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

UNIVERSITE YAHIA FARES DE MEDEA

Faculté de **T**echnologie

Département du **G**énie **E**lectrique

Mémoire de fin d'études de Master en

Filière : télécommunications

Spécialité : systèmes de télécommunications

Classification des images satellitaires en utilisant l'application « Classification Learner »

Présenté par :

CHABANE Abderraouf

BOUDJEMAA Aicha

Proposé et Dirigé par :

Dr. REBIAI Mohamed

Promotion 2022-2023

Remerciements

Nous tenons à remercier dieu le tout puissant qui nous a donné la santé et la persévérance pour accomplir ce projet.

De plus, ce travail n'aurait pas été aussi riche et n'aurait pas vu le jour sans l'aide et l'encadrement de Dr. Rebiai Mohamed. Nous le remercions pour sa guidance, son patience, son expertise et sa disponibilité tout au long de notre projet.

Également, nous sommes empreints d'une profonde reconnaissance envers les enseignants qui ont été des guides remarquables tout au long de notre parcours académique, particulièrement envers les enseignants du département de télécommunications pour leur dévouement et leur engagement envers notre réussite.

Pour terminer, nous aimerions remercier chaleureusement nos parents pour leur amour inconditionnel.

Nous ne serions pas là où nous en sommes aujourd'hui sans leur aide et leurs encouragements.

Dédicaces

J’ai l’immense honneur de dédier ce projet de fin d’études :

A ma mère KHEIRA, A celle qui a tout souffert, sans me faire souffrir, Qu’elle trouve dans ce mémoire le témoignage de ma reconnaissance et de mon affection pour tous les sacrifices, l’extrême amour et la bonté, Qu’elle m’a offert pour me voir réussir.

A mon père LAMRAOUI, A l’homme à qui je dois ma réussite, mon bonheur, et tout le respect ; Qu’il trouve ici l’expression de mon affection et une récompense des sacrifices consentis pour moi.

Je dédie ce travail aussi à mon très chère frère SALIM et mes très chères sœurs ASMA, KHAWLA.

J'exprime ma gratitude à ma chère grand-mère SAADIA pour ses prières pour moi.

A mes oncles CHAABANE, KWIDER et mes t’antes FATIHA, NAWAL.

A ma meilleure Binôme.

A mes amis YOUSSOUF, NACER, YOUCEF, MOUNIR, MOKHTAR, ANIS et ABDERRAHMANE.

A mes collègues étudiants de ma promotion 2023.

Sans oublier tous mes enseignants qui ont contribué à ma formation depuis le primaire à ce jour.

Abderraouf

Dédicace

Je dédie ces mots exprimant mon amour et ma reconnaissance envers ma mère chérie.

Merci à elle pour tous les sacrifices. Je souhaite exprimer ma gratitude envers mes frères et surtout envers ma petite sœur gâtée, MANEL, de m'avoir encouragée.

De plus, je rends hommage à mon père décédé pour l'impact des leçons de vie qu'il m'a apprises.

Pareillement, je remercie mon binôme pour son sérieux. Sa contribution a été inestimable et j'ai de la chance de travailler avec une personne aussi remarquable.

Enfin, mes remerciements s'adressent à mon meilleur ami, LOKMAN ,BK

Merci infiniment à tous pour votre soutien."

Aicha

ملخص

في عصر الذكاء الاصطناعي، يجلب التحليل عن بُعد وخاصة التصوير الفضائي اهتمامًا واسعًا في مجتمع علوم الحاسوب، في سعيها لمنح الآلات القدرة على التعرف على بيئتها من خلال تصنيف الصور الفضائية. تقدم محطة الأقمار الاصطناعية صورًا للأرض يتم جمعها وتحليلها ومعالجتها لأغراض مدنية وعسكرية. تطبيق"classification learner" هو أداة تفاعلية متاحة في Matlab لأداء مهام التعلم مثل استكشاف البيانات واستخراج السمات وتدريب وتحقق النماذج أو تقييم النتائج، يختار المستخدم الخوارزمية المطلوبة، ويضبط المعلمات حسب الحاجة، ويبدأ عملية تدريب النموذج. توفر أداة تصنيف المتعلم التفاعلي Matlab حلولًا لأداء مهام التعلم المختلفة مثل استكشاف البيانات واستخراج الميزات والتدريب النموذجي والتحقق من الصحة وتقييم النتائج.

يهدف هذا المشروع إلى تطبيق تقنية التعلم الآلي الخاصة بـ Classifier Learner لتصنيف صور الأقمار الصناعية. الميزات المستخرجة من الصور بسيطة جدًا مثل(RMS (Root Mean Square ، kurtosis ،.... إلخ بعد ذلك ، تم اختبار العديد من خوارزميات التصنيف ، بما في ذلك الجيران الأقرب لـ k ، وشجرة القرار ، و SVM (Machine A Vecteurs de Support) ، وما إلى ذلك. تمت مقارنة أداء كل خوارزمية لتحديد أفضل خيار لتصنيف صور الأقمار الصناعية. أظهرت النتائج أن Classifier Learner هي أداة فعالة لمقارنة عدة طرق لتصنيف صور الأقمار الصناعية ، وفي حالتنا تصل دقة التصنيف إلى 96.2٪ لبعض الطرق.

الكلمات المفتاحية: تصنيف الصور ، الاستشعار عن بعد ، المصنف المتعلم ، التعلم الآلي ، استخراج الميزات ، صور الأقمار الصناعية.

Abstract

In the era of artificial intelligence, the IT community shows a growing interest in remote detection, especially satellite imaging, with the aim of enabling machines to recognize their environment through the classification of satellite images. Imaging satellites capture images of the Earth, which are then collected, analyzed and processed for civilian and military purposes. In this perspective, the user selects the desired algorithm, adjusts the parameters as needed, and starts the model training process. Matlab interactive “learner classification” tool offers a solution for carrying out a variety of learning tasks, such as data exploration, characteristic extraction, model training and validation, as well as evaluation of results.

This project aims to apply the machine learning technique of Classifier Learner to classify satellite images. The features extracted from the images are very simple such as RMS (Root Mean Square), kurtosis, …. etc Then, several classification algorithms were tested, including k-nearest

neighbors, decision tree, SVM (Machine A Vecteurs de Support), etc. The performances of each algorithm were compared to determine the best choice for the classification of satellite images. The results showed that Classifier Learner is an efficient tool to compare several satellite image classification methods, in our case the classification accuracy reaches 96.2% for some methods.

Keywords: Image classification, remote sensing, Classifier Learner, machine learning, feature extraction, satellite images.

Résumé

À l'ère de l'intelligence artificielle, la communauté informatique montre un intérêt croissant pour la télédétection, en particulier l'imagerie satellitaire, dans le but de permettre aux machines de reconnaître leur environnement par le biais de la classification des images satellites. Les satellites d'imagerie capturent des images de la Terre, qui sont ensuite collectées, analysées et traitées à des fins civiles et militaires. Dans cette optique, l'outil interactif "classification learner" de Matlab offre une solution pour réaliser diverses tâches d'apprentissage, telles que l'exploration des données, l'extraction de caractéristiques, la formation et la validation de modèles, ainsi que l'évaluation des résultats.

Ce projet a pour but d'appliquer la technique d'apprentissage machine de Classifier Learner pour classifier les images satellitaires. Les caractéristiques extraites des images sont très simples telles que RMS (Root Mean Square), kurtosis, …. etc. Ensuite, plusieurs algorithmes de classification ont été testés, notamment le k-plus proches voisins, l'arbre de décision, la SVM (Machine A Vecteurs de Support) …etc. Les performances de chaque algorithme ont été comparées pour déterminer le meilleur choix pour la classification des images satellitaires. Les résultats ont montré que Classifier Learner est un outil efficace pour comparer plusieurs méthodes de classification des images satellitaires, dans notre cas la précision de classification atteint 96.2% pour certaines méthodes.

Mots-clés : Classification d'images, télédétection, Classifier Learner, apprentissage machine, extraction des caractéristiques, images satellites.

.

Table des Matières

Résumé V
Liste des figures VIII
Liste des tableaux XI
Liste des Abréviations XII
Introduction Générale 1
I. Chapitre I : Généralité sur les images et les satellites 3
I.1 Introduction 3
I.2 Historique 3
I.3 Définition de traitement d'images 4
I.4 Numérisation de l'image 4
I.4.1 Définition d'une d'image numérique 4
I.4.2 L'échantillonnage et la quantification 5
I.5 Codification d'une image numérique 6
I.5.1 Images en noir et blanc (monochromes) 6
I.5.2 Images binaires 6
I.5.3 Images à niveaux de gris 6
I.5.4 Images en couleurs (Polychromes) 7
I.6 Caractéristique d'une image 7
I.6.1 Pixel 8
I.6.2 La résolution 8
I.6.3 Dimensions 8
I.6.4 La texture 8
I.6.5 Bruit 9
I.6.6 Contours 9
I.6.7 La luminance 9
I.6.8 Histogramme d'une image 10
I.6.9 Régions 10
I.6.10 Le contraste 10
I.7 Système de traitement d'image 11
I.7.1 Acquisition et numérisation 11
I.7.2 Visualisation 11
I.7.3 Traitement numérique des images 12
I.7.3.1 Filtrage Numérique 12
I.7.3.1.1 Filtres linéaires 12
I.7.3.1.2 Filtres non linéaires 13
I.8 Domaines d'application de traitement d'image 14
I.9 Généralités sur le satellite 15
I.9.1 Définition d'un satellite 15
I.9.2 Architecture d'un satellite : 15
I.9.3 Différentes vitesses de satellisation : 16
I.9.4 Orbite de satellites : 16
I.9.5 Caractéristiques principales des systèmes satellitaires 17
I.10 Les satellites de télédétection 18
I.10.1 Définitions 18
I.10.2 Principe physique de la Télédétection 19

I.10.3 Spectre électromagnétique 20
I.10.4 Source de l'énergie électromagnétique 22
I.10.5 Perturbations atmosphériques 23
I.11 Images satellitaires 24
I.11.1 La résolution des images satellitaires 25
I.11.2 La résolution spectrale 25
I.11.3 La résolution spatiale 25
I.11.4 La résolution temporelle 25
I.11.5 La résolution radiométrique 25
I.12 Conclusion 26
Chapitre II : L'apprentissage automatique et l'intelligence artificiel 27
II.1 Introduction 27
II.2 Les méthodes de classification 28
II.2.1 L'apprentissage automatique (Maching learning) 28
II.2.1.1 Algorithmes de Machine Learning 28
II.2.1.1.1 K-means 29
II.2.1.1.2 Les machines à support de vecteurs (SVM) 30
II.2.1.1.3 Les réseaux de neurones (Neural network) 32
II.2.1.2 Application de machine Learning 35
II.2.2 Deep Learning 36
II.2.2.1 Modèles du Deep Learning 37
II.2.2.1.1 Convolutional Neural Network (CNN) (réseaux de neurones convolutifs) : 37
II.2.2.1.2 Réseaux Neuronaux Récurrents (RNN) : 40
II.3 Conclusion : 41
Chapitre III : Classification des images et interprétation des résultats 42
III.1 Introduction 42
III.2 Bases de données 42
III.3 Les logiciels utilisés 43
III.3.1 Matlab 43
III.3.2 Matlab classification learner 44
III.4 Préparation de la base de données 45
III.4.1 Lire les images 46
III.4.2 Extraction des caractéristiques 47
III.4.3 Sauvegarde 49
III.4.4 Segmentations de la base des données 49
III.5 Classifications les images 51
III.5.1 Les étapes pour classifier les données par Classifier Learner 51
III.5.2 Les modèles utilisés 57
III.6 Les résultats obtenus 58
III.6.1 Précision 58
III.6.2 Matrice de Confusion 60
III.6.3 La courbe ROC (Receiver Operating Characteristic) 63
III.7 Améliorations d'un modèle 64
III.8 Comparaison 66
III.9 Conclusion 67
Conclusion Général 78
Bibliographie 69

Liste des figures

Figure I-1 : Représentation d'image numérique 4
Figure I-2 : quantifications d'une image..... 5
Figure I-3 : Exemple d'image utilisant une quantification de 1 bit/composante primaire. 5
Figure I-4 : Image binaire..... 6
Figure I-5 : Image Monochrome. 7
Figure I-6 : Image polychrome (65536 couleurs). 7
Figure I-7 : Exemple d'image 12x12 pixels..... 8
Figure I-8 : (A) Image sans bruit. (B) Image avec bruit. 9
Figure I-9 : Contour d'une image..... 9
Figure I-10 : Image avec histogramme. 10
Figure I-11 : Schéma d'un système de traitement d'images. 11
Figure I-12 : Filtre médian. 13
Figure I-13 : Filtre maximum..... 14
Figure I-14 : Filtre minimum. 14
Figure I-15 : l'architecteur de satellites. 16
Figure I-16 : Principe physique de la télédétection..... 19
Figure I-17 : Onde électromagnétique. 21
Figure I-18 : Spectre électromagnétique. 21
Figure I-19 : Distribution spectrale de l'énergie émise par un corps noir à des différentes températures..... 23
Figure I-20 : Rayonnement solaire et influence de l'atmosphère. 24

Figure II-1 : La relation entre l'intelligence artificielle, le Learning ML et le deep. 28
Figure II-2 : Problème de classification à deux classes avec un séparateur linéaire [6]..... 31
Figure II-3 : Problème de classification à deux classes avec un séparateur non linéaire [6]..... 31
Figure II-4 : Neurone artificiel avec une seule sortie..... 32
Figure II-5 : Le réseau de neurones à un seul niveau..... 33
Figure II-6 : Le réseau de neurones multi-niveaux 34

Figure II-7 : La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données. 37
Figure II-8 : les couches Convolutional Neural Network (CNN). 38
Figure II-9 : Exemple explicative sur l'opération de convolution. 38
Figure II-10 : Exemple d'une convolution 2D. 39
Figure II-11 : a) Pooling Moyne, b) Pooling maximal. 39
Figure II-12 : Couche fully-connected. 40
Figure II-13 : Architecteur de RNN. 40

Figure III-1 : quelques images pour les quatre fichiers. 43
Figure III-2 : capture d'écran montre l'application classificatin learner 45
Figure III-3 : capteur d'écran montre le chemin d'accès et le format des images d'un programme MATLAB. 46
Figure III-4 : capture d'écran montrant une boucle qui lit les fichiers d'images. 46
Figure III-5 : La séparation des matrices rouge vert et bleu. 47
Figure III-6 : organigramme expliqué la séparation matrices. 47
Figure III-7 : capture d'écran d'un programme Matlab qui calculé la moyenne. 48
Figure III-8 : Extraction des caractéristiques. 48
Figure III-9 : Sauvegarde les tableaux des caractéristiques dans un fichier Excel. 49
Figure III-10 : capteur d'écran représente un exemple d'un data. 49
Figure III-11 : Segmentations de la base de données. 50
Figure III-12 : Organigramme résumé les étapes de préparation de la base de données. 50
Figure III-13 : l'ouverture de classification learner. 51
Figure III-14 : les figures (a) (b) et (c) représente les étapes d'Importation des données. 51
Figure III-15 : Choix le modèle d'apprentissage. 52
Figure III-16 : Galerie des modèles de classification disponibles. 52
Figure III-17 : l'entrainement de tous les modèles. 53
Figure III-18 : validation Accuracy of training. 53
Figure III-19 : Scatter plot affichiez distribution des données après l'entrainement. 53
Figure III-20 : Matrice de confusion de l'entrainement 54
Figure III-21 : ROC graphe de l'entrainement. 54
Figure III-22 : Capture d'écran représente comment importer les données de test. 54
Figure III-23 : Capture d'écran représente les données de test. 55
Figure III-24 : Capture d'écran de lancement test de données par l'application CL. 55
Figure III-25 : Capture d'écran de « testing Accuracy of training ». 55
Figure III-26 : Capture d'écran d'une matrice de confusion de test. 56
Figure III-27 : ROC graphe de l'entrainement. 56
Figure III-28 : matrice de confusion de moyenne data type de modèle Fine Gaussian SVM. 61

Figure III-29 : matrice de confusion de (M SK K) data type de modèle Trilayered Neural Network. 61
Figure III-30 : matrice de confusion de (RMS SK K) data type de modèle Narrow Neural Network. 61
Figure III-31 : matrice de confusion de (M RMS K) data type de modèle Boosted Trees..... 61
Figure III-32 : deux images de cloud et deux desert..... 62
Figure III-33 : deux images de green_area et deux water..... 62
Figure III-34 : ROC graph de moyenne data de modèle Fine Gaussian SVM. 63
Figure III-35 : ROC graph de(M,SK, K) data type de modèle Trilayered Neural Network..... 63
Figure III-36 : ROC graph de (RMS SK K) data type de modèle Narrow Neural Network. 64
Figure III-37 : ROC graph de (M RMS K) data type de modèle Boosted Trees..... 64
Figure III-38 : les paramètres du model-« Wide Neural Network ». 65
Figure III-39 : (a) Représente les paramètres de model avant la modification et (b) après la modification..... 65

Liste des tableaux

Tableau III-1 : description de base de données. 43
Tableau III-2 : les équations des paramètres. 48
Tableau III-3 : Les modèles de classification dans l'application CL. 57
Tableau III-4 : Les résultats de précision de 10 premiers modelés (caractéristique : Moyenne M). 58
Tableau III-5 : Les résultats de précision de 10 premiers modelés (caractéristiques : Moyenne M, Skewness Sk et Kurtosis K). 59
Tableau III-6 : Les résultats de précision de 10 premiers modelés (caractéristiques : RMS, Skewness Sk et Kurtosis K). 59
Tableau III-7 : Les résultats de précision de 10 premiers modelés (caractéristiques : Moyenne M, RMS et Kurtosis K). 60
Tableau III-8 : Les résultats du meilleur modèle « Wide Neural Network ». 64
Tableau III-9 : les meilleurs modèles obtenus. 66

Liste des Abréviations

AUC : Area Under the Curve.

CL : Classification Learner.

CNN : Convolutional Neural Network.

DL : Deep learnig.

EMR : Energies Marines Renouvelables.

FPR : Taux de Faux Positifs.

GEO : Geostationary Earth Orbit.

GTO : Geostationary Transfer Orbit.

IA : Intelligence Artificielle.

IR : Infra-Rouge.

IRM : L'imagerie par Résonance Magnétique.

K : Kurtosis.

K-NN : (K-Nearest Neighbors),

LEO : Low Earth Orbit.

M : Moyenne.

MEO : Medium Earth Orbit.

ML : Machine learning.

REM : Rapid Eye Movement.

RMS : Root Mean Square.

RNN : Réseaux Neuronaux Récurrents.

ROC : Receiver Operating Characteristic.

RVB : Rouge-Vert-Bleu.

SK : Skewne.

SVM : Machine A Vecteurs de Support.

TPR : Taux de Vrais Positifs.

Introduction générale

Introduction Générale

Les satellites sont des objets artificiels qui orbitent autour de la Terre ou d'autres corps célestes. Ils sont principalement utilisés à des fins de communication, d'observation de la Terre, de navigation et de recherche scientifique. Les satellites de télédétection sont une catégorie spécifique de satellites utilisés pour collecter des informations sur la surface de la Terre à l'aide de capteurs à distance. Les satellites de télédétection ont de nombreuses applications, notamment la cartographie, la surveillance environnementale, la gestion des ressources naturelles, la prévision météorologique, la surveillance des catastrophes naturelles, l'agriculture de précision, la gestion des forêts, la surveillance des zones côtières, etc.

Avec l'avènement de l'intelligence artificielle, la télédétection et l'imagerie satellitaire suscitent un intérêt croissant dans la communauté informatique pour donner aux machines la capacité de reconnaître leur environnement. Les satellites d'imagerie fournissent des images de la terre qui ont des applications civiles et militaires importantes.

L'objectif de notre projet est d'étudier et de classifier des images satellitaires de la base de données « Dataset-RSI-CB256 » en utilisant l'application « classification learner » du Matlab. L'application « classification learner » permet d'explorer les données, d'extraire des caractéristiques, de former et de valider des modèles, et d'évaluer les résultats, sans avoir besoin d'écrire des lignes de code. Cette application permet également de comparer facilement plusieurs modèles de formation et de générer automatiquement le code Matlab correspondant au modèle sélectionné.

Dans le premier chapitre, nous avons couvert des généralités sur les images numériques et les étapes de base de leur traitement, ainsi que sur les satellites, leurs types, le principe de leur fonctionnement et ce qu'est une image satellitaire.

Quant au deuxième chapitre, nous avons d'abord abordé une définition sur la machine Learning, ce qu'est l'apprentissage supervisé, qui représente un type de machine Learning, et le principe de classification des images, puis nous avons abordé les méthodes de classification d'images telles ques SMV, Neural network, k-mean, nous avons donc identifié ces méthodes, leur principe de fonctionnement et avantages et inconvénients dans la classification des images.

Quant au dernier chapitre, nous avons utilisé classifier Learning qui représente une application dans Matlab et nous avons également abordé la base de données que nous utilisons dans la classification qui est de quatre catégories qui sont l'eau, déserts, nuages et forêts. Et nous avons extrait les caractéristiques des images : kurtosis, skewness, RMS et le moyen, afin d'obtenir la meilleure façon de classer les images.

Chapitre I : Généralité sur les images et les satellites

I. Chapitre I : Généralité sur les images et les satellites

I.1 Introduction

Le traitement d'images est un domaine très vaste qui a connu, et qui connaît un développement important depuis quelques dizaines d'années.

On désigne par traitement d'images numériques l'ensemble des techniques permettant de modifier une image numérique afin d'améliorer ou d'en extraire des informations.

De ce fait, le traitement d'images est l'ensemble des méthodes et techniques opérant celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes.

Dans ce chapitre, nous abordons les notions de base nécessaire à la compréhension des techniques de traitement d'images.

I.2 Historique

Le traitement d'images commence à être étudié dans les années 1920 pour la transmission d'images par le câble sous-marin allant de New York à Londres. Harry G. Bartholomew et Maynard D. Macfarlane effectuent la première numérisation d'image avec compression de données pour envoyer des fax de de Londres à New York. Le temps de transfert passe ainsi de plus d'une semaine à moins de trois heures. Il n'y a pas vraiment d'évolution par la suite jusqu'à la période d'après-guerre [1].

En 1980, David Marr formalise le premier la détection de contours de manière précise. Au cours des années 1980, un véritable engouement se fait jour pour le traitement de l'image et surtout pour la compréhension de l'image par des systèmes experts. Les ambitions étaient beaucoup trop grandes, l'échec fut d'autant plus cuisant.

Les années 1990 voient l'amélioration constante des opérateurs. La recherche médicale devient un très gros demandeur en traitement d'images pour améliorer les diagnostics faits à partir des nombreuses techniques d'imagerie médicale, la technique reine étant l'IRM.

