



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mohamed Khider – BISKRA

Faculté des Sciences Exactes, des Sciences de la Nature et de la Vie

Département d'informatique

N° d'ordre :IVA13/M2/2022

Mémoire

Présenté pour obtenir le diplôme de master académique en

Informatique

Parcours : Image et Vie Artificielle (IVA)

Classification multispectrale des images satellites

Par :

MILOUDI OUIEM

Soutenu le 28/06/2022 devant le jury composé de :

Babahenini Mohamed Chaouki

Professeur

Président

FEKRAOUI Farah

MCB

Rapporteur

Bentrah Ahlem

MCB

Examineur

Année universitaire 2021-2022

DEDICATION

je dédie ce modeste travail :

Mes parents sont la joie de ma vie.

mes frères et ma soeur Nizar, Wail, Nafaa et Rihem pour leurs encouragements.

Remerciements

"Au début, je remercie Allah qui m'a aidé à accomplir ce travail, et qui a été avec moi à tous les moments de mon chemin d'étude. A mes chers parents : ma mère et mon père, pour leur Patience, leur amour, leur soutien et leurs Encouragements.

Je tiens à exprimer mon vif remerciement **DR FEKRAOUI FARAH** ma superviseure pour son aide, ses conseils et ses encouragements depuis le premier jour jusqu'à maintenant, sans vous je ne pourrais pas présenter ce travail.

Je désire témoigner ma reconnaissance et mes remerciements les plus sincères au Chef de département d'informatique et le Doyen de la faculté de la Science de la Nature et la vie.

Mes remerciements vont également aux membres du jury d'avoir accepté d'évaluer mon travail.

Abstract

Over time, man has developed the means he has used to identify the land and reveal its wealth. He has also developed programs and equipment to classify images taken by satellite, which allow him to determine the terrain and determine the places and changes that occur at ground level. Classification is a predictive task that consists of grouping the most similar data into the same class. This operation is therefore very complex and the use of powerful algorithms is necessary. Deep Learning or deep learning is a family of learning algorithms (machine learning) to train neural networks composed of several internal layers and potentially a large number. These techniques have enabled significant and rapid progress in the fields of image analysis. The work proposed in this thesis aims to achieve a classification of satellite images using DeepLearning.

We used a deep neural network, a variant of the ResNet 50 network, which can go up not to 50 layers deep, but to 100 layers. The results obtained, compared to the results obtained by other networks on the same image database, are considered satisfactory in terms of computational efficiency and precision.

Résumé

Au fil du temps, l'homme a développé les moyens qu'il a utilisés pour identifier la terre et révéler sa richesse. Il a également mis au point des programmes et du matériel permettant de classer les images prises par satellite, ce qui lui permet de déterminer le terrain et de déterminer les lieux et les changements qui se produisent au niveau du sol. La classification est une tâche prédictive qui consiste à regrouper les données les plus similaires dans une même classe. Cette opération est donc d'une grande complexité et l'utilisation des algorithmes puissants s'avère nécessaire. Le Deep Learning ou apprentissage profond est une famille d'algorithmes d'apprentissage (machine learning) pour entraîner des réseaux de neurones composés de plusieurs couches internes et potentiellement un grand nombre. Ces techniques ont permis des progrès importants et rapides dans les domaines de l'analyse des images. Le travail proposé dans ce mémoire vise à réaliser une classification des images satellites à l'aide du Deep Learning.

Nous avons utilisé un réseau de neurone profond, une variante du réseau ResNet 50, qui peut aller jusqu'à non pas à 50 couches en profondeur, mais à 100 couches. Les résultats obtenus, comparés aux résultats obtenus par d'autres réseaux sur de la même base d'images mais, sont jugés satisfaisants en termes d'efficacité de calcul et de précision.

