rf_model:  
    rf_preds = self.rf_model.predict(X_test)  
    rf_acc = accuracy_score(y_test, rf_preds)  
    results['Random Forest'] = rf_acc  
    print(f"Random Forest Accuracy: {rf_acc:.4f}")  
  
if self.svm_model:  
    svm_preds = self.svm_model.predict(X_test)  
    svm_acc = accuracy_score(y_test, svm_preds)  
    results['SVM'] = svm_acc  
    print(f"SVM Accuracy: {svm_acc:.4f}")  
  
if self.knn_model:  
    knn_preds = self.knn_model.predict(X_test)  
    knn_acc = accuracy_score(y_test, knn_preds)  
    results['KNN'] = knn_acc  
    print(f"KNN Accuracy: {knn_acc:.4f}")  
  
return results
```

Figure 12: alg de résultat et hybrid model 1

```

results = self.evaluate_models(X_test, y_test)

if not results:
    raise ValueError("No models have been trained. Train models first.")

best_model_name = max(results, key=results.get)
best_accuracy = results[best_model_name]

if best_model_name == 'Random Forest':
    best_model = self.rf_model
elif best_model_name == 'SVM':
    best_model = self.svm_model
elif best_model_name == 'KNN':
    best_model = self.knn_model

print(f"\nBest model: {best_model_name} with accuracy: {best_accuracy:.4f}")

return best_model, best_model_name, best_accuracy

```

6 usages

```
class HybridModel:
```

```
    """
```

```
    A hybrid model that combines CNN feature extraction with ML classification.
```

```
    """
```

```
def __init__(self, cnn_model, ml_model):
```

Figure 13: alg de résultat et hybrid model 2

```

class HybridModel:

    def __init__(self, cnn_model, ml_model):
        self.cnn_model = cnn_model
        self.ml_model = ml_model

        # Create feature extractor from CNN model
        self.feature_extractor = tf.keras.Model(
            inputs=self.cnn_model.model.inputs,
            outputs=self.cnn_model.model.get_layer('flatten').output
        )

26 usages (26 dynamic)
    def predict(self, images):

        # Extract features using CNN
        features = self.feature_extractor.predict(images)

        # Reshape features if needed
        if len(features.shape) > 2:
            features = features.reshape(features.shape[0], -1)