Les publicitaires, puis le grand public se familiarisent avec la retouche d'image grâce au logiciel Photoshop, et le traitement d'images dans un objectif esthétique se répand avec l'apparition d'autres logiciels dédiés (The Gimp, Paint Shop Pro).

Enfin, la décennie s'achève sur l'engouement pour les ondelettes et les images multimodales.

I.3 Définition de traitement d'images

Le traitement d'image est une opération qui commence avec une image et finit avec une autre ou bien une image corrigée. Cette opération ne doit être confondue avec l'analyse d'image qui débute sur une image et en extrait des résultats brefs, réduisant les données nécessaires pour stocker l'image originale comme un tableau des pixels. Le traitement produit habituellement une autre image aussi grande que l'originale mais dans laquelle les valeurs des pixels (intensité ou couleur) ont changé [2].

I.4 Numérisation de l'image

I.4.1 Définition d'une d'image numérique

L'image numérique est une image dont la surface est divisée en élément d'une taille fixe appelés cellules ou pixels, ayant chacune comme caractéristiques : le niveau de couleurs (ou de gris) prélevé et l'emplacement correspondant dans l'image réelle

La numérisation d'une image est la conversion de celle-ci de son état analogique en une image numérique représentée par une matrice bidimensionnelle de valeurs numériques $F(x, y)$.

x, y : Coordonnées cartésiennes d'un point de l'image.

$F(x, y)$: Niveau d'intensité.

Pour des raisons de commodité de représentation pour l'affichage et l'adressage, les données images sont généralement rangées sous forme de tableau I de n lignes et p colonnes où chaque élément représente un pixel de l'image et sa valeur est associée à un niveau de gris codé sur m bits (2m niveaux de gris, 0 = noir, 2m - 1 = blanc) [3].

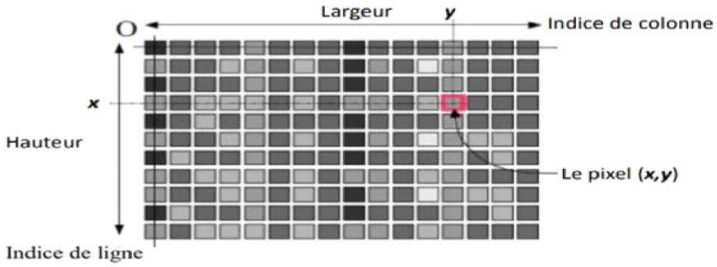


Figure I-1 : Représentation d'image numérique[3]

I.4.2 L'échantillonnage et la quantification

La quantification détermine la qualité de l'échantillonnage du signal. Celui-ci se mesure en nombre de bits par pixel de l'image. La précision du rendu colorimétrique de l'image dépend du nombre de niveaux du signal pouvant être codés pour chaque pixel.

Les valeurs les plus courantes sont 8 bits/pixel pour les images en niveaux de gris (256 niveaux de gris) et 24 bits/pixels, c'est à dire 8 bits par composantes primaires, pour les images en couleur (plus de 16 millions de couleurs distinctes).

Les images suivantes illustrent l'influence de la quantification (nombre de bits pour le codage de chaque composante primaire) sur la qualité de l'image. Par rapport à l'image originale codée sur 8 bits par composante, la dégradation est progressive jusqu'à atteindre une image qui est "monochrome" dans chacune des couleurs primaires (image retravaillée en contraste)



Figure I-2 : quantifications d'une image.[3]

Certaines techniques de tramage permettent d'augmenter artificiellement le nombre d'Il est possible d'utiliser, par exemple, un tramage de diffusion (régulier ou aléatoire) permettant de répartir les erreurs colorimétriques par rapport à l'image modèle sur des pixels adjacents [2].



Figure I-3 : Exemple d'image utilisant une quantification de 1 bit/composante primaire.[2]

I.5 Codification d'une image numérique

I.5.1 Images en noir et blanc (monochromes)

Ces images sont dites à niveaux de gris, car on ne prend pas en compte ici la couleur mais seulement l'intensité lumineuse (l'exemple classique correspond aux photographies noir et Blanc) parmi ces images on peut trouver :

I.5.2 Images binaires

Chaque pixel est représenté par un bit (0/1) avec en général (0) pour le noir, intensité nulle et (1) pour le blanc, intensité maximale). Notons que la plupart des systèmes de traitement d'images placeront chaque pixel dans un octet (code 0 ou 255 (pour coder le 1 de l'image binaire » pour des facilités d'accès et d'écriture des algorithmes [4].



Figure I-4 : Image binaire.[4]

I.5.3 Images à niveaux de gris

Le niveau de gris est la valeur de l'intensité lumineuse en un point. La couleur du pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaires. Donc pour représenter les images à niveaux de gris, on peut attribuer à chaque pixel de l'image une valeur correspondant à la quantité de lumière renvoyée. Cette valeur peut être comprise par exemple entre 0 et 255.

Chaque pixel n'est donc plus représenté par 1 bit, ais par 1 octet. Pour cela, il faut que le matériel utilisé pour afficher l'image, soit capable de produire les différents niveaux de gris correspondant. Le nombre de niveaux de gris dépend du nombre de bits utilisés pour décrire la " couleur " de chaque pixel de l'image. Plus ce nombre est important, plus les niveaux possibles sont nombreux [2].



Figure I-5 : Image Monochrome.[2]

I.5.4 Images en couleurs (Polychromes)

Elle est obtenue par la combinaison de trois couleurs dites primaires : Rouge, vert et bleu (RVB). Chaque couleur est codée comme une image à niveaux de gris, avec des valeurs allantes de 0 à 255. Pour R=V=B=0 nous auront un noir pur, et pour R=V=B=255 nous auront un blanc pur.

La représentation des images couleurs se fait donc soit par une image dont la valeur du pixel est une combinaison linéaire des valeurs des trois composantes couleurs, soit par trois images 6représentant chacune une composante couleur, on distingue généralement deux types d'images [2].



Figure I-6 : Image polychrome (65536 couleurs).[2]

I.6 Caractéristique d'une image

Comme nous l'avons vu, l'image est un ensemble structuré d'informations parmi ses Caractéristiques nous pouvons citer les paramètres suivants :

I.6.1 Pixel

Une image numérique est constituée d'un ensemble de points appelés pixels (abréviation De Picture Elément) pour former une image. Le pixel représente ainsi le plus petit élément Constitutif d'une image numérique. L'ensemble de ces pixels est contenu dans un tableau à deux dimensions constituantes l'image [5].

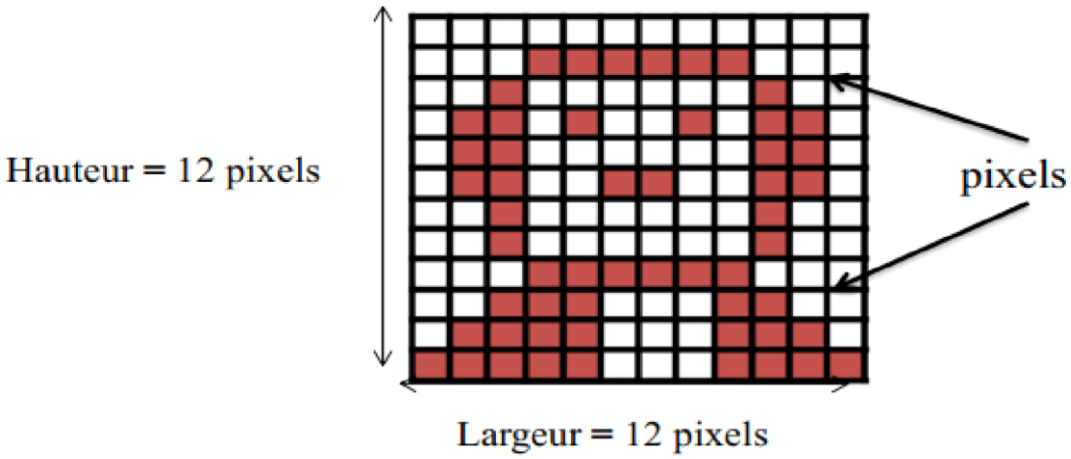


Figure I-7 : Exemple d'image 12x12 pixels.[5]

I.6.2 La résolution

La résolution est définie par un nombre de pixels par unité de longueur de l'image à Numériser en dpi (dots per inch) ou ppp (points par pouce).

On parle de définition pour un écran et de résolution pour une image. Plus le nombre de pixels est élevé par unité de longueur, plus la quantité d'informations qui décrit l'image est importante et plus la qualité est meilleure (mais plus le poids de l'image est élevé) [6].

I.6.3 Dimensions

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multipliée par le nombre de colonnes nous donne le nombre total de pixels dans une image [2].

I.6.4 La texture

Une texture est une région dans une image numérique qui a des caractéristiques homogènes. Ces caractéristiques sont par exemple un motif basique qui se répète .la texture est composée de Texel, l'équivalent des pixels [3].

I.6.5 Bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs de optiques et électroniques du capteur [4].



(A) (B)

Figure I-8 : (A) Image sans bruit. (B) Image avec bruit.[4]

I.6.6 Contours

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux Pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes [2].



Figure I-9 : Contour d'une image.[2]

I.6.7 La luminance

C'est le degré de luminosités des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente C'est le degré de luminosité de cette surface, le mot Luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet. Une bonne luminance se caractérise par :

- Des images lumineuses (brillantes)
- Un bon contraste : il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir : ces images entraînent des pertes de détails dans les zones sombres ou lumineuses.
- L'absence de parasites [6].

I.6.8 Histogramme d'une image

Un histogramme (traitement statistique de l'image) représente la fréquence des valeurs d'intensité des pixels dans une image. Ce concept peut être explique en considérant une image comme celle montrée dans la figure 1.6 un histogramme h pour une image I des niveaux de gris avec les valeurs d'intensité I (u, v) ϵ (0, K – 1) contient exactement k entrées.

Pour une Image de 256 niveaux de gris (k =28 =256), chaque entrée de l'histogramme est définie :

- Pour $0 \leq i < k$:

$$H(i) = card\{(u,v)/I(u,v)\} = i \qquad \text{(I-1)}$$

Le nombre de pixels dans l'image I avec la valeur d'intensité i [4].

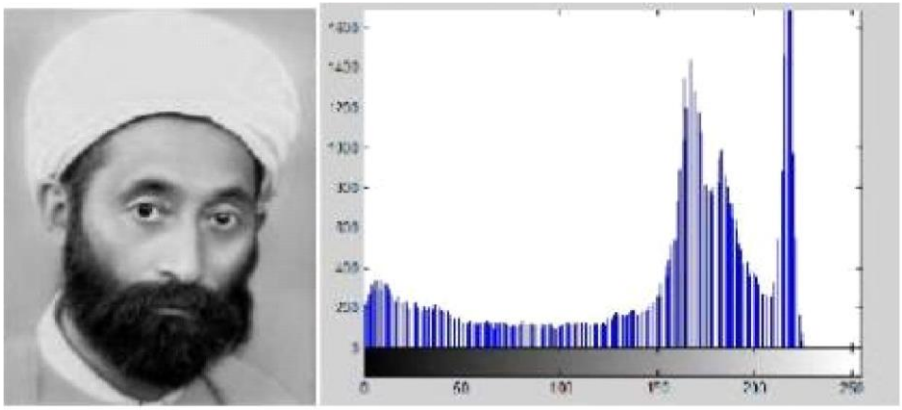


Figure I-10 : Image avec histogramme.[4]

I.6.9 Régions

Groupe de pixel présentant des caractéristiques similaires (intensité, mouvement, etc…)

I.6.10 Le contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des

luminances de deux zones d'images. Si L1 et L2 sont les degrés de luminosité respectivement de deux zones voisines A1 et A2 d'une image, le contraste C est défini par le rapport : [3]

$$C = (L1 - L2)/(L1 + L2) \quad \text{(I-2)}$$

I.7 Système de traitement d'image

Un système de traitement d'image est généralement composé des unités suivantes :

Système d'acquisition et de numérisation qui permet d'effectuer l'échantillonnage et la quantification d'une image. Une mémoire de masse pour stocker les images numérisées.

Un système de visualisation. Une unité centrale permettant d'effectuer les différentes opérations de traitement d'images [2].

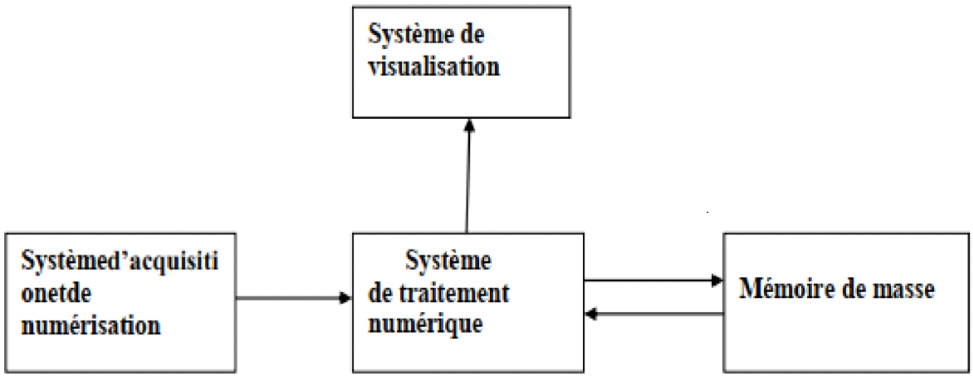


Figure I-11 : Schéma d'un système de traitement d'images.

I.7.1 Acquisition et numérisation

L'acquisition d'images constitue un des maillons essentiels de toute chaîne de conception et de production d'images. Pour pouvoir manipuler une image sur un système informatique, il est avant tout nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable par ce système. Le passage de cet objet externe (l'image d'origine) à sa représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Ces systèmes de saisie, dénommés optiques, peuvent être classés en deux catégories principales : les caméras numériques et les scanners.

I.7.2 Visualisation

Tout système de traitement d'images est doté d'un dispositif de visualisation qui permet l'affichage des images. L'utilisation de différents types de restituteurs permet de transformer le signal numérique qu'est la matrice image en un signal analogique visible par l'œil de l'observateur.

Pour cela, différents types de supports peuvent être employés : moniteur vidéo, clichés photographiques, impression sur papier. Dans tous les cas et pour chaque échantillon de l'image numérique, on recrée un nouvel élément d'image ou un nouveau pixel dont on choisit la forme de façon à reconstituer une image analogique qui soit la plus proche possible de l'image avant numérisation compte tenu des erreurs introduites lors de l'acquisition, de la numérisation et de la transmission [2].

I.7.3 Traitement numérique des images

Les techniques de traitement sont destinées à l'exploitation des informations contenues dans les images, ceci dans le but d'améliorer la qualité des images et de les rendre plus facilement interprétables, en d'autres termes elles permettent d'augmenter la qualité visuelle de l'image.

I.7.3.1 Filtrage Numérique

Les images numériques Telles qu'elles sont acquises, sont très souvent inexploitables pour le traitement d'images. Elles contiennent des signaux bruités. Pour remédier à cela, différents prétraitements pour l'amélioration ou la correction sont effectués [7].

I.7.3.1.1 Filtres linéaires

Les filtres linéaires transforment un ensemble de données d'entrée en un ensemble de données de sortie par une convolution bidimensionnelle qui est une opération mathématique. Ils permettent de supprimer le bruit dans l'image. Chaque filtre a une taille N x N avec N impair. Les filtres linéaires les plus connus sont les filtres passe-bas, passe-haut [2].

- **Filtre passe-bas (lissage)**

Opération destinée à éliminer le bruit dans l'image : le filtre passe-bas élimine les signaux de haute fréquence caractérises par de grandes variations des niveaux de Gris entre pixels voisins. IL est appelé aussi filtre de lissage car il adoucit considérablement les contours de l'image. Le principe de ce filtre consiste à remplacer la valeur de chaque pixel par la moyenne effectuée sur un voisinage.

$$M = {}^{1}/_{9} * \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \qquad \text{(I-3)}$$

- **Filtre passe-haut (Accentuation)**

Le renfoncement des contours et leur extraction s'obtiennent dans le domaine fréquentiel par l'application d'un filtre passe-haut. Le filtre digital passe-haut aux caractéristiques inverses du filtre passe-bas. Ce filtre n'affecte pas les composantes de haute fréquence d'un signal, mais doit atténuer les composantes de basse fréquence [6].

$$H = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad \text{(I-4)}$$

I.7.3.1.2 Filtres non linéaires

Ils sont conçus pour régler les problèmes des filtres linéaires, Leur principe est le même que celui des filtres linéaires, il s'agit toujours de remplacer la valeur de chaque pixel par la valeur d'une fonction calculée dans son voisinage. La différence majeure, est que cette fonction n'est plus linéaire mais une fonction quelconque (elle peut inclure des opérateurs de comparaisons ou de classification). Les filtres non linéaires les plus connu sont : [8]

- **Filtre médian**

Ce filtre est très utilisé pour éliminer le bruit sur une image qui peut être de différentes origines (poussières, petits nuages, baisse momentanée de l'intensité électrique sur les capteurs, ...). L'avantage de ce filtre réside dans le fait qu'il conserve les contours alors que les autres types de filtres ont tendance à les adoucir.

L'algorithme de filtre médian est le suivant :

- Trier les valeurs par ordre croissant.
- Remplacer la valeur du pixel centrale par la valeur située au milieu de la triée.
- Répéter cette opération pour tous les pixels de l'image.

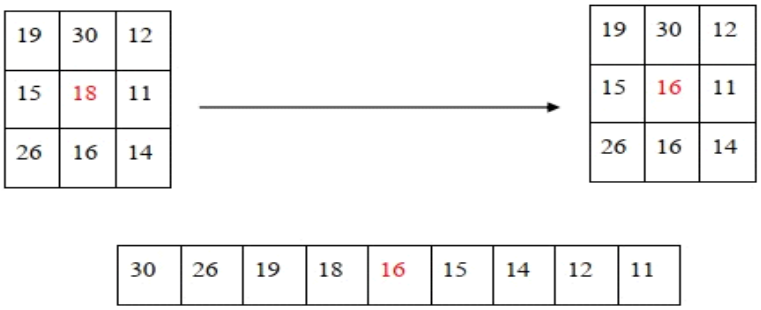


Figure I-12 : Filtre médian.

- **Filtre maximum**

On applique le même traitement que celui du filtre médian mais la valeur du pixel du centre comme la montre la figure I.13 va être changée par le maximum.

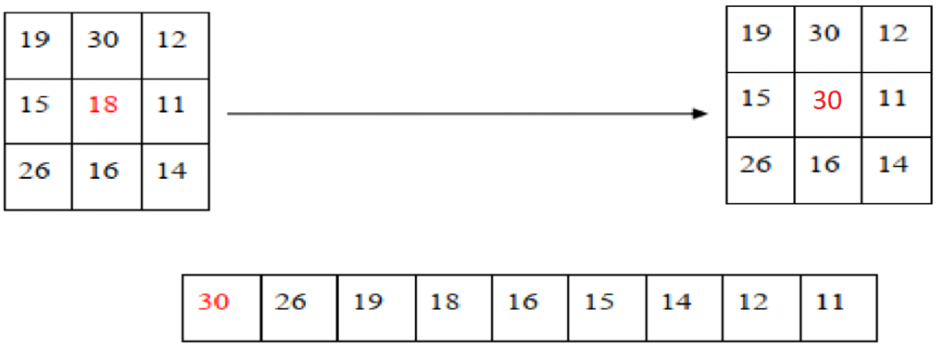


Figure I-13 : Filtre maximum.

- **Filtre minimum**

On applique le même traitement que celui du filtre maximum mais, cette fois, la valeur du pixel du centre comme la montre la figure va être remplacée par le minimum [8].

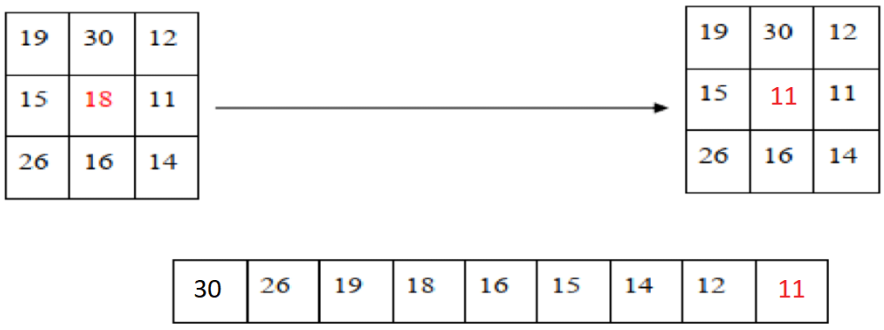


Figure I-14 : Filtre minimum.

I.8 Domaines d'application de traitement d'image

Le traitement d'images possède l'aspect multidisciplinaire. On trouve ses applications dans des domaines très variés tels que les télécommunications (T.V., vidéo, publicité,), la médecine (radiographie, ultrasons,), biologie, astronomie, géologie, l'industrie (robotique, sécurité), la météorologie, l'architecture, l'imprimerie, l'armement (application militaire). De nouvelle applications pratiques sont possibles aujourd'hui et touchent tous les domaines d'activités, tels que : métiers du spectacle, de la radio, créations artistiques…

I.9 Généralités sur le satellite

I.9.1 Définition d'un satellite

Un satellite est un corps qui gravite autour d'un autre corps ainsi la lune est satellite de la terre et la terre est un satellite du soleil. Les objets introduit dans l'espace par l'homme et qui continuent à tourner autour de la terre ou d'une autre planète sont désignés sous le nom de satellite artificiels. La trajectoire décrite périodiquement par le satellite est appelée orbite.