المخلص

بمرور الوقت ، طور الإنسان الوسائل التي استخدمها لتحديد الأرض والكشف عن ثروتها. كما طور برامج ومعدات لتصنيف الصور الملتقطة بواسطة الأقمار الصناعية ، مما يسمح له بتحديد التضاريس وتحديد الأماكن والتغيرات التي تحدث على مستوى الأرض. التصنيف هو مهمة تنبؤية تتكون من تجميع البيانات الأكثر تشابهاً في نفس الفئة. لذلك فإن هذه العملية معقدة للغاية ، ومن الضروري استخدام خوارزميات قوية. التعلم العميق أو التعلم العميق عبارة عن عائلة من خوارزميات التعلم (التعلم الآلي) لتدريب الشبكات العصبية المكونة من عدة طبقات داخلية وربما عدد كبير. سمحت هذه التقنيات بإحراز تقدم كبير وسريع في مجالات تحليل الصور. يهدف العمل المقترح في هذه الأطروحة إلى تحقيق تصنيف لصور الأقمار الصناعية باستخدام ResNet 50 ، التعلم العميق. لقد استخدمنا شبكة عصبية عميقة ، وهي نوع مختلف من شبكة والتي لا يمكن أن تصل إلى عمق 50 طبقة ، بل تصل إلى 100 طبقة. تعتبر النتائج التي تم الحصول عليها ، مقارنة بالنتائج التي حصلت عليها الشبكات الأخرى على نفس قاعدة بيانات الصور ، مرضية من حيث الكفاءة الحسابية والدقة.

الكلمات المفتاحية

العصبية CNN التصنيف ، التعلم العميق ، الاستشعار عن بعد ، صور الأقمار الصناعية ، شبكة Resnet 50 المتشجعة ،

Table des matières

table des matières	i
table des Figures	iv
Liste des Tableaux	vii
General Introduction	2
1 La Classification des images satellites	3
1.1 Introduction	3
1.2 Généralités sur la télédétection	3
1.2.1 Définition de la télédétection	3
1.2.2 Processus de la télédétection :	4
1.2.3 Détection passive et active	5
1.2.3.1 capteur active	5
1.2.3.2 capteur passive	6
1.2.4 Caractéristiques des images	7
1.2.4.1 Résolution spatiale	7
1.2.4.2 Résolution spectrale	8
1.2.5 Paramètres influant sur le contenu d'une image satellitaire	8
1.2.5.1 La définition de l'image :	8
1.2.5.2 Les canaux disponibles :	9
1.2.5.3 La date de prise de vue :	9
1.3 La classification des images satellites	9
1.3.1 Définitions	9
1.3.2 Types de classification	9

Classification non supervisée	10
Classification supervisée	11
1.4 conclusion :	15
2 Le Deep learning pour la classification des images	16
Introduction.....	16
Définition de l'apprentissage automatique(machine learning)	16
Les différents procédés d'apprentissage automatique	17
Les applications d'apprentissage automatique	18
Définition de l'apprentissage profond (deep learning)	19
Pour quoi le deep learning?	20
Architectures de réseaux de neurones profonds	20
Les réseaux de neurones convolutifs.....	21
Réseau de neurones récurrents.....	22
Cartes auto-adaptatives (SOMs)	23
Machines de Boltzmann	24
Auto-encodeurs	24
la comparaison entre l'apprentissage automatique et l'apprentissage en profondeur :	25
transfer learning.....	26
l'utilisation du Transfer Learning	27
Conclusion.....	29
3 Conception du notre système	30
Introduction.....	30
Conception du système.....	30
L'architecture générale	30
Architecture détaillée	31
Lecture et collecte des données.....	31
Augmentation de données :	31
Pré-traitement	33
Conception de l'architecture du modele(resnet-50) . 343.2.2.5	
l'apprentissage :	36

Conclusion.....	37
4 implémentation, résultats et discussions	38
Introduction.....	38
Environnements et outils de développement	38
Framework et environnement de travail	38
Langages de programmation	39
Outils de développements.....	39
Environnement.....	41
Implémentation et discussion des résultats.....	43
Collecte de données	43
Prétraitement des données	43
augmentation des données	44
Réseau de neurone ResNet-50.....	45
L'apprentissage	45
l'interface de l'application.....	47
Validation des résultats.....	49
Matrice de confusion	51
étude comparative.....	52
test des résultats	53
Limites du système classifieur et solutions proposées.....	55
Conclusion.....	56
General Conclusion	58
Bibliographie	59