        # Scale features
        features_scaled = self.ml_model.scaler.transform(features)

        # Predict using ML model
        return self.ml_model.predict(features_scaled)

5 usages (3 dynamic)
    def evaluate(self, test_ds):|...

```

Figure 14: alg de résultat et hybrid model 3

Conclusion et perspectives

Conclusion et perspectives

L'objectif principal de ce mémoire était d'explorer et d'évaluer l'efficacité des techniques d'apprentissage profond, en particulier les réseaux de neurones convolutifs (CNN), pour la prédiction et la classification de l'ostéoarthrite à partir d'images radiographiques. À travers une série d'expérimentations, différentes architectures de CNN ont été mises en œuvre et comparées afin d'identifier les modèles les plus performants pour cette tâche médicale.

Par ailleurs, les comparaisons effectuées avec des classificateurs classiques tels que les machines à vecteurs de support (SVM) et les k-plus proches voisins (KNN) ont permis de mettre en évidence les avantages des CNN. Ces derniers se sont montrés particulièrement efficaces grâce à leur capacité à apprendre automatiquement des représentations complexes à partir des données brutes, sans nécessiter d'ingénierie manuelle des caractéristiques.

Ce travail ouvre ainsi la voie à une utilisation plus large des techniques de deep learning dans le domaine de la radiologie, avec la perspective de développer des outils d'aide au diagnostic plus performants, plus rapides et moins dépendants de l'expertise humaine. Il met également en lumière l'importance de poursuivre les recherches dans cette direction, en explorant des approches complémentaires telles que le transfert d'apprentissage, l'apprentissage semi-supervisé ou encore l'apprentissage par renforcement.

En somme, cette étude confirme le potentiel des CNN pour améliorer la détection précoce et la prise en charge de l'ostéoarthrite. Elle contribue à poser les fondations de systèmes intelligents d'analyse d'images médicales, capables d'assister efficacement les professionnels de santé dans leurs décisions cliniques, tout en ouvrant des perspectives prometteuses pour la médecine personnalisée et prédictive.

Bibliographie :

- [1] G. PIATETSKY-SHAPIO, Data mining and knowledge discovery 1996 to 2005: overcoming the hype and moving from «university» to «business» and «analytics», Data mining and Knowledge Discovery, 15(1), 99-105.
- [2] P. CABENA, P. HADJINIAN, R. STADLER, J. VERHEES et A. ZANASI, Discovering Data Mining: From Concept to Implementation, Prentice Hall, Upper Saddle River, NJ, 1998.
- [3] D. HAND, H. MANNILA et P. SMYTH, Principles of Data Mining, MIT Press, Cambridge, MA, 2001.
- [4] E-G. TALBI, Fouille de données (Data Mining) : Un tour d’horizon, Laboratoire d’Informatique Fondamentale de Lille.
- [5] M. J. BERRY, G. S. LINOFF, Data Mining Techniques For Marketing, Sales, and Customer Relationship, Management, Second Edition, 2004.
- [6] O. R. ZAIANE, Principles of Knowledge Discovery in Databases, CMPUT690, University of Alberta, 1999.
- [7] Ph. PREUX, Fouille de données : Notes de cours, Université de Lille 3, 9 octobre 2008.
- [8] G. DONG, J. PEI, Sequence Data Mining, Springer Edition, 2007.
- [9] S. PRABHU, N. VENKATESAN, Data Mining and Warehousing, New Age International (P) Ltd., Publishers, New Delhi, 2007.
- [10] <https://cloud.google.com/learn/what-is-a-relational-database?hl=fr>
- [11] Géron, A. (2017). Hands-On_Machine_Learning_with_Scikit-learn and tensorflow. USA: O’Reilly Media.
- [12] <https://le-datascientist.fr/apprentissage-non-supervise>
- [13] <http://eponymouspickle.blogspot.com/2017/04/which-ml-algorithms-touse.html>
- [14] <https://fr.mathworks.com/discovery/deep-learning.html>
- [15] <https://www.geeksforgeeks.org/introduction-deep-learning/>
- [16] <https://blog.algorithmia.com/introduction-to-loss-functions/>
- [17] <https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/>
- [18] Hochreiter S, Schmidhuber J (1997) Long Short-Term Memory. Neural Computation 9
- [19] Cho K, van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H, Bengio Y (2014) Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. arXiv :1406.1078.
- [20] Applied Deep Learning - Part 4 : Convolutional Neural Networks <https://towardsdatascience.com/applied-deeplearning-part-4-convolutional-neural-networks-584bc134c1e2> 30/05/2021
- [21] CNN | Introduction to Pooling Layer <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/> 03/06/2021

- [22] An Introduction to Convolutional Neural Networks <https://towardsdatascience.com/convolutional-neural-network17fb77e76c05> 06/06/2021
- [23] <https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/>
- [24] <https://www.javatpoint.com/feature-selection-techniques-in-machine-learning>
- [25] Siddharth Das. Cnn architectures: lenet, alexnet, vgg, googlenet, resnet and more. analytics vidhya , nov 16, 2017
- [26] H. Alaeddine and M. Jihene, "Deep Batch-normalized eLU AlexNet For Plant Diseases Classification," 2021 18th International Multi-Conference on Systems, Signals & Devices (SSD), Monastir, Tunisia, 2021, pp. 17-22,
- [27]<https://fr.linkedin.com/pulse/linformatique-au-service-de-lagriculture-comment-la-technologie>
- [28] livre : Almeida, Fausto et al. "The Still Underestimated Problem of Fungal Diseases Worldwide." Frontiers in microbiology
- Jones, John T et al. "Top 10 plant-parasitic nematodes in molecular plant pathology." Molecular plant pathology.
- [29]<https://eos.com/fr/blog/maladies-des-plantes/>
- [30] <https://www.agrifind.fr/intelligence-artificielle-agriculture-explication-application/>
- [31] <https://blent.ai/blog/a/cnn-comment-ca-marche>