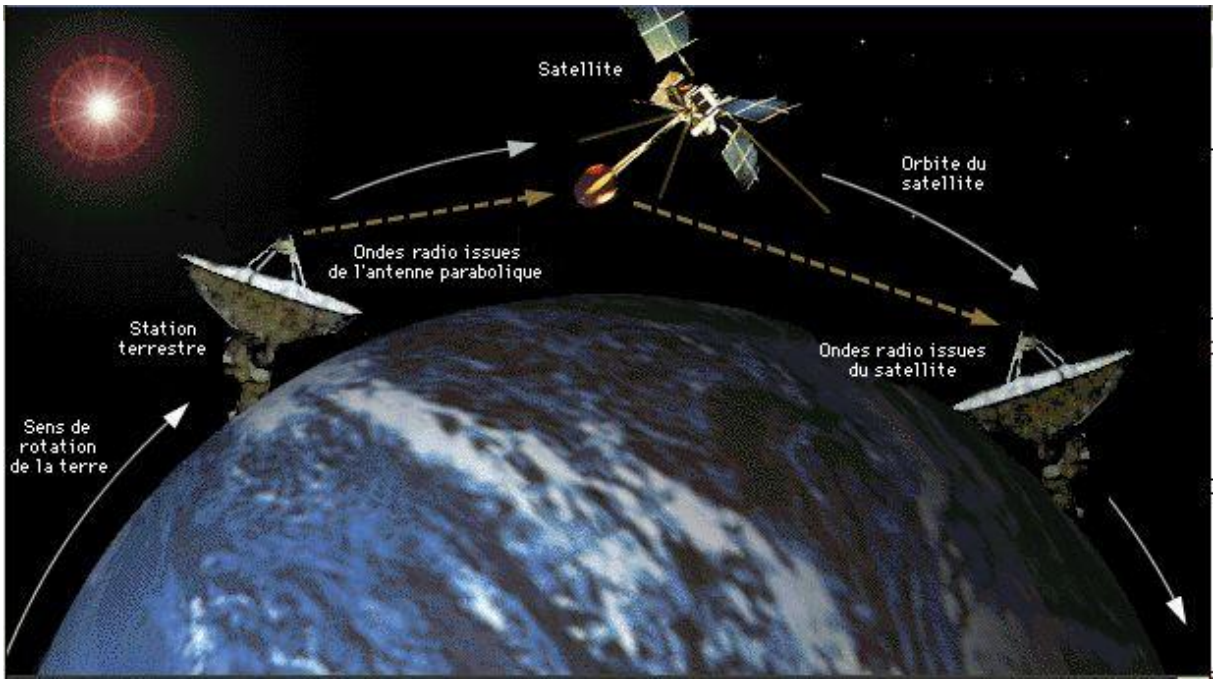


Figure I-15 : La trajectoire décrite périodiquement par le satellite est appelée orbite.

I.9.2 Architecture d'un satellite :

Les satellites sont des objets très variés et ont de ce fait une architecture qui leur est propre L'élément central :

La plate-forme ou « bus » supporte les équipements nécessaires à la mission, qu'on appelle la charge utile et est équipée pour lui fournir les ressources nécessaires à son fonctionnement.

Elle comprend notamment :

- Structure
- Alimentation électrique (génération, distribution et stockage
- Equipement de propulsion
- Contrôle de température

- Contrôle de l'attitude du satellite (orientation dans l'espace, stabilisation selon les trois axes
- Equipement pour le suivi (télémesure), le contrôle (télécommande) et la localisation du satellite.

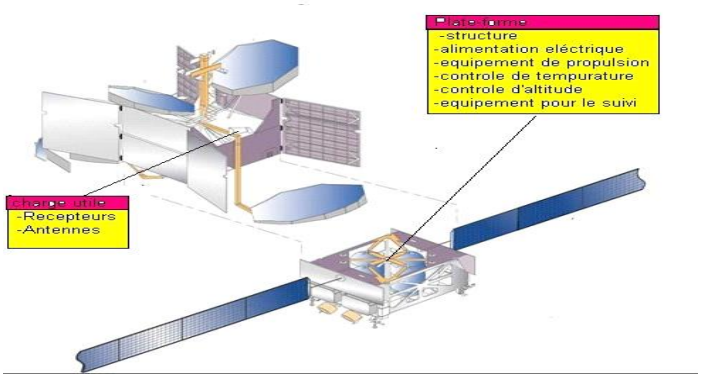


Figure I-16 : l'architecteur de satellites.

I.9.3 Différentes vitesses de satellisation :

Pour pouvoir mettre un satellite en orbite autour de la terre, il faut lui donner une certaine vitesse, elle se nomme première vitesse cosmique. Elle est environ égale à v1= 7,9 km/s (28080 km/h) Pour les sondes spatiales il faut une vitesse plus importante car la sonde doit s'échapper de la gravitation terrestre.

Elle est égale à v2= 11,2 km/s (40320 km/h). C'est la vitesse d'évasion.

On a les situations suivantes pour les satellites et sondes

- Si v < v1 alors l'objet lancé retombe sur la terre.
- Si v = v1 alors le satellite à une orbite circulaire.
- Si v est compris entre v1 et v2 alors le satellite à une orbite elliptique.
- Si v < v2 alors la sonde à une orbite elliptique autour du soleil.

  Si v est supérieur à v3=16.1 km/h la sonde quittera l'attraction solaire, toutefois, à ce jour, aucun des engins spatiaux n'a échappé à la gravitation du soleil.

I.9.4 Orbite de satellites :

La diversité des missions spatiales a pour conséquence une grande variété d'orbites. En fonction de ces missions, les orbites décrites par les satellites de la terre s'organisent en deux grandes catégories.

Les orbites circulaires (quasi –circulaires) : Les satellites en orbite circulaire sont classés par :

- Leur altitude moyenne : les orbites circulaires (quasi –circulaires)
- Orbite basse : LEO (Low Earth Orbit) pour une altitude inférieure à 1500 km et supérieure à 500km
- Orbite moyenne : MEO (Medium Earth Orbit) pour une altitude voisine de 20000 km.
- Orbite haute : GEO (Geostationary Earth Orbit) pour une altitude de 36000 km

Les orbites elliptiques :

Cette orbite est généralement provisoire, puisqu'on y met des satellites à orbite géostationnaire GTO (Geostationary Transfer orbit)

Parmi les orbites elliptiques, l'orbite de transfert géostationnaire est caractérisée par une apogée située à 36000 km .Ce qui correspond à l'altitude des satellites géostationnaire.

Cette orbite est l'étape quasi-incontournable pour mettre un satellite géostationnaire à poste dans une première phase, le satellite est injecté en périgée d'une altitude de 500 km, puis il décrit l'orbite elliptique de transfert.

Dans une seconde phase, lors de l'un des passages du satellite à l'apogée on lui donne une impulsion supplémentaire à l'aide d'un moteur d'apogée, pour « circulariser » son orbite à cette altitude de 36000 k.

I.9.5 Caractéristiques principales des systèmes satellitaires

Un satellite de télécommunications est un relais hertzien en orbite. Le fait d'être en orbite par rapport à un relais terrestre conduit aux conséquences suivantes :

- Un système satellitaire demande peu d'infrastructures terrestres.
- Un système satellitaire peut fonctionner indépendamment des autres systèmes terrestres.
- Un système satellitaire possède une large couverture.
- En conséquence un système satellitaire peut être déployé rapidement tout en couvrant une population importante.

Le satellite en orbite est soumis à des lois de dynamiques célestes. La force principale appliquée au satellite est l'attraction terrestre et les lois de Kepler les plus importantes pour cet exposé sont les suivantes :

- On définit Le satellite se meut dans un plan (plan orbital) et sa trajectoire est une ellipse dont la Terre occupe un foyer. L'ellipse possède un demi grand axe noté *a* et un demi petit axe noté *b.*
- L'excentricité e de l'ellipse, e 2 = 1− b2.
- Le cas de l'orbite circulaire est celui
- Où e=0, *a* et *b* sont alors égaux.

I.10 Les satellites de télédétection

I.10.1 Définitions

Littéralement, la télédétection fait référence à l'acte d'en tirer des informations. La distance à un objet ou phénomène sans que le détecteur soit en contact avec l'objet Appris. Malgré son étymologie large, le terme télédétection est actuellement Utilisé pour désigner la science visant à étudier l'environnement terrestre Capteurs, sur plateformes aériennes ou spatiales, sensibles aux rayonnements Rayonnement électromagnétique réfléchi ou émis par la surface de la Terre ou son [9].

La télédétection est basée sur l'hypothèse que tout objet, en fonction de ses propriétés physiques et Produits chimiques qui réfléchissent ou émettent des rayonnements électromagnétiques (REM) de manière unique, Dans diverses parties du spectre, en fonction du temps et de sa position dans l'espace.

L'observation et l'analyse des variations du REM provenant des objets visés par le capteur en fonction de la longueur d'onde, du ou des moments d'observation et de l'emplacement relatif de ces objets peuvent, en principe, nous permettre :

- D'identifier la nature des objets
- D'évaluer leur état ou mesurer leurs propriétés
- De surveiller leur comportement dans le temps et dans l'espace
- De déduire la présence ou l'absence des objets non directement "visibles" par les capteurs [10].

Les données des capteurs de télédétection nous permettent de Reconstruire des images séquentielles de la scène cible ou étudier le comportement de la cible Selon le plan d'échantillonnage spatial.

Dans le premier cas on parle de capteurs, Les imageurs, dans le second cas, sont des capteurs non imageurs. La fonction principale du capteur

Les imageurs sont ceux qui nous fournissent les outils appropriés pour étudier les phénomènes de leur ampleur et de leur ampleur La variation spatiale est un paramètre important que nous devrions considérer Notre analyse [11].

I.10.2 Principe physique de la Télédétection

Dans la plupart des cas, la télédétection implique une interaction entre l'énergie incidente et les cibles. Le processus de la télédétection au moyen de systèmes imageurs comporte sept étapes que nous allons élaborer ci-après. Notons cependant que la télédétection peut également impliquer l'énergie émise et utiliser des capteurs non-imageurs [12].

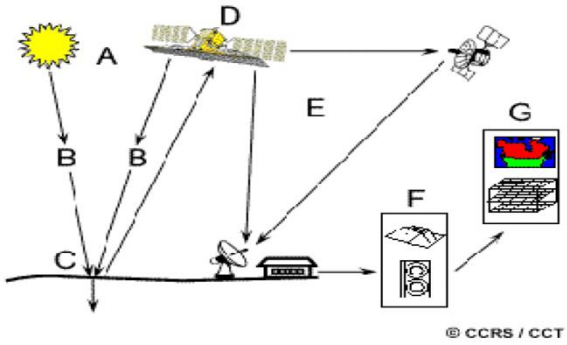


Figure I-17 : Principe physique de la télédétection [12].

Source d'énergie ou d'illumination (A) : À l'origine de tout processus de télédétection se trouve nécessairement une source d'énergie pour illuminer la cible.

Rayonnement et atmosphère (B) : Durant son parcours entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une seconde interaction se produit lors du trajet entre la cible et le capteur.

Interaction avec la cible (C) : Une fois parvenue à la cible, l'énergie interagit avec la surface de celle-ci. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface.

Enregistrement de l'énergie par le capteur (D) : L'énergie diffusée ou émise par la cible, doit être captée à distance (par un capteur qui n'est pas en contact avec la cible) pour être enfin enregistrée.

Transmission, réception et traitement (E) : L'énergie enregistrée par le capteur est transmise, souvent par des moyens électroniques, à une station de réception où l'information est transformée en images (numériques ou photographiques).

Interprétation et analyse (F) : Une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information que l'on désire obtenir sur la cible.

Application (G) : La dernière étape du processus consiste à utiliser l'information extraite de l'image pour mieux comprendre la cible, pour nous en faire découvrir de nouveaux aspects ou pour aider à résoudre un problème particulier [13].

Les données acquises par les capteurs de télédétection peuvent nous permettre de reconstituer une image continue de la scène visée ou d'étudier le comportement des cibles selon un plan d'échantillonnage dans l'espace. Dans le premier cas nous parlons de capteurs imageurs et dans le second cas de capteurs non imageurs. La première fonction des capteurs imageurs est de nous fournir l'outil approprié pour étudier des phénomènes dont l'étendue et les variations spatiales sont des paramètres importants dont on devra tenir compte dans notre analyse.

Les capteurs imageurs comprennent les caméras photographiques conventionnelles, les caméras de télévision, les balayeurs optico-mécaniques et électroniques opérant dans le visible et l'infra-rouge, ainsi que les radiomètres et les radars imageurs dans les micro-ondes (ou hyperfréquences) [14].

Les capteurs non imageurs de leur côté, acquièrent des données à des emplacements spécifiques selon un pas d'échantillonnage dans l'espace ou suivant des transepts. Dans les applications orientées vers les ressources terrestres, ces capteurs servent surtout à la compréhension des principes physiques de base qui donnent naissance au signal capté à distance. Les résultats de ces études sont, par la suite, utilisés pour bâtir des capteurs imageurs avec une meilleure définition des paramètres d'observation.

I.10.3 Spectre électromagnétique

Les senseurs /capteurs/ instruments d'acquisitions actuels sont basés sur les variations de la distribution de l'énergie électromagnétique, réfléchie ou émise par des objets à la surface de la terre.

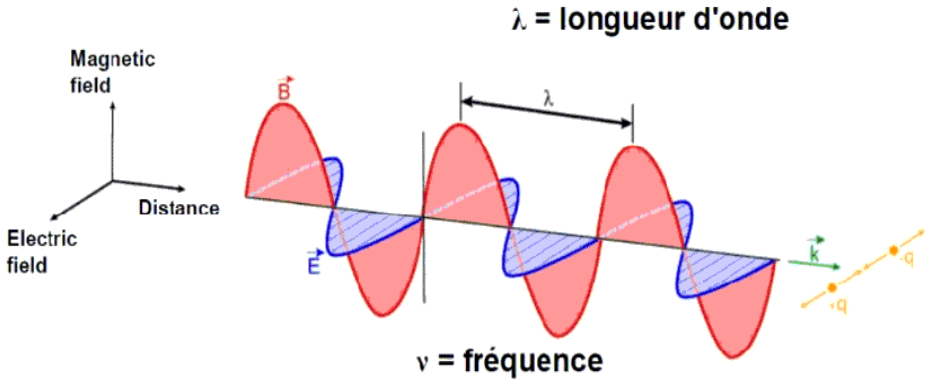


Figure I-18 : Onde électromagnétique.

L'énergie électromagnétique se propage sous forme d'ondes (Figure I-17) à fréquences et longueurs variées, constituant ainsi ce qu'on appelle le spectre électromagnétique (Figure I-18)

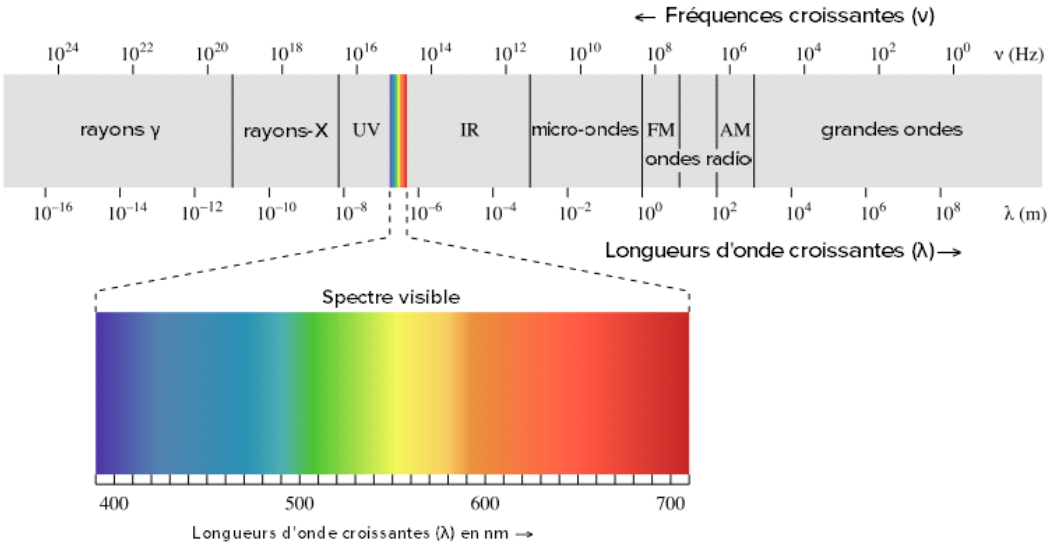


Figure I-19 : Spectre électromagnétique.

La propagation et la distribution de l'énergie électromagnétique obéissent à la théorie des ondes, dont la formule peut s'écrire :

$$c = \lambda n \qquad (I.5)$$

Où :

λ = longueur d'onde,

c = vitesse de la lumière dans le vide = 3 x 108 m/s,

n = fréquence de la longueur d'onde.

En télédétection, il est courant de catégoriser les ondes électromagnétiques par la localisation de leur longueur à l'intérieur du spectre électromagnétique.

$$\lambda = {}^{c}/_{n} \quad \text{(I.6)}$$

Comme l'indique la figure 3, la portion du visible est extrêmement petite puisque la sensibilité spectrale de l'œil humain ne s'étend que de 0.4 à 0.7mm seulement. L'ultra-violet (UV) vient immédiatement après le bleu. Il est suivi des rayons X, rayons gamma, puis rayons cosmiques. Au-delà du rouge, il y a 3 types d'infra-rouge (IR) : IR proche (0.7-1.3mm), IR moyen (1.3-3mm), et IR thermique (3-15mm). Viennent ensuite les hyperfréquences ou micro-ondes (1mm-1m), puis les ondes radar, de télévision et radio.

Bien que le spectre soit divisé en régions spécifiques, il n'y a pas une limite nette entre les différentes zones. En plus, la plupart des instruments de télédétection opèrent dans le visible, l'IR ou les micro-ondes du spectre électromagnétique.

I.10.4 Source de l'énergie électromagnétique

Le soleil constitue une source très importante pour les instruments de télédétection. Tout objet ayant une température supérieure à -273°C (0°K) peut émettre de l'énergie. L'énergie émise par un objet est fonction de sa température et peut être exprimée par la loi de Stéphan - Boltzman :

$$M = sT^4 \quad \text{(I.7)}$$

Où :

M = la puissance (ou existence) totale d'énergie émise par un corps,

s = Constante de Stéphan - Boltzman (6.6697 10-8 Wm-2 K4),

T = température absolue de l'objet (K).

Cette loi suppose que la source d'énergie en question se comporte comme un corps noir. On définit un corps noir comme étant un corps théorique qui absorbe et réémet la totalité de l'énergie qu'il reçoit.

Comme l'énergie totale émise par un corps varie en fonction de sa température, la distribution spectrale de cette énergie varie aussi. La loi de Stéphan - Boltzman montre que plus la température d'un corps n'augmente, plus l'énergie émise par ce corps n'augmente. La figure 4

représente les courbes de la distribution de l'énergie pour un corps noir à des températures variables (200 -6000°K).

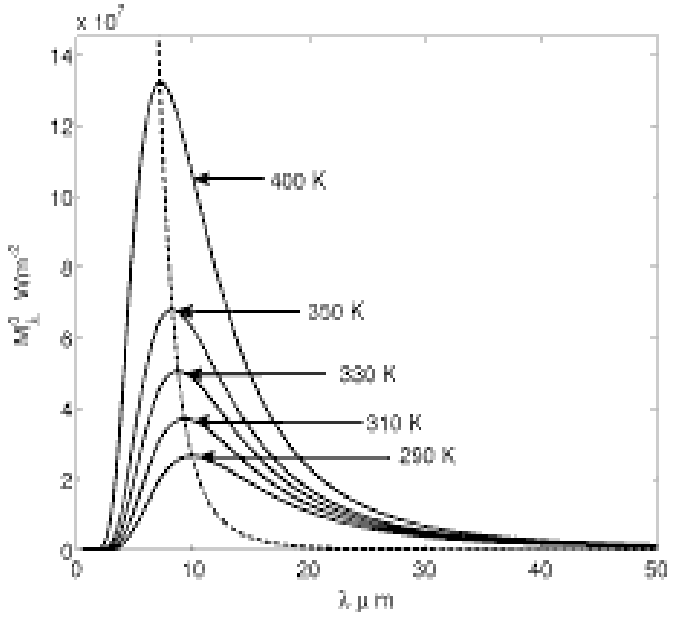


Figure I-20 : Distribution spectrale de l'énergie émise par un corps noir à des différentes températures.

Le soleil émet de l'énergie de la même façon qu'un corps noir à 6000 °K. Son maximum d'émission se situe à 0.5 mm, c'est-à-dire dans la portion du visible. La température ambiante de la terre (objets de surface) est environ 300°K (27°C). En appliquant la loi de Wien, le maximum d'émission à cette température se situe à 9.7 mm Comme cette énergie correspond à la température terrestre, il est convenu de l'appeler l'infra-rouge thermique.

La séparation entre l'infra-rouge réfléchi et l'infra-rouge émis se situe approximativement à 3 mm au-dessous de laquelle l'infra-rouge réfléchi prédomine et au-dessus de laquelle l'infrarouge émis prédomine.

I.10.5 Perturbations atmosphériques

L'influence de l'atmosphère sur le rayonnement électromagnétique porte sur la réfraction, l'absorption, la diffusion et l'émission propre.

Réfraction : C'est la distorsion géométrique du trajet des ondes, due à des variations d'indice de réfraction.

Absorption : Elle est fortement liée à la longueur d'onde utilisée et dépend du type de molécules et de leurs propriétés. Pour les gaz, dont la répartition est stable, la modélisation de l'absorption

est possible. Par contre, pour la vapeur d'eau, dont la concentration varie beaucoup, il faut effectuer des sondages, avant de pouvoir en effectuer la correction.

Les principales bandes d'absorption dans le visible sont dues à l'ozone (O3) à 600 nm, à la vapeur d'eau à 718 nm et à l'oxygène (O2) à 760 nm.

Dans l'infra-rouge, on observe des bandes d'absorption de 2.7 à 5 mm dues au gaz carbonique (CO2) et à la vapeur d'eau. L'ozone a une bande d'absorption à 9.6 mm et l'azote (N2) à 4.3 mm (figure 13). L'atmosphère est opaque pour le rayonnement infra-rouge de 22 mm à 1 mm, ce qui explique la non-utilisation de cette portion du spectre en télédétection.

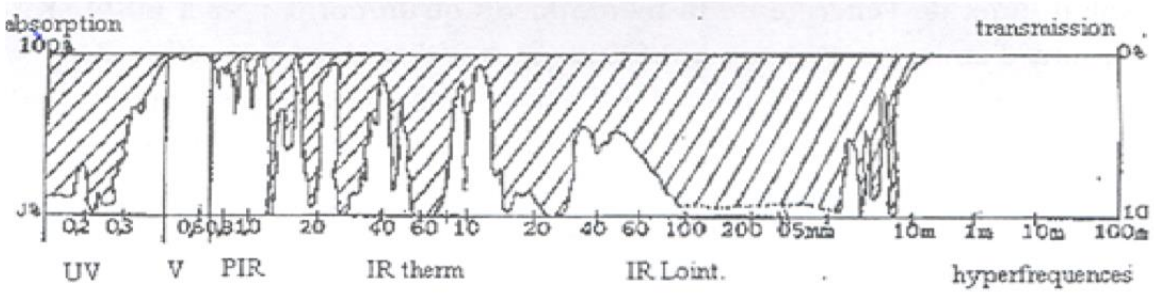


Figure I-21 : Rayonnement solaire et influence de l'atmosphère.[15]

Diffusion : Ce phénomène correspond à l'action des molécules et particules (gouttelettes d'eau, poussières, fumées...) sur les longueurs d'ondes.

Emission propre : L'atmosphère réémet une partie du rayonnement reçu, ce qui contribue à augmenter la valeur du flux mesuré par le capteur. Cette luminance atmosphérique s'ajoute à la valeur du flux réfléchi ou émis par la surface terrestre faisant l'objet de l'étude. Il est donc nécessaire de modéliser les effets de l'atmosphère sur les flux mesurés, tout particulièrement par les satellites, pour lesquels ces effets sont très importants

I.11 Images satellitaires

Une image est une représentation graphique, quel que soit longueurs d'onde ou le dispositif de télédétection a été utilisée pour détecter et enregistrer l'énergie électromagnétique [15].

Chaque élément de l'image dans une image, appelé un pixel, a pour coordonnées (x, y) dans l'espace discret représentant un échantillonnage en continu de la surface de la terre. Valeurs de pixels d'image représentent l'échantillonnage de la radiance de surface. Valeur du pixel est aussi appelé intensité de l'image, luminosité de l'image ou niveau de gris. Dans une image multi-

spectrale, un pixel a plus d'un niveau de gris. Chaque niveau de gris correspond à une bande spectrale. Ces niveaux de gris peuvent être considérés comme des vecteurs de niveaux de gris.

Applications image réussie des données de télédétection nécessitent une attention particulière à la fois les systèmes de capteurs à distance et les caractéristiques environnementales. Parmi les divers facteurs qui influent sur la qualité du contenu et des informations des données de télédétection, deux concepts sont très importants pour nous de comprendre. Ils déterminent le niveau de détails du processus de modélisation. Il s'agit de la résolution et la fréquence d'échantillonnage.

I.11.1 La résolution des images satellitaires

Est une mesure de la capacité d'un système optique de faire la distinction entre les signaux qui sont rapprochés dans l'espace ou dans le spectre.

I.11.2 La résolution spectrale

Se réfère au nombre et la dimension des intervalles de longueur d'onde spécifique dans le spectre électromagnétique à laquelle un capteur est sensible. Une sélection rigoureuse des bandes spectrales peut améliorer la probabilité qu'une fonctionnalité sera détectée et identifié et extrait des données biophysiques.

I.11.3 La résolution spatiale

Est une mesure de la plus petite séparation angulaire ou linéaire entre deux objets qui peuvent être résolus par le capteur. Il existe une relation entre la taille d'une caractéristique d'être identifiés et la résolution spatiale du système de télédétection.

En général plus la résolution spatiale n’est plus le pouvoir de résolution du système de détection.

I.11.4 La résolution temporelle

La résolution temporelle d'un système de capteur de référence à quelle fréquence il enregistre des images d'une zone particulière.

I.11.5 La résolution radiométrique

Définit la sensibilité d'un détecteur de différences dans l'intensité du signal comme il enregistre le flux énergétique réfléchie ou émise par la région d'intérêt. Amélioration de la résolution augmentent généralement la probabilité que phénomènes peuvent être obtenues par

télédétection avec plus de précision. Pour la haute résolution spatiale, la sonde doit avoir un champ de vision instantané de petite taille. Cependant, ce qui réduit la quantité d'énergie qui peut être détecté que la zone de la cellule au sol résolution dans le champ de vision instantané devient plus petite. Cela conduit à la résolution radiométrique réduite- la capacité de détecter des différences d'énergie fine. Pour augmenter la quantité d'énergie détectée (et donc, la résolution radiométrique) sans réduire la résolution spatiale, il faudrait élargir la gamme de longueur d'onde détecté par un canal notamment ou de la bande. Malheureusement, cela permettrait de réduire la résolution spectrale du capteur. Inversement, résolution spatiale plus grossière permettrait l'amélioration de radiométriques et / ou la résolution spectrale. Ainsi, ces trois types de résolution doit être équilibrée par rapport aux capacités et aux objectifs souhaités de la sonde.

I.12 Conclusion

Nous espérons qu'il fournit une brève introduction aux concepts pertinents dans le domaine du traitement d'images. Le différent bien d'autres domaines. La quantité toujours croissante de données d'imagerie que les satellites transmettent quotidiennement aux stations de réception au sol invite à discuter d'une des principales activités de la télédétection spatiale, l'imagerie satellitaire et ces différentes résolutions spatiales.

Chapitre II : L’apprentissage automatique et l’intelligence artificiel

Chapitre II : L'apprentissage automatique et l'intelligence artificiel

II.1 Introduction

Intelligence Artificielle (IA) est l'un des domaines les plus récents de la science et de l'ingénierie. Les travaux ont sérieusement débute après la seconde guerre mondiale, et le nom lui-même a été inventé en 1956. Régulièrement cité comme "domaine ou j'aimerai bien y être" par les scientifiques dans d'autres disciplines.

Un étudiant en physique peut raisonnablement se dire que toutes les bonnes idées ont été trouvées par Galilée, Newton, Einstein et le reste. De l'autre côté, tout reste ouvert en IA.

Historiquement, quatre approches de l'IA ont été suivies, chacune par des gens différents avec des méthodes différentes. Une approche axée sur l'homme doit être en partie une science empirique, impliquant observation et hypothèse sur le comportement humain. Une approche rationnelle implique une combinaison de mathématique et d'ingénierie.

L'IA englobe plusieurs sous domaines allant du plus général (apprentissage et perception) au plus spécifique, comme jouer aux échecs, démontrer des théorèmes mathématiques, écrire des poèmes, conduire une voiture ou diagnostiquer des maladies. L'IA se révèle être utile dans toutes les taches intellectuelles. C'est vraiment un domaine universel et pluri-disciplinaire.

Pour ce deuxième chapitre nous allons approfondir la notion d'IA en citant les outils et les algorithmes mis en œuvre pour l'IA. Premièrement nous aborderons les techniques de l'apprentissage, bien précisément l'apprentissage machine (l'apprentissage automatique ou machine Learning), nous allons citer ses différents types utilisés lors de la conception d'un système doté d'une intelligence artificielle et parler plus en détails de l'apprentissage profond

(*Deep Learning*), ou nous allons exposer la notion des réseaux de neurones artificiels et ses différents types et leurs principes de fonctionnement afin de mieux comprendre la notion de l'apprentissage profond. Ensuite nous allons présenter le principe de fonctionnement de DeepLearning, ses domaines d'applications pour pouvoir conclure le chapitre [16].

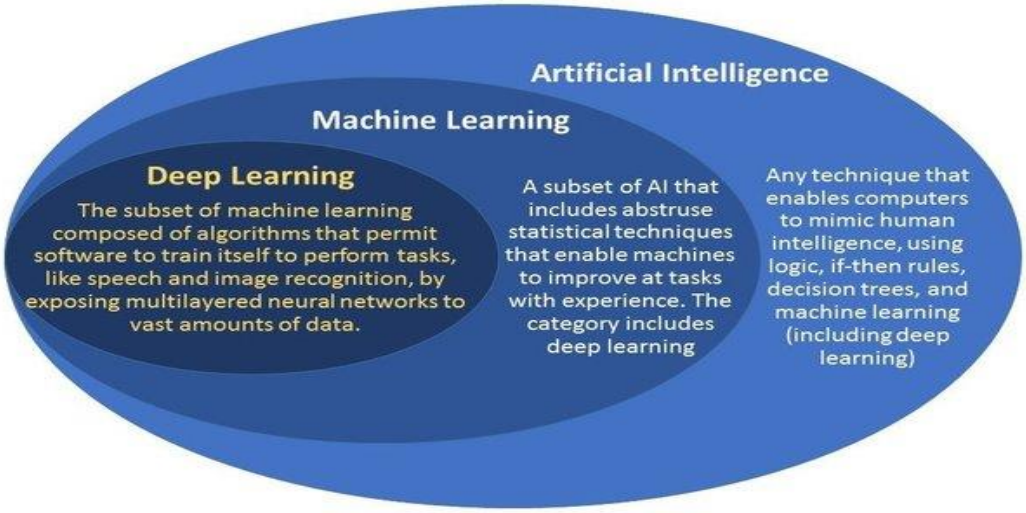


Figure II-1 : La relation entre l'intelligence artificielle, ML et deep Learning.

II.2 Les méthodes de classification

La classification c'est l'action de ranger par classes, par catégories des objets avec des propriétés communes. Il existe deux catégories de classification : classification supervisée et classification non supervisée. Dans la première catégorie, les méthodes consistent à classer les objets à partir d'une base de données dite d'apprentissage, tandis que dans l'autre les méthodes classent les objets sans besoin de cette base de données. Dans la littérature scientifique, plusieurs méthodes de classification ont été présentées. Dans ce chapitre nous allons présenter les plus connues dans **la Machine learning** et **Deep learnig** et d'autres :

II.2.1 L'apprentissage automatique (Maching learning)

L'apprentissage automatique (ML) est un ensemble d'outils statistiques etgéométriques ainsi que d'algorithmes informatiques qui automatisent la création de fonctions de prédiction à partir d'ensembles de données, ou ce que l'on appelle l'ensemble d'apprentissage.

Un modèle d'apprentissage automatique est un processus algorithmique particulier qui permet de construire une fonction de prédiction à partir d'un ensemble de données d'apprentissage.

La formation ou l'instruction du modèle est représentée par la construction de f.Une prédiction est l' évaluation de la fonction de prédiction f sur les variables prédictives d' une observation x, exprimée sous la forme f(x).

II.2.1.1 Algorithmes de Machine Learning

Les principaux algorithmes du machine learning supervisé sont les suivants :

Forêts aléatoires,arbres de décision, algorithme K-NN (k-Nearest Neighbors), régressionlinéaire, algorithme deNaïve Bayes, machine à vecteurs de support (SVM), régression logistique et boosting de gradient, On se parle sur lesalgorithmes suivants :

II.2.1.1.1 K-means

La méthode k-moyen a été introduite par MacQueen en 1967. En 1965 Forgy a publié un algorithme similaire, c'est pour cette raison qu'elle est parfois référée à Forgy. C'est une méthode efficace qui permet de diviser un ensemble de données en k classes homogènes [17].

La méthode K-moyen est utilisée dans l'apprentissage non supervisé. Elle est itérative c'est-à-dire qu'elle converge vers une solution quel que soit son point de départ.

Dans un premier temps, l'algorithme choisit le centre des k clusters à k objets. Par la suite, on calcule la distance entre les objets et les k centres et on affecte les objets aux centres les plus proches. Ensuite, les centres sont redéfinis à partir des objets qui ont été affectés aux différents clusters. Puis, les objets sont assignés en fonction de leur distance aux nouveaux centres et ainsi de suite. L'algorithme se répète donc jusqu'à ce qu'il y ait convergence [16].

Les k clusters sont produits de façon à minimiser la fonction objective suivante **[**18**]:**

$$E = \sum\sum(xi - gr)2 \quad xi \in Cr\ k\ r = 1 \tag{II.1}$$

Où :
Cr : l'ensemble des classes.
Xi : Un individu appartenant à une classe Cr.
gr : Le point moyen de la classe Cr.

Il existe plusieurs types de distance pour calculer la distance entre les objets et les k centres. Parmi ces distances, on peut citer [4][19]:

- La distance Euclidienne.
- La distance de Minkowsky.
- La distance de Manhattan.
- La distance Euclidienne est souvent utilisée. Elle est donnée par la formule suivante :

$$D(x, y) = \sqrt{\sum(x - y)} \tag{II.2}$$

Où : x,y sont des vecteurs.

a) Le fonctionnement de K-moyen

Se résume dans les étapes suivantes :

1. On choisit k objets au hasard qu'on considère comme des centres pour les classes initiales
2. On affecte chaque objet au centre le plus proche pour obtenir une partition de k classes.
3. On recalcule les centres de chaque classe.
4. La répétition des étapes 2 et 3 jusqu'à la stabilité des centres.
5. La complexité de l'algorithme du K-moyen est de (lkn) [18].

Où :

l : est le nombre d'itérations.

k: le nombre des classes telles que $k<n$.

b) Avantages du K-moyen

La méthode du K-moyen comporte des avantages, comme par exemple :

1. L'assimilation de cette méthode est rapide.
2. La méthode simple à appliquer.
3. Son adaptation à de larges bases de données [18]**.**

c) Inconvénients du K-moyen

La méthode du K-moyen comporte les inconvénients suivants :

1. La difficulté de comparer la qualité des clusters obtenus.
2. La performance de l'algorithme dépend fortement de l'estimation initiale de la partition**.**
3. Le choix du paramètre k influences les résultats [16] [18]**.**

II.2.1.1.2 Les machines à support de vecteurs (SVM)

Introduit par Vapnik en 1990, les machines à vecteurs de support sont des techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification et de régression. Elles reposent sur deux notions principales : la notion de marge maximale et la notion de fonction noyau [10].

Les machines à support de vecteurs peuvent être utilisées pour résoudre divers problèmes en bio-informatique, recherche d'information et vision par ordinateur, etc[25].

a) Le principe des SVM

Le but des SVM est de trouver un séparateur entre deux classes qui soit au maximum éloigné de n'importe quel point des données d'entraînement. Si on arrive à trouver un séparateur linéaire c'est-à-dire qu'il existe un hyperplan séparateur alors le problème est dit linéairement séparable sinon il n'est pas linéairement séparable et il n'existe pas un hyperplan séparateur [20].

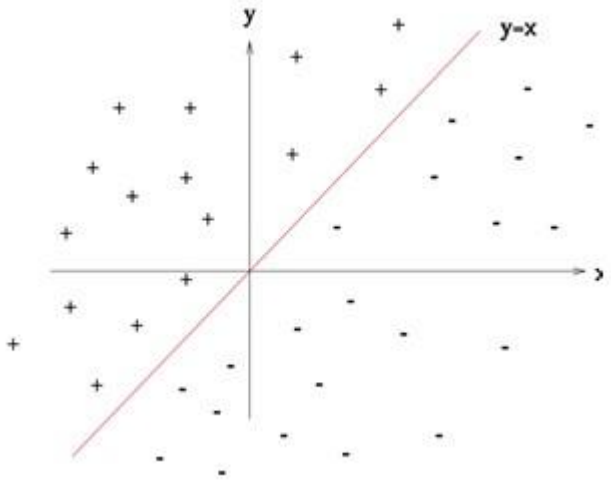


Figure II-2 : Problème de classification à deux classes avec un séparateur linéaire [21].

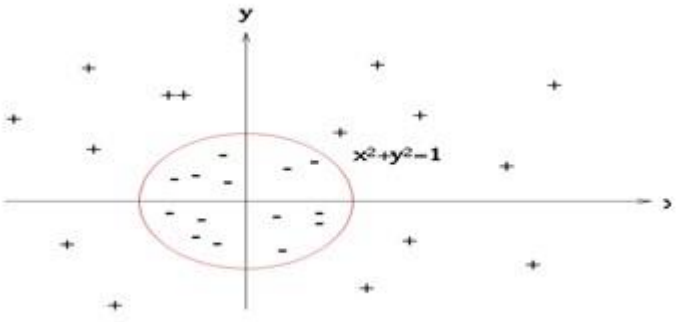


Figure II-3 : Problème de classification à deux classes avec un séparateur non linéaire [21].

Pour deux classes et des données linéairement séparable (figure 2.3), il y a beaucoup de séparateurs linéaires possibles. Les SVM choisissent seulement celui qui est optimal, c'est-à-dire la recherche d'une surface de décision qui soit Éloignée au maximum de tout point de données.

Cette distance de la surface de décision au point de données le plus proche détermine la marge maximale du classifieur. En effet, pour obtenir un hyperplan optimal, il faut maximiser la marge entre les données et l'hyperplan [20].

b) Avantages des SVM

Les SVM représentent plusieurs avantages, notamment ceux-ci :

1. Elles ont une base théorique solide.
2. Les SVM sont efficaces dans les espaces de grande dimension.
3. Différentes fonctions noyau peuvent être spécifiées [18][22].

c) Inconvénients des SVM

Malgré leurs performances, les SVM représentent aussi des faiblesses, notamment celles-ci :

1. Elles utilisent des fonctions mathématiques complexes pour la classification.
2. Les machines à support de vecteurs demandent un temps énorme durant les phases de Test [18][22]**.**

II.2.1.1.3 Les réseaux de neurones (Neural network)

Ont été développés comme un modèle mathématique générique afin de modéliser les neurones biologiques. Ils comportent un certain nombre d'éléments de traitement d'information appelés neurones

Chaque neurone a son propre état interne interprété par la fonction d'activation. Il envoie son activation aux autres neurones sous forme de signaux. La connexion entre les neurones est réalisée via des liens orientés et pondérés [23] .

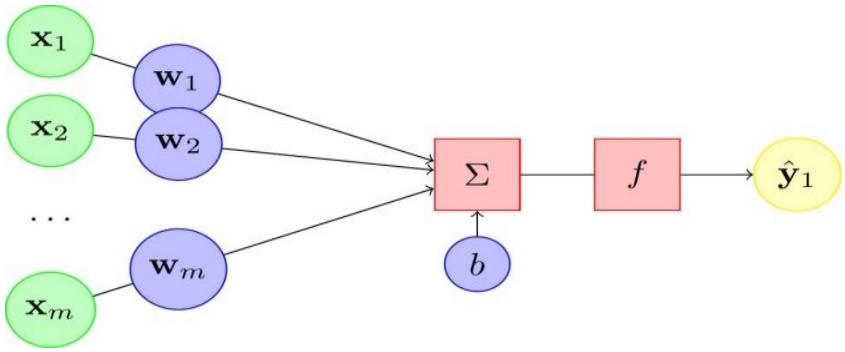


Figure II-4 : Neurone artificiel avec une seule sortie

Le neurone Y reçoit les entrées de X_1, $X_2 et X_3$ qui ont comme valeurs de sortie x_1, $x_2 et x_3$. Les poids des liens de connexion de X_1, $X_2 et X_3$sont w_1, $w_2 et w_3$. La valeur d'entrée de neurone Y est : $\boldsymbol{y} = w_1x_1 + w_2x_2 + w_3x_3$. Le signal de sortie y est déterminée par la fonction d'activation (y).

Les réseaux de neurones sont caractérisés par l'architecture (l'organisation des neurones), l'apprentissage (méthode de détermination des poids de connexions), et par leur fonction d'activation [23].

a) Architecture

Les réseaux de neurones sont souvent classifiés en deux architectures : les réseaux de neurone avec un seul niveau et multi-niveaux. Le nombre de niveaux est calculé sans prendre en considération les unités [23].

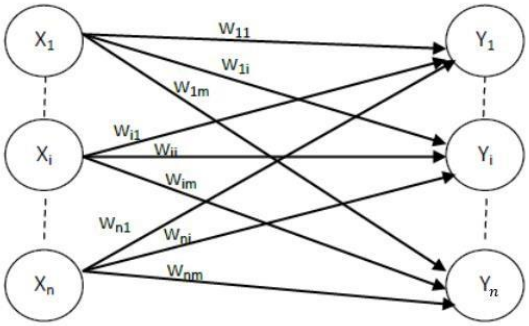


Figure II-5 : Le réseau de neurones à un seul niveau.

Les neurones de la couche d'entrée doivent uniquement passer et distribuer les entrées et ne pas effectuer de calcul. Ainsi, la seule vraie couche de neurones est celle de droite. Chacune des entrées X_1, $X_2 \ldots X_n$ est connectée à chaque neurone de la couche de sortie à travers le poids de lien. Comme chaque valeur des sorties Y_1, $Y_2 \ldots Y_n$ est calculée à partir du même ensemble de valeurs d'entrée, chaque sortie est modifiée en fonction des poids de liens. [23] [24].

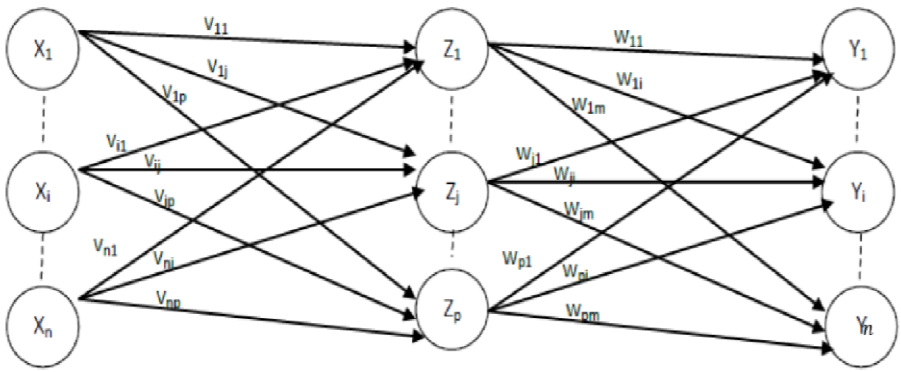


Figure II-6 : Le réseau de neurones multi-niveaux

(Figure 0-6) montre le réseau de neurones multi-niveaux ce dernier se distingue du réseau d'un seul niveau en ayant une ou plusieurs couches masquées.

Dans cette structure, les nœuds d'entrée transmettent les informations aux unités dans la première couche masquée, puis les sorties de la première couche masquée sont passées à la couche suivante, et ainsi de suite [23] [24].

Le réseau multi-niveau peut également être considéré comme une cascade de groupes de réseaux d'un seul niveau. Le niveau de complexité se traduit par le nombre de réseaux monocouche qui sont combinés dans ce type de réseau. Le concepteur d'un réseau de neurones devrait considérer combien de couches cachées sont requises, selon la complexité du calcul souhaité [23] [24].

b) L'apprentissage

La méthode de paramétrage des poids (apprentissage) est une caractéristique importante pour distinguer différents types de réseaux de neurones. Deux modes d'apprentissage existent : l'apprentissage supervisé, et l'apprentissage non supervisé [23]**.**

c) L'apprentissage supervisé

Dans ce type d'apprentissage, les entrées et les sorties sont fournies au préalable. Ensuite, le réseau traite les entrées et compare ses résultats aux sorties souhaitées. Les poids sont ensuite ajustés grâce aux erreurs propagées à travers le système. Ce processus se produit à plusieurs reprises tant que les poids sont continuellement améliorés.

L'ensemble de données qui permet l'apprentissage est appelé l'ensemble d'apprentissage [23] [24].

d) L'apprentissage non supervisé

Dans l'apprentissage non supervisé, le réseau est fourni avec des entrées mais pas avec les sorties souhaitées. Le système lui-même doit alors décider quelles fonctionnalités il utilisera pour regrouper les données d'entrée. C'est ce qu'on appelle souvent l'auto-organisation ou l'adaptation [23] [24].

e) Avantages des réseaux de neurones

Les réseaux de neurones représentent des avantages, tels que :

1. Les réseaux de neurones sont souples et génériques. Ils peuvent résoudre différents types de problèmes dont le résultat peut être : une classification, analyse de données, etc .
2. Ils traitent des problèmes non structurés sur lesquels aucune information n'est disponible à l'avance .
3. Les réseaux neuronaux se comportent bien parce que même dans des domaines très complexes, ils fonctionnent mieux que les arbres de statistique ou de décision.
4. Les réseaux de neurones fonctionnent sur des données incomplètes ou bruitées. Cette lacune d'information peut être complétée par l'ajout d'autres neurones à la couche cachée [25] [26].

f) Inconvénients des réseaux de neurones

Les réseaux de neurones ont aussi des inconvénients, tels que :

1. La lenteur d'apprentissage .
2. La difficulté de choisir des valeurs initiales des poids de connexion ainsi que l'adaptation du pas d'apprentissage
3. L'apprentissage au détriment de la généralisation .
4. En cas d'erreur dans les résultats de sorties, l'utilisateur n'a aucune information sur le fonctionnement interne [18] [22].

II.2.1.2 Application de machine Learning

Voici quelques exemples d'utilisation de la *machine Learning* parmi les plus communs :

1. Détecter des comportements frauduleux lors de transactions financières en ligne.

2. Estimer un taux de transformation sur un site marchand en fonction du nombre de clics sur certaines pages.
3. Prédire les risques de non-solvabilité d'un client en fonction de ses ressources et de son profil socioprofessionnel.
4. Anticiper les intentions de résiliation d'un service en fonction des activités d'un souscripteur.
5. Découvrir les préférences d'un client que l'on souhaite retenir pour lui suggérer des produits et des services adaptés à ses goûts et ses besoins.
6. Pattern recognition

II.2.2 Deep Learning

Le Deep Learning ou apprentissage profond est un type d'intelligence artificielle, dérivé du machine Learning qui a été développé dans le but de créer des algorithmes capables d'apprendre et de s'améliorer de manière autonome, contrairement à la programmation où la machine se contente d'exécuter à la lettre des règles prédéterminées.

Les algorithmes de ML décrits dans la première partie fonctionnent bien pour une grande variété de problèmes. Cependant ils ont échoué à résoudre quelques problèmes majeurs de l'IA telle que la reconnaissance vocale et la reconnaissance d'objets. Le développement du deep learning fut motivé en partie par l'échec des algorithmes traditionnels dans de telle tâche de l'I Mais ce n'est qu'après que de plus grandes quantités de données ne soit disponibles grâce notamment au Big Data et aux objets connectés et que les machines de calcul soient devenues plus puissantes qu'on a pu comprendre le potentiel réel du Deep Learning.

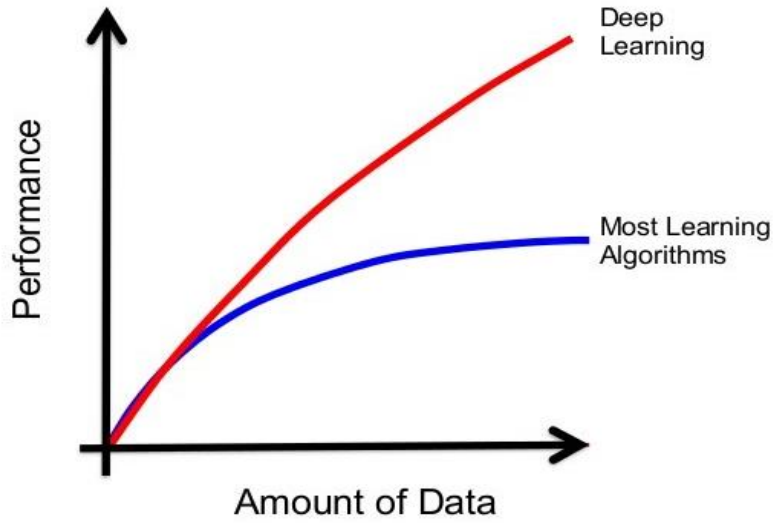


Figure II-7 : La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données.

L'introduction des réseaux de neurones convolutifs (CNN) par LeCun a révolutionné le traitement d'image et éliminé le besoin d'extraction manuelle des caractéristiques. Pour les images avec trois canaux de couleur RVB, CNN travaille directement sur les matrices ou les tensions.

II.2.2.1 Modèles du Deep Learning

On va présenter dans cette section les modèles de deep learning utilisés dans notre proposition (à savoir les CNN et les RNN).

II.2.2.1.1 Convolutional Neural Network (CNN) (réseaux de neurones convolutifs) :

Sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Les exemples comprennent des données de type série temporelle, qui peuvent être considérées comme une grille 1D en prenant des échantillons à des intervalles de temps réguliers et des données de type image, qui peuvent être considérées comme une grille 2D de pixels. Les réseaux convolutifs ont connu un succès considérable dans les applications pratiques. Le nom « réseau de neurones convolutif » indique que le réseau emploie une opération mathématique appelée convolution.

La convolution est une opération linéaire spéciale. Les réseaux convolutifs sont simplement des réseaux de neurones qui utilisent la convolution à la place de la multiplication matricielle dans

au moins une de leurs couches. Ils ont de larges applications dans la reconnaissance de l'image et de la vidéo, les systèmes de recommandations et le traitement du langage naturel [27][28].

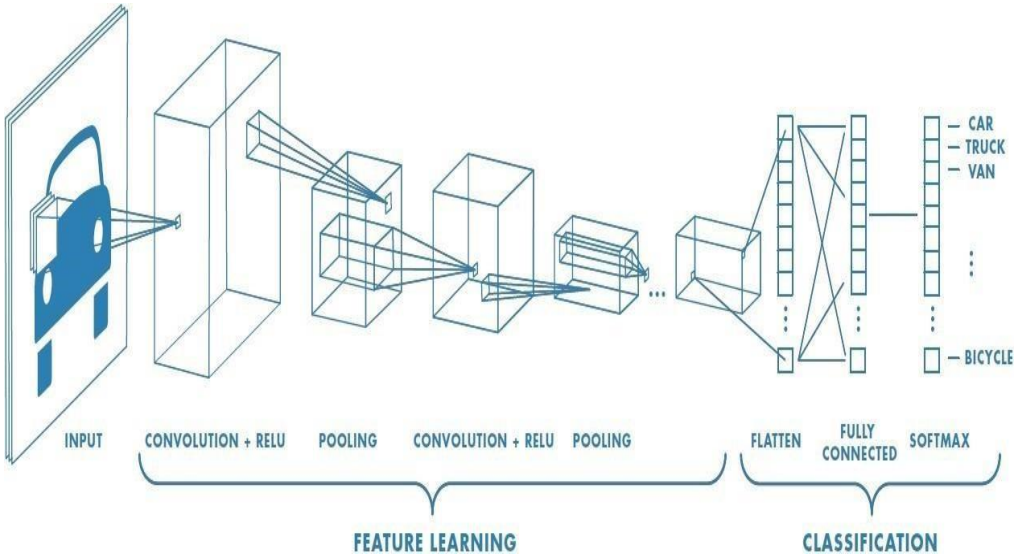


Figure II-8 : les couches Convolutional Neural Network (CNN).

- **Les couches *de* Convolutional Neural Network (CNN) :**

- **Couche convolutive** : une couche convolutive est la première couche qui extrait les caractéristiques de l'image d'entrée. Les convolutions préservent la relation entre les pixels en apprenant les caractéristiques d'une image à l'aide de petits carrés de données d'entrée. C'est une opération mathématique qui prend deux entrées telles qu'une matrice d'image et un filtre ou un noyau



Figure II-9 : Exemple explicative sur l'opération de convolution.

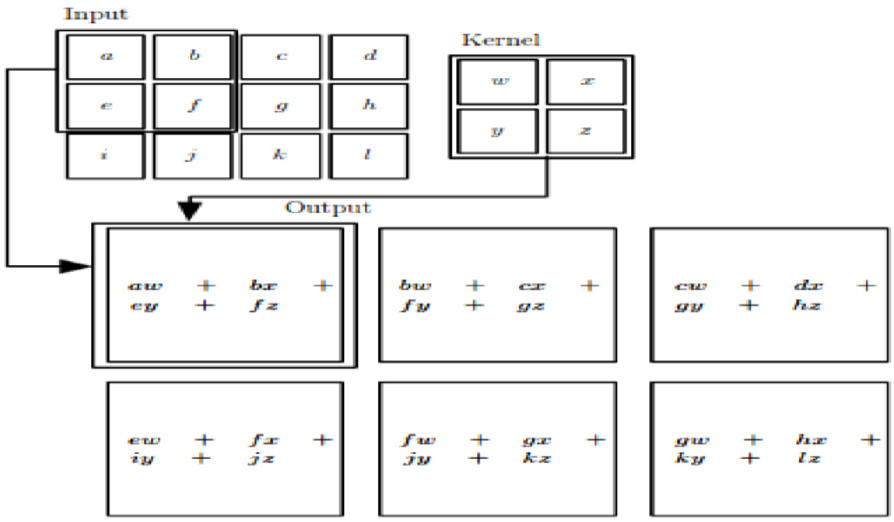


Figure II-10 : Exemple d'une convolution 2D.

1. (Dizaines ou des centaines de pixels : Cela signifie que nous pouvons stocker moins de paramètres, ce qui réduit les besoins en matière de mémoire du modèle et améliore son efficacité. Cela signifie également que le calcul des sorties nécessite moins d'opérations. Ces améliorations en matière d'efficacité sont généralement assez importantes. Figure (10) Couche de pooling) [29].

- **Couche de pooling** : La couche pooling généralement placé entre deux couches de convolution, le pooling est un processus de discrétisation à base d'échantillon. L'objectif est à en-bas-de-promotion une représentation de contribution (l'image, la matrice de production de cacher-couche, etc.), en réduisant sa dimensionnalité et en tenant compte des hypothèses à être rendues des caractéristiques contenues dans les sous-régions regroupées. Il existe différents types de pooling : *(1)* Pooling moyenqui prend la moyenne de tous les pixels de la sélection Figure 11 *(a), (2)* Pooling maximalqui prend le pixel qui a la valeur maximale entre tous les pixels de la sélection.

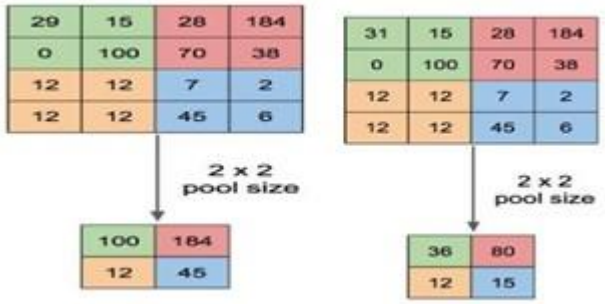


Figure II-11 : a) Pooling Moyne, b) Pooling maximal.

- **Couche fully-connected**: La couche entièrement connectée est similaire au réseau entièrement connecté dans les modèles conventionnels. La sortie de la première phase (comprenant la convolution et la mise en commun répétitive) est introduite dans la couche entièrement connectée, et le produit scalaire du vecteur de poids et du vecteur d'entrée est calculé afin d'obtenir la sortie finale.

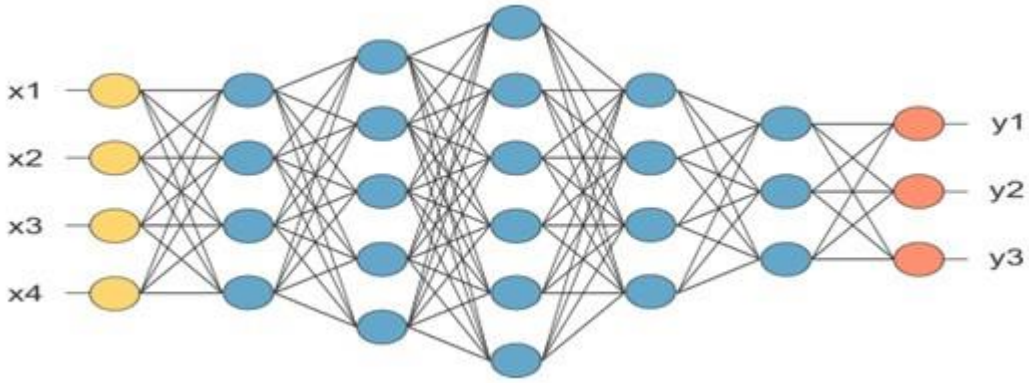


Figure II-12 : Couche fully-connected.

II.2.2.1.2 Réseaux Neuronaux Récurrents (RNN) :

Les Réseaux Neuronaux Récurrents (RNN) sont une variante très importante de réseaux neuronaux lourdement utilisés dans le traitement de langue naturelle. Ils sont appelés récurrents car ils effectuent la même tâche pour chaque élément d'une séquence, la sortie dépendant des calculs précédents. Une autre façon de penser aux RNN est qu'ils ont une « mémoire » qui capture des informations sur ce qui a été calculé jusqu'à présent. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais en pratique, ils se limitent à ne regarder que quelques étapes en arrière. Les RNN sont une classe de réseaux de neurones qui permettent aux prédictions antérieures d'être utilisées comme entrées, par le biais d'états cachés.

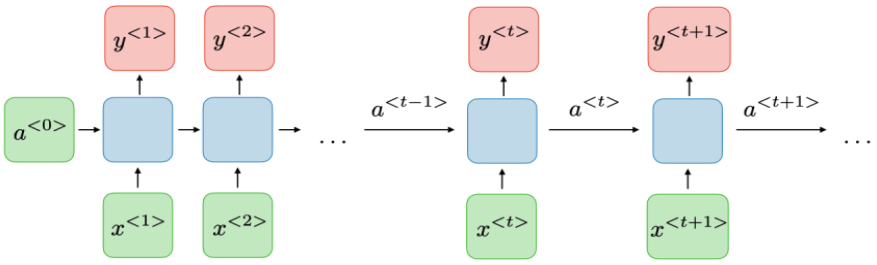


Figure II-13 : Architecteur de RNN.

II.3 Conclusion :

Dans ce chapitre, nous avons appris ce qu'est l'apprentissage en profondeur et en quoi il diffère des algorithmes d'apprentissage automatique traditionnels. Nous avons été témoins de plusieurs jalons dans son développement et de ce qui a été réalisé. Nous présentons quelques méthodes communautaires d'apprentissage en profondeur et expliquons les principes sous-jacents à chacune. Nous avons également discuté de Deux grandes familles de modèles, à savoir les réseaux convolutifs.

Chapitre III : Classification des images et interprétation des résultats

Chapitre III : Classification des images et interprétation des résultats

III.1 Introduction

La classification des images peut être définie comme la distribution du système Images selon des catégories précédemment connues. Alors classer une image c'est son fait correspond à une classe, marquant ainsi ses affinités avec d'autres images. Donc, la classification des images est de construire un système qui peut attribuer automatiquement des classes aux images.

Ce chapitre vise à montrer l'efficacité de l'application Classifier Learner pour classer les images et sa capacité à utiliser plusieurs méthodes de classification à la fois et à choisir la méthode la plus appropriée, ce qui permet de gagner un temps considérable. En outre, il fournit un guide pratique pour catégoriser les images d'une manière simple et efficace qui peut être utilisé pour des projets similaires à l'avenir

III.2 Bases de données

Il y a plusieurs bases de données contient des images stellaires comme « Dataset-RSI-CB128 » et « Dataset-RSI-CB256 » et nous choisit la base de données Dataset-RSI-CB256 par ce que « Dataset-RSI-CB128 » contient plus que 35 fichiers qui contient images multi-objet et 1.8 Go stockage, en contraire « Dataset-RSI-CB256 » elle contient 4 fichiers des images clair et mono-objet en plus le contenu de cette image est simple. En plus, Dataset-RSI-CB256 disponible est facile de télécharger online depuis n'importe quel navigateur.

En conséquence, pour entrainer et testé les algorithmes par l'application « classification learner » du Matlab nous avant utilisé les images stellaires de la base de données « Dataset-RSI-CB256 ».

❖ **La Base de données (Dataset-RSI-CB256) :**

L'ensemble de la base de données contient 5631 images divisé en quatre fichiers dans l'ordre suivant :

- Un fichier contenant des images de nuages nommé « cloudy » contient 1500 images de taille 64*64.
- Un fichier contenant des images de désert nommé « desert » contient 1131 images du taille 64*64

- Un fichier contenant des images d'espaces verts nommé « green_area » contient 1500 images du taille 256*256.
- Un fichier contenant des images de plans d'eau nommé « water » contient 1500 images du taille 256*256.
- Tous les images sont du format « jpg »

La figure III-1 représenté quelques images pour les quatre fichiers

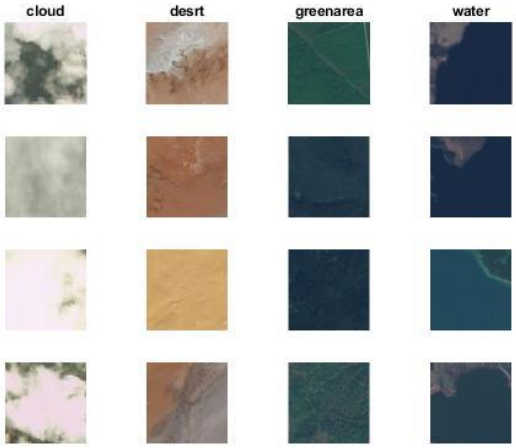


Figure III-1 : quelques images pour les quatre fichiers.

La description de base de données est représentée dans (Tableau III-1)

Tableau III-1 : description de base de données.

Numéro	Class	Nombre d'images	Format
1	cloudy	1500	JPG
2	desert	1131	JPG
3	Green_area	1500	JPG
4	Water	1500	JPG
Total : 5631			

III.3 Les logiciels utilisés

III.3.1 Matlab

Matlab c'est abréviation de « Matrix (Maths) LaBoratory », c'est une plateforme de programmation conçue spécifiquement pour les ingénieurs et les scientifiques afin d'analyser et de concevoir des systèmes et des produits qui transforment notre monde. Le cœur de Matlab est le

langage Matlab, c'est un langage de programmation multi paradigme propriétaire et un environnement informatique numérique développé par Math Works.

Matlab permet de :

- Analyse des données.
- Développement des algorithmes.
- Création des modèles et des applications.
- Manipulations matricielles.
- Traçage des fonctions et des données.
- Mise en œuvre d'algorithme.
- Création d'interfaces d'utilisateurs.
- Création d'interfaçage avec des programmes écrits dans d'autres langages [30].

III.3.2 Matlab classification learner

L'application Classification Learner est un outil interactif présent dans le logiciel Matlab permettant d'effectuer des tâches d'apprentissage comme l'exploration de données, l'extraction de caractéristiques, l'entraînement et la validation de modèles ou l'évaluation de résultats.

Classification Lerner vous permet d'effectuer des tâches courantes d'apprentissage automatique, telles que l'importation de données prétraitées, l'exploration de vos données, la formation rapide de plusieurs modèles, l'évaluation des performances du modèle et les étapes itératives nécessaires pour ajuster les performances du modèle, notamment l'optimisation des hyperparamètres, le coût de mauvaise classification et la sélection des fonctionnalités. Vous pouvez trouver le Classification Learner dans la galerie d'applications ou en tapant Classification Learner sur la ligne de commande MATLAB.

Classification Learner vous permet d'importer des données à partir de matrices ou de tables. L'application peut identifier automatiquement vos prédicteurs et vos variables de réponse en fonction de votre type de données. L'étape suivante consiste à choisir le schéma de validation utilisé pour mesurer la précision du modèle.

Une fois que l'application a chargé les données, vous pouvez choisir parmi plusieurs algorithmes de classification, notamment les arbres de décision, la régression logistique, les machines à vecteurs de support et les arbres boostés. Si vous ne savez pas lequel choisir, l'info-bulle contextuelle vous donne une brève description de chaque classificateur. Les nuages de points

par paires vous permettent d'explorer vos données à la recherche de prédicteurs importants, de valeurs aberrantes et de modèles visuels ou de tendances.

L'entrainement d'un nouveau modèle est facile. Tout d'abord, dans la galerie de modèles, choisissez l'un des préréglages de classificateur ou l'option Train All. Ensuite, cliquez sur Train.

Le volet Modèle actuel affiche des informations utiles sur votre modèle, telles que le type de classificateur, les préréglages, les fonctions sélectionnées et l'état du modèle. Pour chaque modèle formé, vous pouvez voir sa précision dans le panneau Historique et inspecter son erreur de classification dans le nuage de points, consulter la matrice de confusion et consulter les courbes ROC disponibles dans la section Tracé de la barre d'outils.

Ensuite, vous pouvez extraire :

- Scater plot
- Matrice de confusion (confusion matrix of validation data et confusion matrix of test data)
- Courbe ROC (ROC of validation data et ROC of test data) [33].

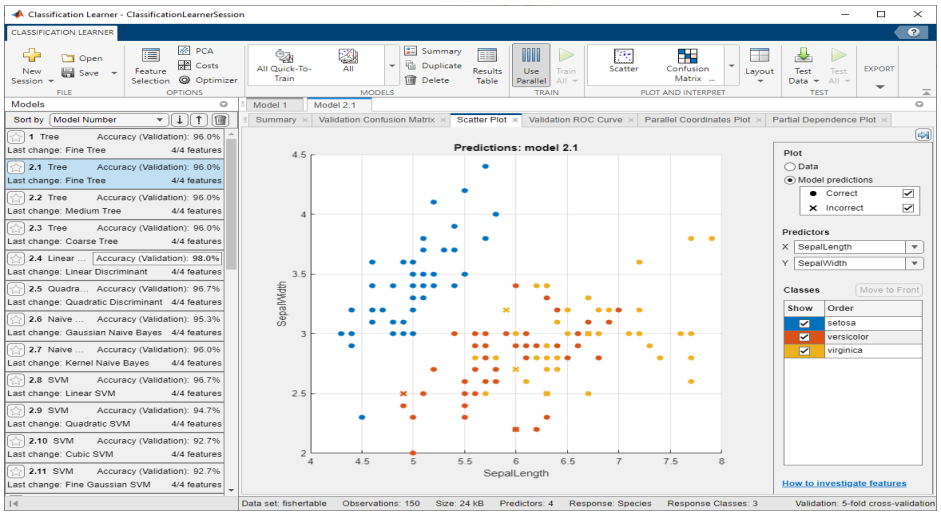


Figure III-2 : capture d'écran montre l'application classificatin learner

III.4 Préparation de la base de données

Nous avant préparé la base de données à l'aide de Matlab par les étapes suivants :

III.4.1 Lire les images

Dans MATLAB, nous avons mis en place un programme qui lit toutes les images de notre base de données en spécifiant le chemin d'accès et le format des images. Voir (Figure III.3)

```
image_folder1 = 'C:\Users\Intel\Desktop\Data\All_DataSet\DataSet\Data\cloud';
image_folder2 = 'C:\Users\Intel\Desktop\Data\All_DataSet\DataSet\Data\desert';
image_folder3 = 'C:\Users\Intel\Desktop\Data\All_DataSet\DataSet\Data\green_area';
image_folder4 = 'C:\Users\Intel\Desktop\Data\All_DataSet\DataSet\Data\water';

filename1 = dir(fullfile(image_folder1,'*.jpg'));
filename2 = dir(fullfile(image_folder2,'*.jpg'));
filename3 = dir(fullfile(image_folder3,'*.jpg'));
filename4 = dir(fullfile(image_folder4,'*.jpg'));

total_images1 = numel(filename1);
total_images2 = numel(filename2);
total_images3 = numel(filename3);
total_images4 = numel(filename4);
```

Figure III-3 : capteur d'écran montre le chemin d'accès et le format des images d'un programme MATLAB.

Nous avons créé une boucle pour parcourir chaque classe et effectuer les opérations nécessaires sur les images cette étape montrer dans la figure suivante :

```
for i=1:total_images1
%     lire le fichier de class "cloudy"
    f1 = fullfile(image_folder1, filename1(i).name);
    our_images = imread(f1);
  end
for i=1:total_images2
    %     lire le fichier de class "desert"
    f2 = fullfile(image_folder2, filename2(i).name);
    our_images = imread(f2);
end
for i=1:total_images3
    %     lire le fichier de class "green_area"
    f3 = fullfile(image_folder3, filename3(i).name);
    our_images = imread(f3);
end
for k=1:total_images4
    %     lire le fichier de class "water"
    f4 = fullfile(image_folder4, filename4(k).name);
    our_images = imread(f4);
end
```

Figure III-4 : capture d'écran montrant une boucle qui lit les fichiers d'images.

III.4.2 Séparer les matrices

La séparation d'une image en trois matrices correspondant aux canaux de couleur (rouge, vert et bleu) est basée sur le modèle de couleur RVB (Rouge-Vert-Bleu) utilisé dans la

représentation des images numériques. Ce modèle représente chaque pixel de l'image en combinant les intensités des trois couleurs primaires : rouge, vert et bleu.

Pour séparer les canaux de couleur, on utilise l'indexation de la matrice de l'image. Chaque canal de couleur correspond à une matrice bidimensionnelle dans laquelle les valeurs représentent l'intensité de la couleur respective pour chaque pixel. Par exemple, la matrice du canal rouge contient les niveaux d'intensité du rouge pour chaque pixel de l'image, de même pour les canaux vert et bleu.

Voici comment séparer les canaux de couleur dans MATLAB :

```
24        %eéparation des matrices
25 -      redl = our_images(:,:,1);
26 -      greenl = our_images(:,:,2);
27 -      bluel = our_images(:,:,3);
```

Figure III-5 : La séparation des matrices rouge vert et bleu.

La séparation des matrices résumé dans l'organigramme sonné par la Figure III-6 suivant :

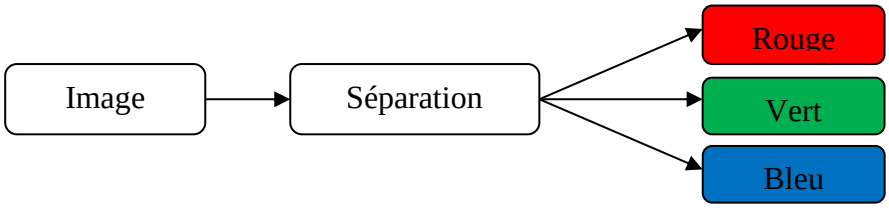


Figure III-6 : organigramme expliqué la séparation matrices.

III.4.2 Extraction des caractéristiques

Nous avons traité les images de notre base de données en extrayant les caractéristiques de chaque matrice rouge, verte et bleue pour chaque image. Nous avons choisi les paramètres Mean, Root Mean Square (RMS), kurtosis et skewness par ce que ces paramètres sont plus connu et facile de calcule. La signification statistique de ces paramètres est mentionnée dans le (Tableau III-2)

Tableau III-2 : les équations des paramètres [31].

Caractéristique	Equation
Mean	$M = \frac{1}{k}\sum_{k=1}^{K} x(k)$
Root Mean Square (RMS)	$RMS = \sqrt{\frac{\sum_{k=1}^{K}(x(k))^2}{k-1}}$
Skewness	$SK = \frac{\sum_{k=1}^{K}(x(k)-xm)^2}{(K-1)x_{std}^3}$
Kurtosis	$K = \frac{\sum_{k=1}^{K}(x(k)-xm)^2}{(K-1){x_{std}}^3}$

Voici comment nous calculer ces paramètres dans Matlab

```
29        %clacule la moyenne de chaque image
30 -      m_cloud(1,i) = mean(mean(red1));
31 -      m_cloud(2,i) = mean(mean(green1));
32 -      m_cloud(3,i) = mean(mean(blue1));
33 -      m_cloud_tran = m_cloud.';
```

Figure III-7 : capture d'écran d'un programme Matlab qui calculé la moyenne.

L'organigramme suivant (Figure III-8) résumé commente on a calculé ces paramètres

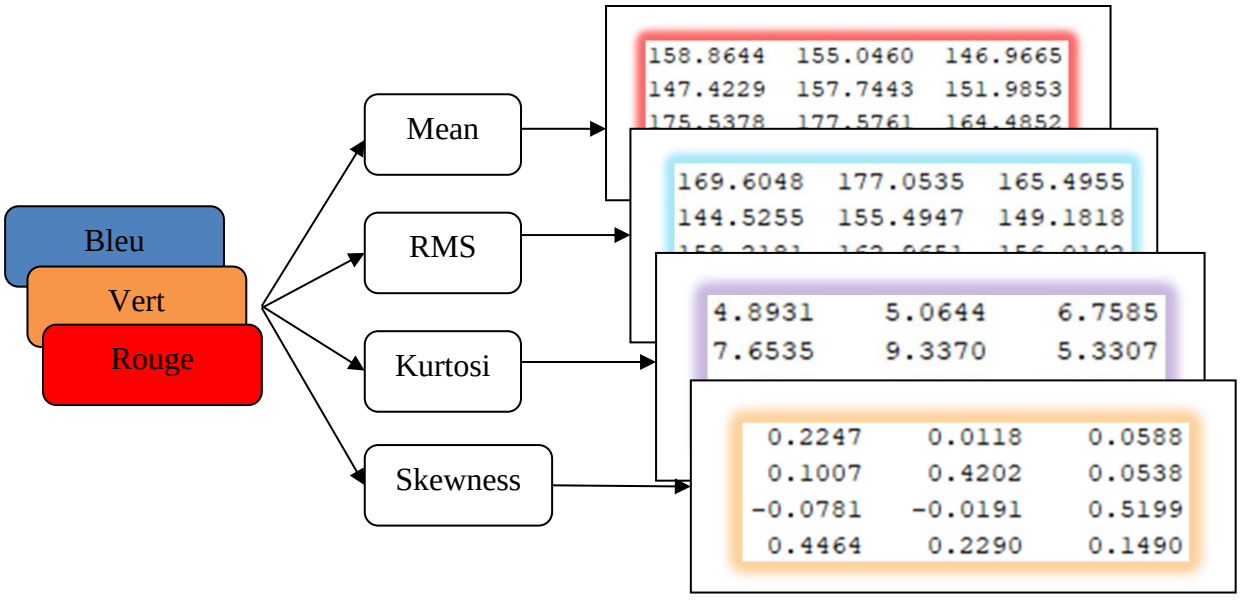


Figure III-8 : Extraction des caractéristiques.

III.4.3 Sauvegarde

Après obtention de ces tableaux, ils sont enregistrés dans un fichier Excel comme le montre Figure III-9,

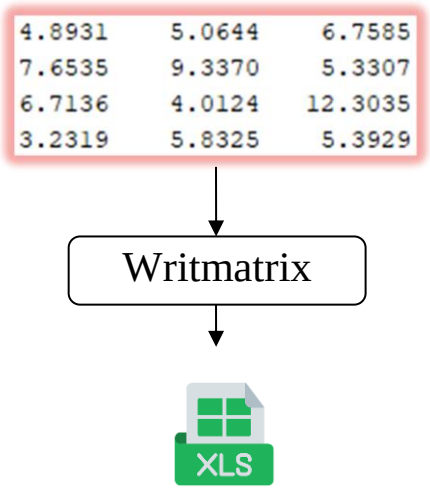


Figure III-9 : Sauvegarde les tableaux des caractéristiques dans un fichier Excel.

Dans cette étape nous avant organisé les tableaux dans Excel est spécifie les classes et les catégories de chaque fichier, nous avons organisé les tableaux obtenus en calculant les différents paramètres (moyenne RMS et kurtosis) pour chaque matrice (rouge, vert et bleu), donc on obtient 9 colonnes de paramètres pour chaque image (ligne) comme le montre la Figure III.10 .

	A	B	C	D	E	F	G	H	I	J	K
1	class	red	green	bleu	red	green	bleu	red	green	bleu	data_type
2	1	158,864426	155,045959	146,966461	-0,19263066	-0,22492892	-0,18297295	2,92269774	3,6490533	2,26126653	cloudy
3	1	147,422882	157,744278	151,985291	0,89907877	0,88301012	0,60500799	5,2285908	3,79153395	4,73989473	cloudy
4	1	175,537811	177,576111	164,485168	0,86725523	0,906313	1,53186	6,65445009	6,3767894	19,5777698	cloudy
5	1	141,707413	152,714661	146,204468	-0,27267336	0,03133341	-0,16414872	3,49035009	3,36376197	7,41174101	cloudy
6	1	179,05304	186,052979	179,064941	0,07910018	0,05419048	0,03933755	5,43737224	5,70101188	4,69779496	cloudy
7	1	214,306076	203,889038	207,575699	0,71237633	-0,18540683	-0,47440364	7,55062312	6,89884657	23,7933909	cloudy
8	1	125,526657	129,364563	118,576324	0,2530022	0,26266429	0,21727727	4,22282307	6,14785961	7,23342441	cloudy
9	1	170,074432	159,624573	137,635239	-0,19285957	0,05868178	-0,00728464	2,24803659	2,95946234	2,64633552	cloudy
10	1	127,604965	136,436371	125,525787	0,17519869	0,0836063	0,38993563	3,49986294	3,84500229	4,14961744	cloudy
11	1	118,888474	125,894638	117,98175	0,21906753	0,48643422	0,31645378	11,2982591	14,5484842	8,14637762	cloudy
12	1	167,366943	163,320221	152,437119	1,10017638	1,19383704	0,84737138	5,74407863	4,07179332	3,40389612	cloudy
13	1	173,49913	167,873245	153,625305	0,8552432	1,19056557	1,01798536	3,15628597	7,42305236	6,68740725	cloudy
14	1	141,922424	147,202332	140,514069	0,29683321	0,33523725	0,42842597	4,4151308	3,83505841	6,8879462	cloudy
15	1	130,511444	137,006744	128,525085	1,49184631	0,92699124	0,17874589	92,9410953	33,4379925	58,4358274	cloudy
16	1	181,738785	185,311234	177,619965	-0,78823513	-0,75455062	-0,71985784	6,50699893	6,21234979	6,11166505	cloudy
17	1	146,949951	155,02597	144,386902	0,67064958	0,47508008	0,54369455	6,69649342	4,6954055	29,3372929	cloudy
18	1	168,623886	173,381378	166,321655	0,11310018	0,37773701	0,67159174	3,42887027	7,41404351	8,6424775	cloudy
19	1	179,216873	181,052811	168,098709	0,27143834	0,55186289	0,37338395	4,10322422	3,88049521	4,08053849	cloudy

Figure III-10 : capteur d'écran représente un exemple d'un data.

III.4.4 Segmentations de la base des données

Nous avons divisé les données préalablement préparées,sous la forme d'un fichier excel,en deux groupes comme suit :

- 1er groupe : 75% des images pour la partie d'entrainement du réseaux neurones.

- 2eme groupe : Les 25% des images qui reste seront réservé pour la phase validation et test du réseau neurone.

La division de la base de données est représentée dans (Figure III-11)



Figure III-11 : Segmentations de la base de données.

L'organigramme donné par la Figure III-12 récapitule toutes les étapes effectuées jusqu'à maintenant.

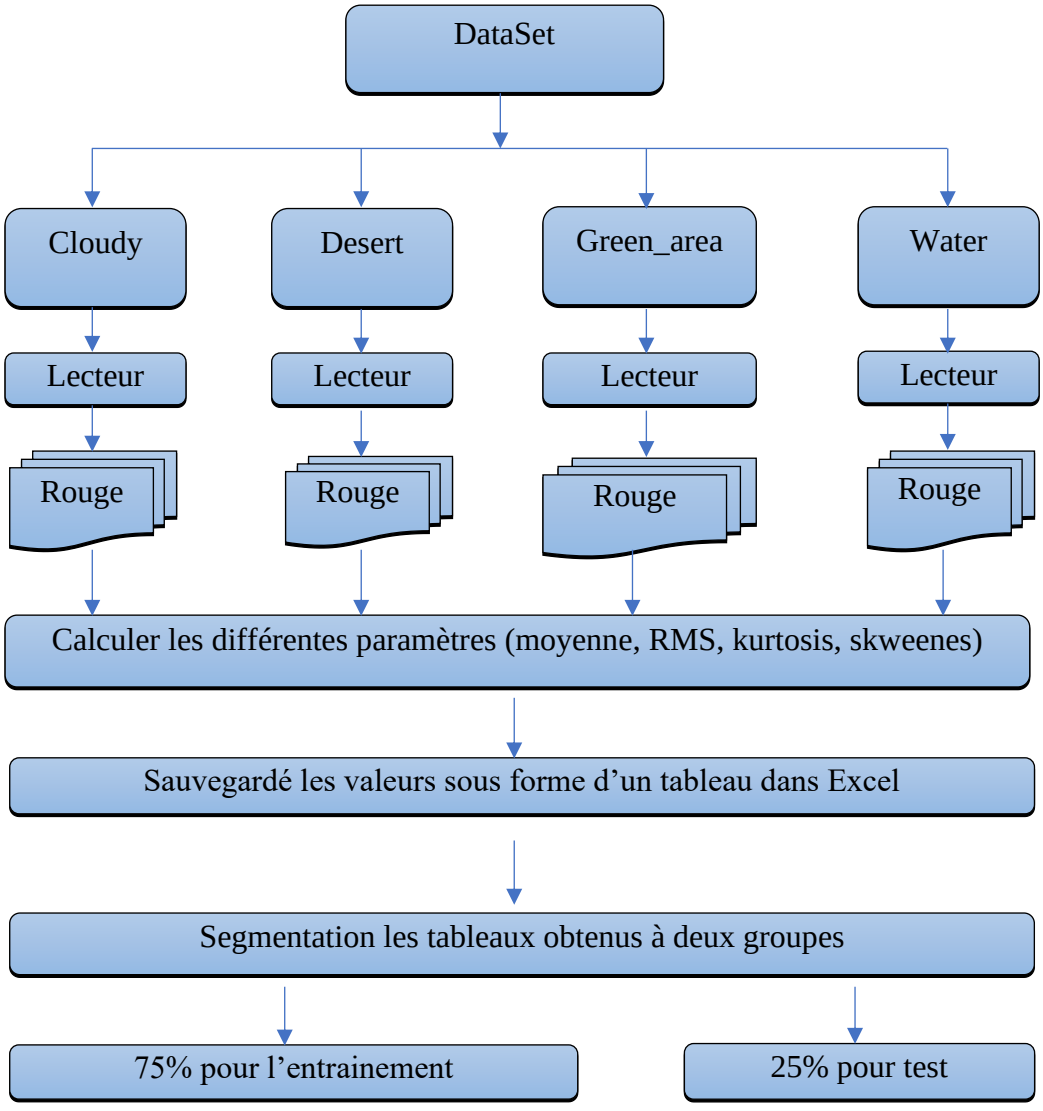


Figure III-12 : Organigramme résumé les étapes de préparation de la base de données.

III.5 Classifications les images

III.5.1 Les étapes pour classifier les données par Classifier Learner

A l'aide de « Classification Learner » nous avons classifié les images a partit des fichiers Excel obtenu dans l'étape de préparation de la base de données, nous avant suivez les étapes suivantes :

1. Lancement de l'application « Classification Learner »

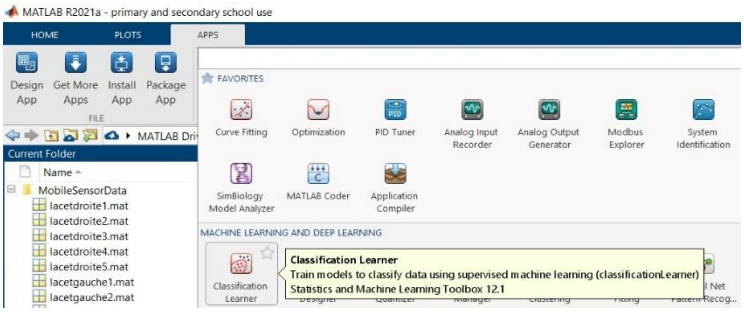
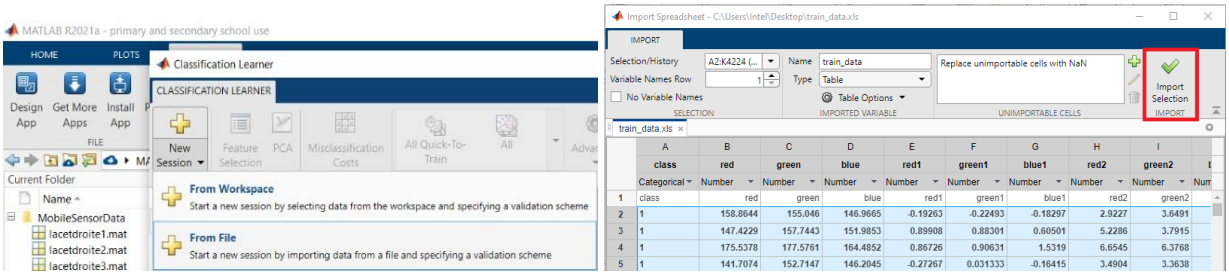
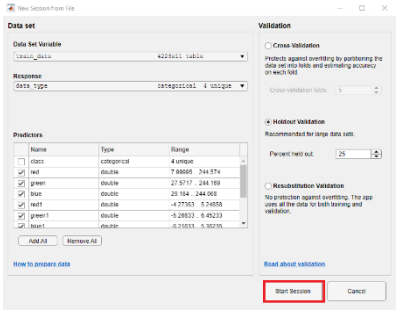


Figure III-13 : l'ouverture de classification learner.

1. Importation des données d'apprentissage : Pour importer les données il suffit d'appuyé sur New sesion → from files → charger le fichier → charger le fichier → Mean_Trainin_DataSet.xls



(a) (b)



(c)

Figure III-14 : les figures (a) (b) et (c) représente les étapes d'Importation des données.

2. Choix d'un modèle d'apprentissage : Classifier Learner permet de sélectionner un, plusieurs ou tous les modèles (nous sélectionné tous les modelés comme le montre la Figure III-15).

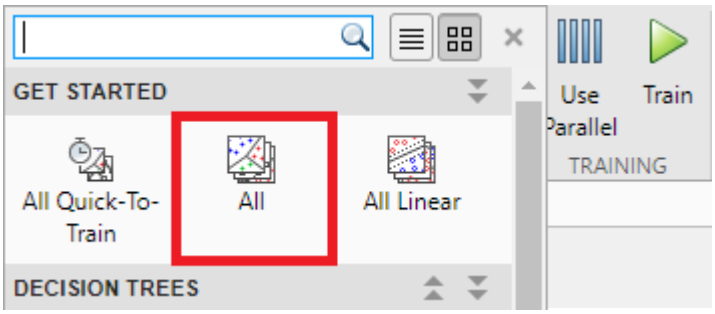


Figure III-15 : Choix le modèle d'apprentissage.

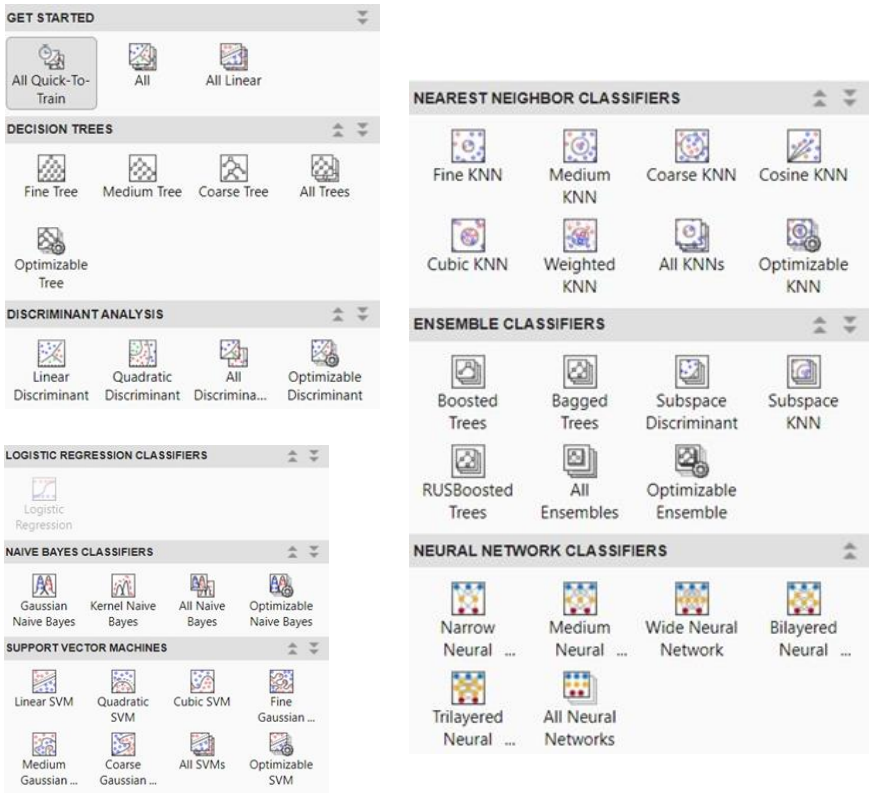


Figure III-16 : Galerie des modèles de classification disponibles.

3. Appuyé sur le bouton 'train' pour lancer l'entrainement de tous les modèles (Figure III-17).

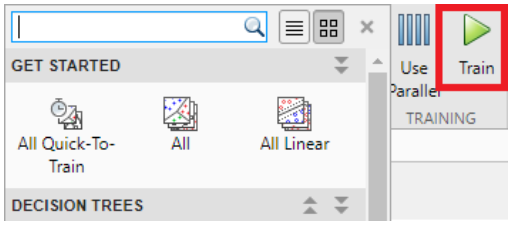


Figure III-17 : l'entrainement de tous les modèles.

A la fin de la phase de l'entraînement, on peut afficher la « validation Accuracy of training » de chaque algorithme (Figure III-18)

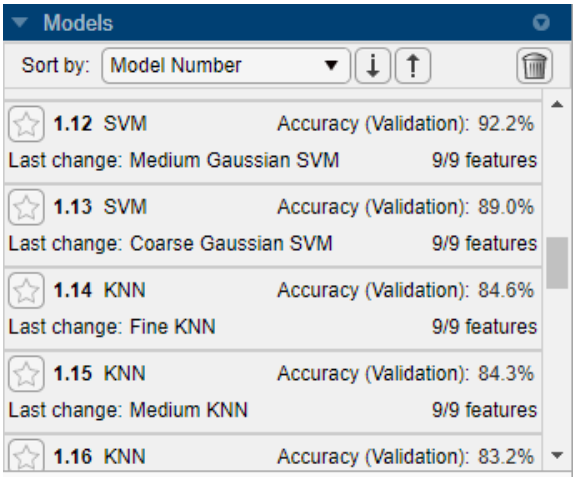


Figure III-18 : validation Accuracy of training.

Aussi, les résultats peuvent être affichés sous différentes formes, par exemple sous la forme d'un nuage de points, comme la montre la Figure III-19, ou sous la forme d'une matrice de confusion comme le montre la Figure III-20, ou sous la forme de un graphe ROC, comme illustré à la Figure III-20 III-21.

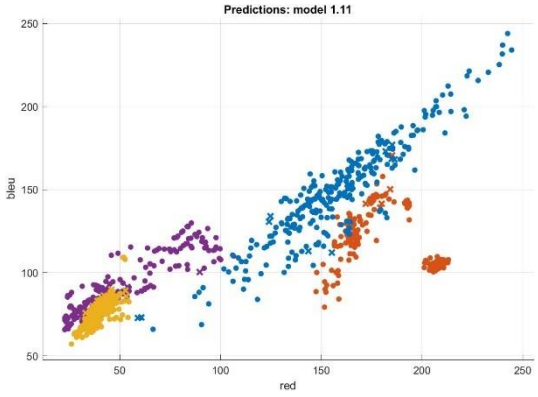


Figure III-19 : Scatter plot affichiez distribution des données après l'entrainement.

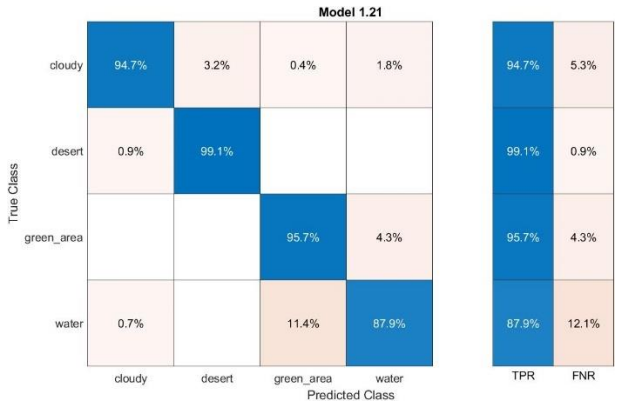


Figure III-20 : Matrice de confusion de l'entrainement

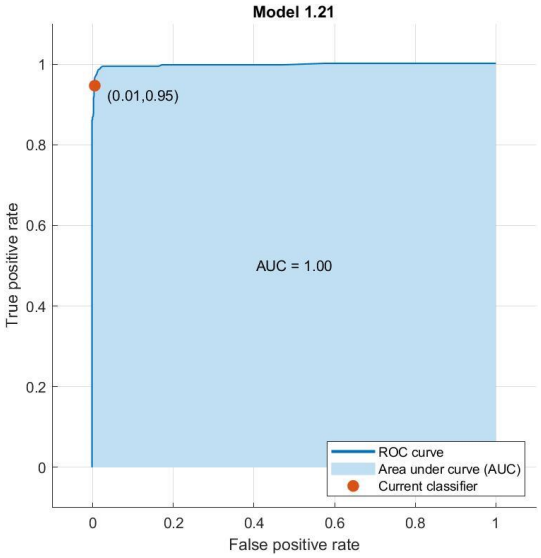


Figure III-21 : ROC graphe de l'entrainement.

4. Importation des données de test « test data ».
   La Figure III.22 montre comment importer les données par l'application CL

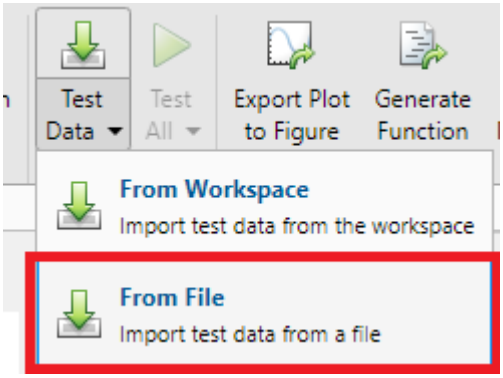
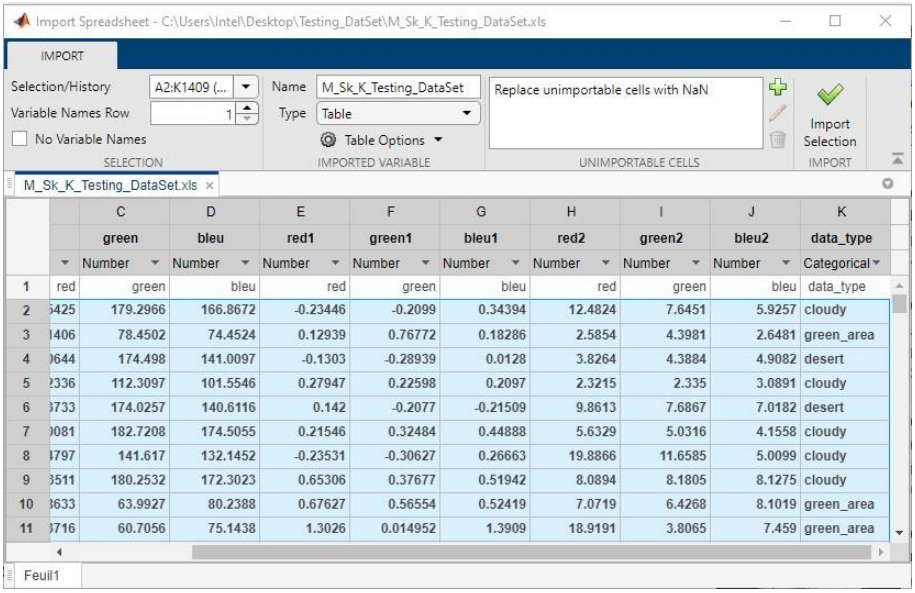


Figure III-22 : Capture d'écran représente comment importer les données de test.



	C	D	E	F	G	H	I	J	K
	green	bleu	red1	green1	bleu1	red2	green2	bleu2	data_type
	Number	Number	Number	Number	Number	Number	Number	Number	Categorical
1	red	green	bleu	red	green	bleu	red	green	bleu	data_type
2	5425	179.2966	166.8672	-0.23446	-0.2099	0.34394	12.4824	7.6451	5.9257	cloudy
3	1406	78.4502	74.4524	0.12939	0.76772	0.18286	2.5854	4.3981	2.6481	green_area
4	0644	174.498	141.0097	-0.1303	-0.28939	0.0128	3.8264	4.3884	4.9082	desert
5	2336	112.3097	101.5546	0.27947	0.22598	0.2097	2.3215	2.335	3.0891	cloudy
6	3733	174.0257	140.6116	0.142	-0.2077	-0.21509	9.8613	7.6867	7.0182	desert
7	0081	182.7208	174.5055	0.21546	0.32484	0.44888	5.6329	5.0316	4.1558	cloudy
8	4797	141.617	132.1452	-0.23531	-0.30627	0.26663	19.8866	11.6585	5.0099	cloudy
9	3511	180.2532	172.3023	0.65306	0.37677	0.51942	8.0894	8.1805	8.1275	cloudy
10	3633	63.9927	80.2388	0.67627	0.56554	0.52419	7.0719	6.4268	8.1019	green_area
11	3716	60.7056	75.1438	1.3026	0.014952	1.3909	18.9191	3.8065	7.459	green_area

Figure III-23 : Capture d'écran représente les données de test.

1. Testez différents algorithmes de classification avec des données de test

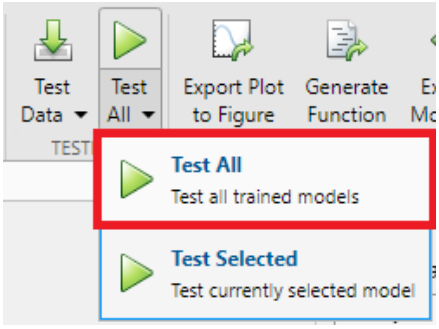


Figure III-24 : Capture d'écran de lancement test de données par l'application CL.

Après cette étape on obtient la « testing Accuracy of training » pour chaque algorithme (Figure III-25)

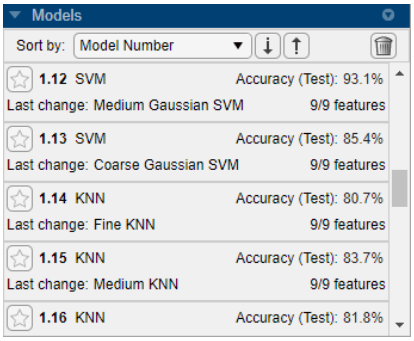


Figure III-25 : Capture d'écran de « testing Accuracy of training ».

En suite les résultats de test peuvent être afficher par la « confusion matrix of test » comme le montre la Figure III-26 ou par ROC graphe comme le montre la Figure III-27

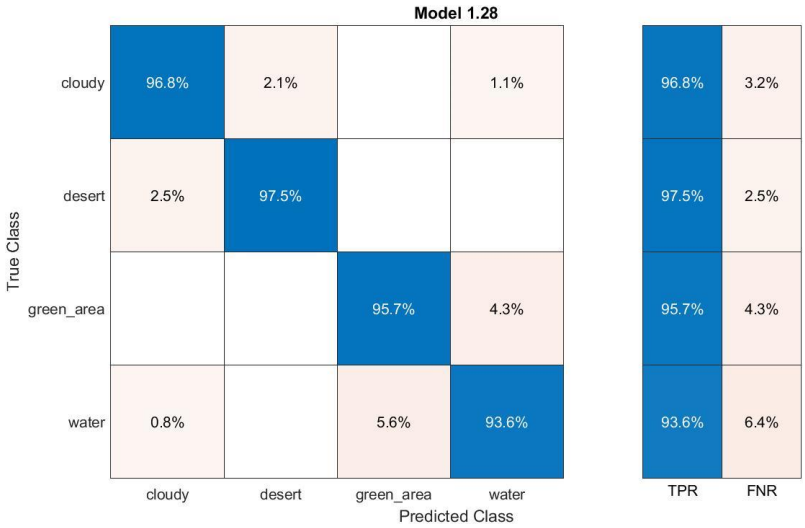


Figure III-26 : Capture d'écran d'une matrice de confusion de test.

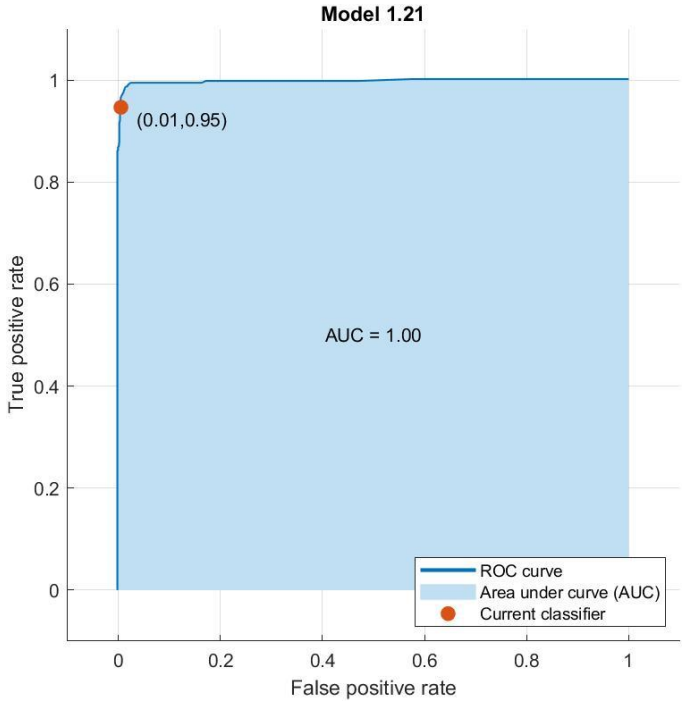


Figure III-27 : ROC graphe de l'entrainement.

III.5.2 Les modèles utilisés

L'application CL utilisé machine Learning pour classifier les données, le tableau III-3 récapitule les machines Learning les plus connues,

Tableau III-3 : Les modèles de classification dans l'application CL [32].

Type de classificateur	Vitesse de prédiction	Memory Usage	Interpretability	Model Flexibility
Coarse Tree 	Rapide	Petite	Facile	Faible Quelques feuilles à mon ke distinctions grossières entre les classes (le nombre maximum de divisions est de 4).
Medium Tree 	Rapide	Petite	Facile	Moyen Nombre moyen de feuilles pour des distinctions plus fines entre les classes (le nombre maximum de divisions est de 20).
Linear Discriminant 	Rapide	Petite	Facile	Faible Crée des frontières linéaires entre les classes.
Quadratic Discriminant 	Rapide	Large	Facile	Faible Crée des frontières non linéaires entre les classes (ellipse, parabole ou hyperbole).
Gaussian Naive Bayes 	Moyen Lent pour les données de grande dimension	Petit Support pour données de grande dimension	Facile	Faible Vous ne pouvez modifier aucun paramètre pour contrôler la flexibilité du modèle.
Kernel Naive Bayes 	Lente	Moyen	Facile	Moyen Vous pouvez modifier les paramètres de type et de prise en charge du noyau pour contrôler la manière dont le classifieur modélise les distributions des prédicteurs.
Linear SVM 	Binaire : Rapide Multiclasse : Moyen	Moyen	Facile	Faible Crée une simple séparation linéaire entre les classes.
Bilayered Neural Network 	Rapide	Moyen	Dure	Élevé - augmente avec la taille de chaque paramètre de couche entièrement connecté
Quadratic SVM 	Binaire : Rapide Multiclasse : Lent	Binaire : moyen Multiclasse : Grand	Dure	Moyen
Logistic Regression 	Rapide	Moyen	Facile	Faible Vous ne pouvez modifier aucun paramètre pour contrôler la flexibilité du modèle.
Fine KNN 	Medium	Moyen	Dure	Distinctions finement détaillées entre les classes. Le nombre de voisins est fixé à 1.
Cosine KNN 	Medium	Moyen	Dure	Distinctions moyennes entre les classes, à l'aide d'une métrique de distance cosinus. Le nombre de voisins est fixé à 10.
Narrow Neural Network 	Rapide	Moyen	Dure	Moyen - augmente avec la taille de chaque paramètre de couche entièrement connecté

III.6 Les résultats obtenus

Dans l'étape de traitement des données, nous avons procédé à une augmentation des données afin d'améliorer l'apprentissage et d'accroître la quantité de données. Par conséquent, au lieu de trois variables, nous disposons désormais de neuf variables.

Nous avons développé l'application en utilisant exclusivement des données qui contiennent des moyennes, et les résultats des tests sont satisfaisants. De plus, nous avons formé les données en incluant trois variables (moyenne RMS K), (RMS SK K) (moyenne SK K) et les résultats des expérimentations ont également démontré de bons résultats.

Après avoir effectué plusieurs tests, nous avons obtenu les résultats pour chaque type de données. Nous avons représenté le meilleur modèle pour chaque type de données en termes de :

- Précision
- Matrice de confusion
- ROC

III.6.1 Précision

Pour la précision, nous avons sélectionné les modèles ayant le pourcentage de test le plus élevé. Les résultats de précision des 10 premiers meilleurs modèles en termes de pourcentage d'entraînement, de temps d'entraînement et de pourcentage de test pour chaque type de caractéristique sont représentés par les tableaux III-4 jusqu'à III-7,

Tableau III-4 : Les résultats de précision de 10 premiers modelés (caractéristique : Moyenne M).

Méthodes	Entrainement		Test
	Temps(s)	Précision (%)	Précision (%)
Wide Neural Network	6.1543	92.5%	92.2%
Subspace KNN	6.5504	91.6%	93.3%
Weighted KNN	1.1983	94.8%	95.5%
Fine KNN	1.3725	94.8%	95.0%
Bagged Trees	5.9358	94.4%	94.7%
Medium Neural Network	22.6230	95.1%	95.7%
Fine Gaussian SVM	2.7532	94.8%	95.7%
Cubic SVM	301.63	82.6%	83.8%
Bilayered Neural Network	22.962	94.2%	94.2%
Trilayered Neural Network	25.058	94.3%	94.2%

Tableau III-5 : Les résultats de précision de 10 premiers modelés (caractéristiques : Moyenne M, Skewness Sk et Kurtosis K).

Méthodes	Entrainement		Test
	Temps(s)	Précision (%)	Précision (%)
Trilayered Neural Network	11.8800	93.4%	96.2%
Narrow Neural Network	6.9303	93.1%	95.0%
Bilayered Neural Network	8.7403	92.5%	95.0%
Quadratic SVM	7.958	92.9%	94.9%
Bagged Trees	2.3368	93.1%	94.1%
Subspace KNN	2.2184	91.3%	94.0%
Medium Neural Network	8.4274	92.5%	93.8%
Cubic SVM	38.075	92.0%	93.6%
Medium Gaussian SVM	1.107	90.9%	93.5%
Boosted Trees	2.9200	91.6%	92.9%

Tableau III-6 : Les résultats de précision de 10 premiers modelés (caractéristiques : RMS, Skewness Sk et Kurtosis K).

Méthodes	Entrainement		Test
	Temps(s)	Précision (%)	Précision (%)
Trilayered Neural Network	9.0164	86.1%	87.6%
Narrow Neural Network	7.5258	87.5%	88.7%
Bilayered Neural Network	8.0894	85.8%	87.5%
Quadratic SVM	14.928	86.1%	87.4%
Bagged Trees	2.8273	86.7%	87.0%
Subspace KNN	9.561	86.8%	87.0%
Medium Neural Network	1.3183	84.3%	85.9%
Cubic SVM	100.66	86.4%	84.9%
Medium Gaussian SVM	24.1	83.2%	84.5%
Boosted Trees	2.7523	82.1%	84.9%

Tableau III-7 : Les résultats de précision de 10 premiers modelés (caractéristiques : Moyenne M, RMS et Kurtosis K).

Methodes	Entrainement		Test
	Temp(s)	Précision (%)	Précision (%)
Boosted Trees	4.5409	93.7%	96.2%
Kernel Naive Bayes	3.9486	87.5%	95.1%
RUSBoosted Trees	7.4706	93.4%	95.0%
Medium Gaussian SVM	4.7268	93.8%	94.6%
Bagged Trees	4.1778	95.1%	93.3%
Subspace KNN	7.2168	94.9%	92.1%
Coarse Gaussian SVM	1.1568	91.3%	91.6%
Cubic KNN	1.3444	89.3%	89.3%
Weighted KNN	0.8772	91.6%	98.0%
Medium KNN	1.404	90.5%	88.3%

À partir des tableaux III-4 à III-7, nous avons remarqué que les types de données (M, RMS et SK) et (M SK et K) sont donnés les meilleurs résultats de test, par exemple la méthode Trilayered Neural Network donne une précision de 96.2%, par contre son temps d'entrainement est très élevé (11.88 s) par rapport à la méthode Boosted Trees (4.5409 s). Donc la méthode Boosted Trees donne les meilleurs résultats en termes de temp d'entrainement et précision.

III.6.2 Matrice de Confusion

Les matrices de confusion sont des outils très utiles pour déterminer rapidement si un modèle de classification de données est efficace. Les données qui sont placées sur la diagonale sont correctement classées. Toutes celles qui sont en dehors de la diagonale ont été mal classées par le modèle. Un modèle parfait aurait un score de 100% sur la diagonale et un score de 0% partout ailleurs.

Les matrices confusion dans les Figures III-28 à III-31 résume les résultats de prédictions et permet d'évaluer les performances des meilleurs modèles de CL. Chaque ligne correspond à une classe réelle, chaque colonne correspond à une classe prédite. Nous avons 4 classes d'où notre matrice de confusion est de 4×4.

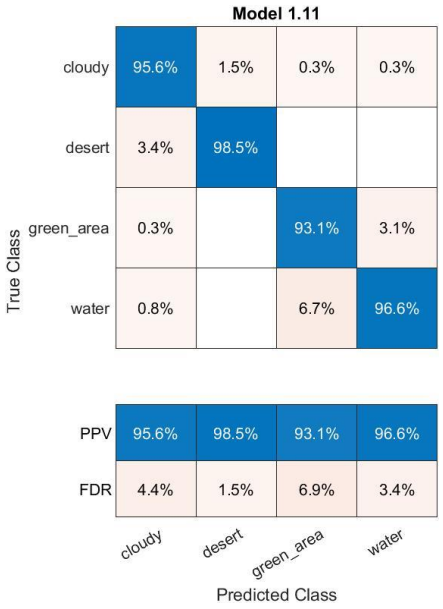


Figure III-28 : matrice de confusion de moyenne data type de modèle Fine Gaussian SVM.

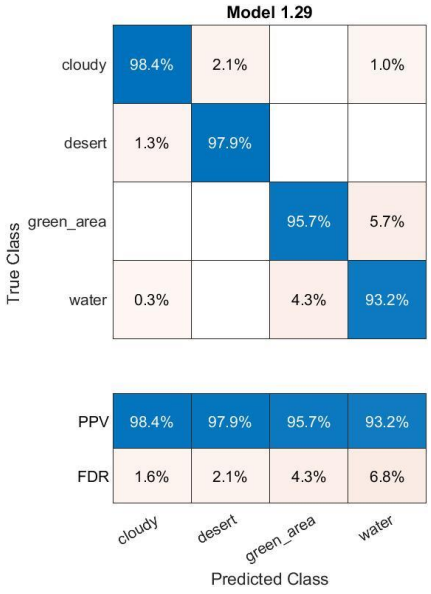


Figure III-29 : matrice de confusion de (M SK K) data type de modèle Trilayered Neural Network.

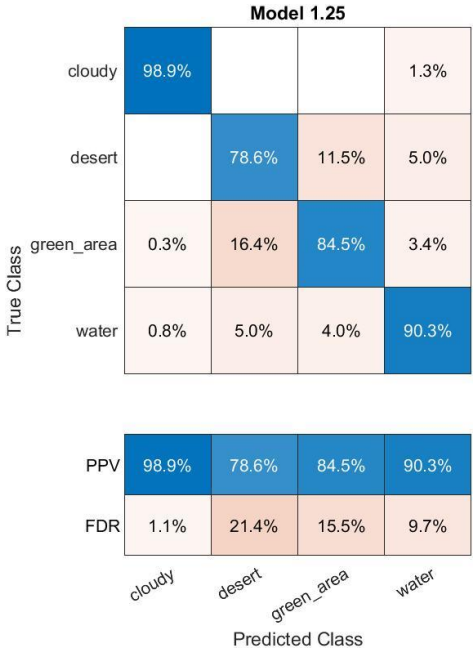


Figure III-30 : matrice de confusion de (RMS SK K) data type de modèle Narrow Neural Network.

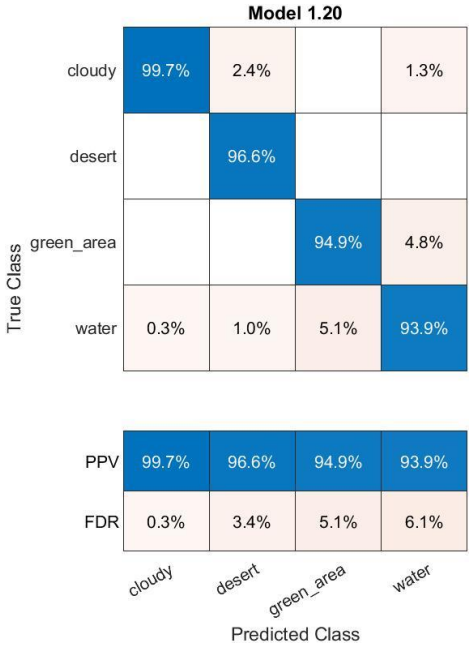


Figure III-31 : matrice de confusion de (M RMS K) data type de modèle Boosted Trees.

D’après l’analyse de ces matrices, nous avons vu que les images de deuxième classe « desert » sont presque bien classées (96.6%), le reste c.à.d. 3.4% sont faussement classées, comme une « cloudy ». Perce que les images de ces deux classes sont similaires (voir figure III-32).

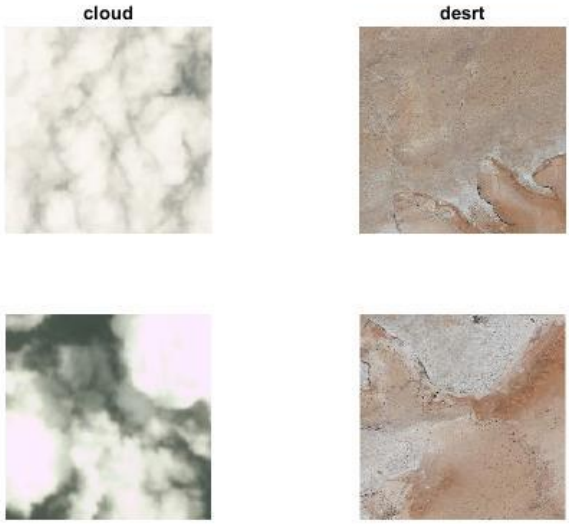


Figure III-32 : deux images de cloud et deux desert.

Concernant les images de la classe « green_area », 6.7% sont faussement classées comme une « water » (4ème classe) car les images sont similaires comme le montre la Figure III-33.

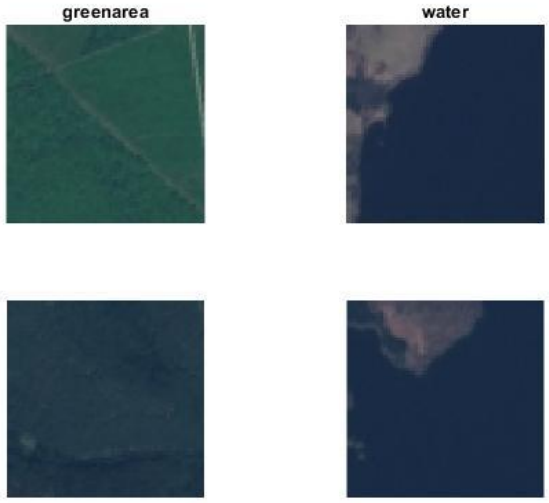


Figure III-33 : deux images de green_area et deux water.

III.6.3 La courbe ROC (Receiver Operating Characteristic)

La courbe ROC est utilisé pour représenter la sensibilité des classificateurs binaires. L'allure de la courbe illustre le compromis réalisé entre sensibilité et spécificité. Elle représente le nombre de vrais positifs en fonction du nombre de faux positifs

La courbe ROC fournit une représentation visuelle des performances d'un modèle de classification binaire à différents seuils de classification. Il vous permet d'évaluer la capacité du modèle à faire la distinction entre les classes positives et négatives et de prendre des décisions éclairées concernant le choix du seuil en fonction du compromis souhaité entre TPR et FPR.

L'aire sous la courbe AUC-ROC (ou Area Under the Curve) est une mesure couramment utilisée pour résumer les performances globales du modèle. Un classificateur parfait aura un AUC-ROC de 1, tandis qu'un classificateur aléatoire aura un AUC-ROC de 0,5.

Les Figures III-34 à III-37 représentent le graphe ROC de test de quatre meilleurs classifier, elles résument les résultats de prédctions et permet d'évaluer les performances des milliers modèle de test.

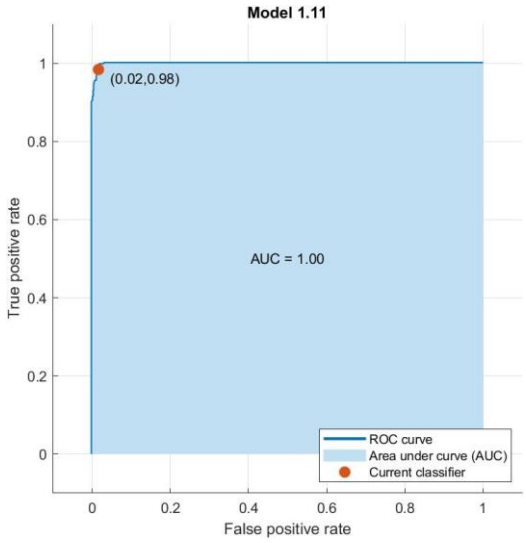


Figure III-34 : ROC graph de moyenne data de modèle Fine Gaussian SVM.

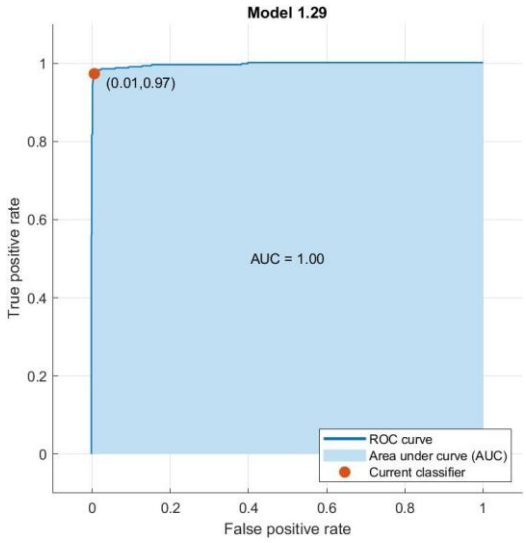


Figure III-35 : ROC graph de(M,SK, K) data type de modèle Trilayered Neural Network.

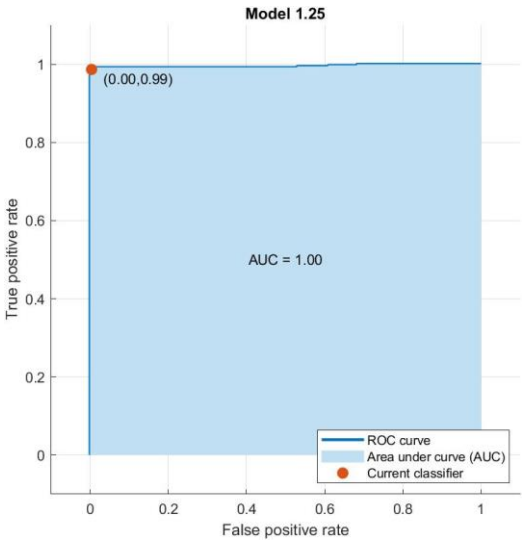


Figure III-36 : ROC graph de (RMS SK K) data type de modèle Narrow Neural Network.

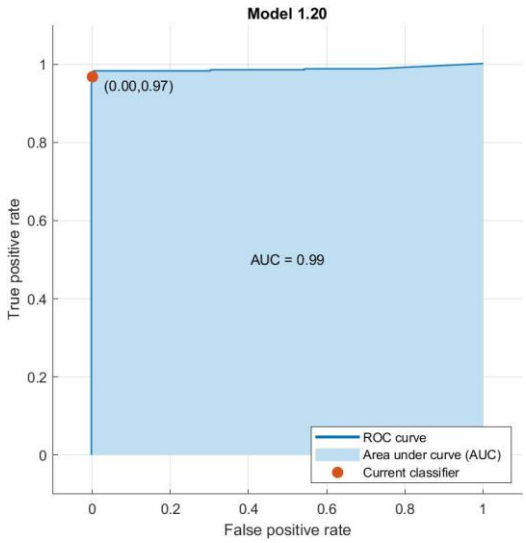


Figure III-37 : ROC graph de (M RMS K) data type de modèle Boosted Trees.

Le marqueur (point rouge) sur le tracé montre les performances du classificateur actuellement sélectionné. Le marqueur affiche les valeurs du taux de faux positifs (FPR) et du taux de vrais positifs (TPR). Par exemple, un taux de faux positifs (FPR) de 0,2 indique que le classificateur actuel attribue de manière incorrecte 20 % des observations à la classe positive. Un vrai taux positif de 0,63 indique que le classificateur actuel attribue correctement 63 % des observations à la classe positive. Un résultat parfait sans point mal classé est un angle droit en haut à gauche du tracé. La surface sous la courbe (AUC) est une mesure de la qualité globale du classificateur. Des valeurs de zone sous les courbes plus grandes indiquent de meilleures performances du classificateur. D'après ces graphes nous avons remarqué que AUC-ROC dans les quatre résultats sont presque 1, c'est-à-dire notre classifier est presque parfait.

Les résultats du meilleur modèle « Boosted Trees» qui donne la plus grande précision sont mentionnés dans le tableau ci-dessous

Tableau III-8 : Les résultats du meilleur modèle « Boosted Trees ».

Entrainement		**Test**
Temp(s)	Précision	Précision
4.54	93.7%	96.2%

III.7 Améliorations d'un modèle

Nous avons essayé d'améliorer la précision de modèle « wide Neural Network » obtenue par la base de données traité par (M, SK et k).

La Figure III.38 représente les paramètres du model « wide Neural Network » avant la modification.

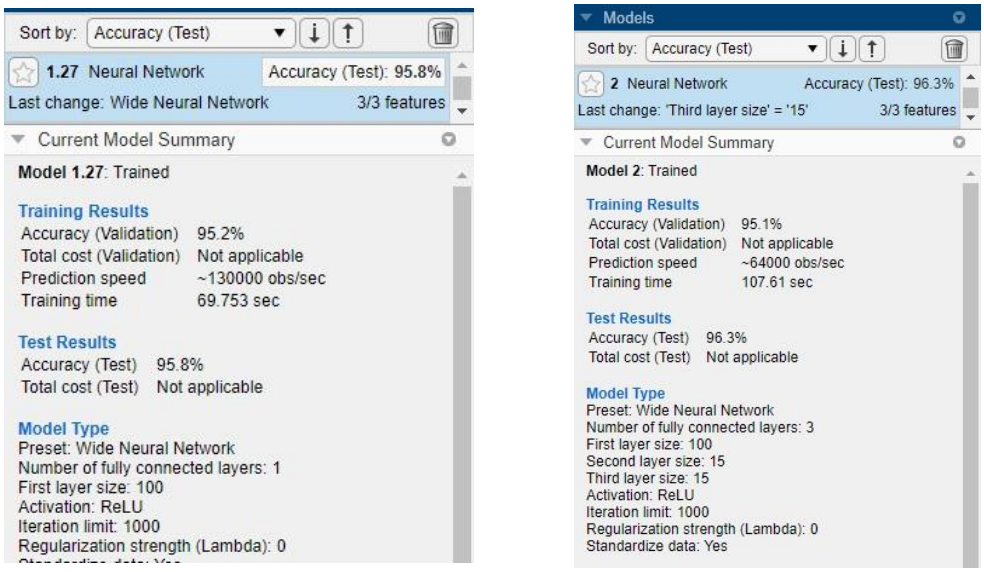
Preset:	wide Neural Network
Number of fully connected layers:	1
First layer size:	25
Activation:	ReLU
Iteration limit:	1000
Regularization strength (Lambda):	0
Standardize data:	Yes

Figure III-38 : les paramètres du model-« Wide Neural Network ».

Nous avons introduit les modifications suivantes pour améliorer notre résultat.

1. Changer « Number of fully connected layers » a “3”.
2. Fixer « First layer size » a 100.
3. Changer « secend layer size » a 15.
4. Changer « third layer size » a 15.

Les Figures III.39 (a) et (b) représentent les paramètres de model avant et après la modification, respectivement.



(a) (b)

Figure III-39 : (a) Représente les paramètres de model avant la modification et (b) après la modification.

Après ces modifications on remarque que la précision est augmentée de 95.8% à 96.3% et le temps de l'entrainement est augment aussi de 69.753 seconde à 107.1 seconde.

III.8 Comparaison

Pour comparaison nous avons recapitulé dans le Tableau III-9 les méthodes de classification qui donnes meilleurs résultats en termes du temps sachant que le temps est très important pour la classification et de précision pour différentes caractéristiques.

Tableau III-9 : les meilleurs modèles obtenus.

		L'entrainement			Test	
L'ordre de data	**Modèle**	**Temp(s)**	**Précision**	**Perte**	**Précision**	**Perte**
Moyenne	**Fine Gaussian SVM**	2.75	94.8%	5.2%	95.7%	4.3%
Moyenne skewness kurtosis	**Trilyered neural network**	11.88	93.4%	6.6%	96.2%	3.8%
RMS skewness kurtosis	**Narraw neural network**	7.52	87.5%	12.5%	88.7%	11.3%
Moyenne RMS kurtosis	**Boosted Trees**	4.54	93.7%	6.3%	96.2%	3.8%

La première ligne du tableau III-9 montre que l'architecteur (Fine Gaussian SVM) est le meilleur modèle pour les caractéristiques (Moyenne) en termes de précision (95.7%) et en terme du temps (2.75 seconde) ce modèle il est rapide.

La deuxième ligne du Tableau III-9 montre que l'architecteur (Trilyered neural network) est le meilleur modèle pour les caractéristiques (Moyenne skewness kurtosis) en termes de précision (96.2%) mais en terme du temps (11.88 seconde) ce modèle il est lent,

La troisième ligne du Tableau III-9 montre que l'architecteur (Narraw neural network) est le meilleur modèle pour les caractéristiques (RMS skewness kurtosis) en termes de précision (88.7%) mais en terme du temps (7.52) ce modèle il est lent.

La quatrième ligne du Tableau III-9 montre que l'architecteur (Boosted Trees) est le meilleur modèle pour les caractéristiques (Moyenne RMS kurtosis) en termes de précision (96.2%) mais en terme du temps (4.54) ce modèle il est rapide.

III.9 Conclusion

En conclusion, l'application Classifier Learner de MATLAB s'est avérée être une méthode simple mais efficace pour classifier des images satellitaires en différentes catégories. En utilisant cette application, nous avons pu classer des images satellitaires en quatre catégories différentes : l'eau, la forêt, le désert et les nuages. Les résultats de la classification ont été évalués et ont montré une précision satisfaisante.

Conclusion Général

Conclusion Générale.

En conclusion, la classification d'images est une tâche essentielle dans le domaine de la vision par ordinateur, et le machine learning joue un rôle clé dans cette entreprise. Le machine learning permet aux ordinateurs d'apprendre à reconnaître et à classer des images en utilisant des algorithmes et des modèles qui sont entraînés sur des ensembles de données annotées.

La classification d'images à l'aide de la machine learning présente plusieurs avantages. Tout d'abord, elle permet d'automatiser le processus de classification, ce qui peut être très utile lorsque l'on travaille avec de grandes quantités d'images. De plus, la machine learning permet aux ordinateurs de généraliser à partir des exemples d'apprentissage et de reconnaître des motifs et des caractéristiques dans les images qui peuvent être difficiles à détecter pour les humains.

Cependant, il convient de noter que la qualité des résultats de classification dépend fortement de la qualité et de la taille de l'ensemble de données d'apprentissage utilisé. Un ensemble de données représentatif et diversifié est essentiel pour former un modèle de machine learning performant. De plus, le processus d'annotation des données peut être coûteux et nécessiter des efforts considérables.

Dans ce travail, nous avons utilisé l'application Classifier Learner pour classer les images satellites. Nous avons d'abord extrait certaines caractéristiques de ces images en utilisant des codes MATLAB. Où nous avons remarqué que l'application était utile pour classer les images satellites sans avoir besoin de codes pour différentes méthodes de classification. La qualité des résultats a été confirmée en utilisant les matrices de confusion pour évaluer les performances.

Ce travail nous a permis d'apprendre différentes techniques de traitement d'image et certaines méthodes de classification, ainsi qu'un aperçu de l'apprentissage automatique. Nous avons également acquis de l'expérience dans l'utilisation de l'application Classifier Learner et MATLAB pour la classification des images satellites.

Pour améliorer ce travail, nous suggérons de continuer à explorer d'autres caractéristiques des images pour obtenir des résultats plus précis. De plus, nous recommandons l'extraction de la version en langage de programmation C du modèle pour une utilisation sur d'autres plates-formes et dans différents langages de programmation

Bibliographie

Bibliographie

[1] L. Lechlek, M. Ghougal, and F. Boutaouche, "La segmentation d'image médicale par la méthode d'ensembles de niveaux level sets," 2012.

[2] S. FAID and W. DEHIMI, "Modèle de segmentation d'image à champ aléatoire de markov (MRF)," Univ M'sila, 2020.

[3] E. Monfrini and W. Pieczynski, "Estimation de mélanges généralisés dans les arbres de Markov cachés, applicationa la segmentation des images de cartons d'orgue de barbarie," *traitement du signal,* vol. 22, pp. 135-147, 2005.

[4] M. J. Cardoso, M. J. Clarkson, G. R. Ridgway, M. Modat, N. C. Fox, S. Ourselin, and A. s. D. N. Initiative, "LoAd: a locally adaptive cortical segmentation algorithm," *NeuroImage,* vol. 56, pp. 1386-1397, 2011.

[5] J. Canny, "A computational approach to edge detection," *IEEE Transactions on pattern analysis and machine intelligence,* pp. 679-698, 1986.

[6] P. Bolon, J.-M. Chassery, J.-P. Cocquerez, D. Demigny, C. Graffigne, A. Montanvert, S. Philipp, R. Zéboudj, J. Zerubia, and H. Maître, "Analyse d'images: filtrage et segmentation," ed: Masson, 1995.

[7] M. Bosc, "Contribution à la détection de changements dans des séquences IRM 3D multimodales," Université Louis Pasteur-Strasbourg I, 2003.

[8] M. T. CHIKH, "Amélioration des images par un modèle de réseau de neurones (Comparaison avec les filtres de base)," 2011.

[9] N. Abbas, "Développement de modèles de fusion et de classification contextuelle d'images satellitaires par la théorie de l'évidence et la théorie du raisonnement plausible et paradoxal," 2009.

[10] http://www.mediadico.com/dictionnaire/télédetection.html (2010).

[11] http://www.techno-science.net/definition/télédetection.html. (26-05-11).

[12] "http://www.fr23.wikipédia.org/wiki/Télédetection ".

[13] "http://www.ccrs.nrcan.gc.ca/ressource/tutor/fudam/chapter1/01."

[14] "http://cartographie.ird.fr/refugies/methodes-telede."

[15] M. Türkmen, "Digital image processing of remotely sensed oceanographic data," Middle East Technical University, 2008.

[16] Mémoire de fin d'études de la 2ème année de Master : l'intelligence artificielle au service de la recherche clinique université de lille (2018 – 2019).

[17] MacQueen.J, Some methods for classification and analysis of multivariate observations, in Proc. Fifth Berkeley Symposium on Mathematical statistics and probability, P.281-297, 1967.

[18] Hilali, h., application de la classification textuelle pour l'extraction des règles ⋯ d'association maximales. thèse de maitrise en informatique, université du québec à trois-rivières, trois-rivières, 2009.

[19] Descôteaux, s., les règles d'association maximale au service de l'interprétation des résultats de la classification. thèse de maitrise en informatique, université du québec à trois-rivières, trois-rivières, 2014: p. 174.

[20] https://datakeen.co/3-deep-learning-architectures-explained-in-human-language/

[21] Wikipedia, machine à vecteurs de support <https://fr.wikipedia.org/wiki/machine_%c3%a0_vecteurs_de_support>, 2017.

[22] Learn, s., support vector machines ,<http://scikitlearn.org/stable/modules/svm.html>

[23] Gurney, k., an introduction to neural networks. 1997

[24] Fausett, l.v., fundamentals of neural networks: architectures, algorithms and applications.1993.

[25] Wikiversite, réseaux de neurones : avantages et possibilités , <https://fr.wikiversity.org/wiki/r%c3%a9seaux_de_neurones/avantages_et_possi bilit%c3%a9s>, 18 mai 2016.

[26] Amira, l., b. khaoukha, and l. adila, identification et commande des systèmes non linéaires.2011.

[27] Van den Oord, S. Dieleman, and B. Schrauwen, "Deep content-based music recommendation," in Advances in neural information processing systems, pp. 2643–2651, 2013.

[28] 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, pp. 160–167, ACM, 2008.

[29] Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016. http://www. deeplearningbook.org.

[30] https://www.mathworks.com/discovery/what-is-matlab.html.

[31] Abd Kadir Mahamad* and Takashi Hiyama . Development of Artificial Neural Network Based Fault Diagnosis of Induction Motor Bearing . 2nd IEEE International Conference on Power and Energy (PECon 08), December 1-3, 2008, Johor Baharu, Malaysia.

[32] https://www.mathworks.com/help/releases/R2021a/stats/choose-a-classifier.html#bunt0ky (25/05/2023)

[33] https://www.mathworks.com/help/stats/classification.html (25/05/2023)