Table des figures

1.1	Processus de la télédétection [2]	4
1.2	Capteur active	5
1.3	Capteur passive	6
1.4	Résolution spatiale	7
	Bandes spectrales de l'image satellitaire	8
	Principe de classification.....	10
	classification k-nearest neighbors.....	12
	Exemple d'arbre de décision	13
	Une architecture CNN.....	14
	Relation entre AI, ML et DL.....	17
	Les application d'apprentissage automatique [1]	19
	Deep learning évoluent avec la quantité de données par pour ancien algorithme d'apprentissage. [21]	20
	Un exemple d'architecture CNN pour une tâche de reconnaissance de chiffres manuscrits.	22
	Schématique Réseau de neurones récurrents.	23
	Schématique réseau de neurones Cartes auto-adaptatives.	23
	Schématique réseau de neurones Machines de Boltzmann.	24
	Schématique réseau de neurones Auto-encodeurs.	25
	Le procède du ML classique comparé à celui du Deep Learning.	26
	Approche traditionnelle vs Approche de Transfert Learning.	27
	Approche de Transfer Learning en Deep Learning,	28
	L'Architecture globale du System	31

L'Architecture détaillée du Système	32
système d'augmentation de la donnée	33
les techniques d'augmentation des données	33
Formation des bases d'images d'apprentissage et de validation à partir de la base globale	34
architecture d'un réseau de neurones convolutif sans (A) et avec (B) connexion résiduelle.....	35
Architecture Resnet50.....	35
l'apprentissage.....	36
4.1 python	39
4.2 pytorch	41
4.3 Kaggle	41
pycharm	42
Qt Designer	42
conda.....	43
Prétraitement des données.....	44
augmentation des données	44
Le retournement horizontal, le retournement vertical, la rotation	44
statistiques de l'apprentissage	45
taux d'apprentissage.....	46
formule mathématique de loss	46
validation des pertes	47
l'interface	48
Téléchargement des images.....	48
classe culture.....	49
Classe Forêt.....	49
statistiques du Test	49
exemple de classification.....	50
matrice de confusion de validation.....	51
matrice de confusion-test-.....	52
la formule de précision(accuracy).....	52

<i>Ville de Biskra</i>	54
Barrage Foum El Ghorza	54
Région de Tolga	54

Liste des tableaux

Description de la base utilisée	43
Comparaison entre les resultats LULC classification avec EuroSAT dataset.....	53
Caractéristiques des images de Test.....	53

Introduction Générale

L'imagerie satellitaire (aussi appelée imagerie spatiale) désigne la prise d'images depuis l'espace, par des capteurs placés sur des satellites. Visuellement, les images satellitaires ressemblent beaucoup à des photos, mais elles contiennent bien plus d'informations [7].

La télédétection se réfère à l'utilisation de technologies de capteurs satellitaires pour détecter et classer des objets sur Terre, c'est une discipline scientifique qui intègre un large éventail de compétences et de technologies utilisés pour l'observation, l'analyse et l'interprétation des phénomènes terrestres et atmosphériques, ses principales sources sont les mesures et les images obtenues à l'aide de plates-formes aériennes et spatiales.

Les systèmes de télédétection actuels, contrairement à ceux du début du développement de ces technologies ont connu des changements importants, en particulier dans la dernière décennie, avec une technologie essentielle dans le suivi des processus multiples qui affectent la surface et l'atmosphère de la Terre. Un impact important, en particulier sur notre planète, tels que le changement climatique, la déforestation, la désertification, etc.

Dans une image satellitaire, l'information sur les couleurs est décomposée en différents canaux ou bandes spectrales. Chaque bande est une image en niveaux de gris, composée de pixels ayant chacun une valeur de réflectance pour un intervalle de longueur d'ondes donné. On parle ainsi de "bande du bleu", du "rouge, du proche infrarouge", etc. Chaque bande va couvrir une portion plus ou moins large du spectre électro magnétique. Par exemple, la bande du bleu correspond à des longueurs dans un intervalle autour de 480 nm, celle du rouge autour de 600 nm.[1]

L'objectif principal de ce travail consiste à concevoir automatiquement un sys-

tème basé sur les réseaux de neurones convolutifs (CNN, Convolutional Neural Networks) pour la classification multispectrale des images satellitaires.

Le présent mémoire est organisé en quatre chapitres dont les thèmes sont donnés ci-dessous : Le 1er chapitre , explique les notions de base de la télédétection et du rayonnement électromagnétique aussi que le principe de la classification. Dans le deuxième chapitre nous présentons le deep learning, les domaines d'application et les différentes architectures. Dans le troisième chapitre, nous avons présenté la conception générale et détaillée de notre système. Le quatrième chapitre sera consacré à la présentation des étapes de l'implémentation de notre système et les outils utilisés pour développer notre application. Une étude comparative avec des travaux relatifs sera présentée. Nous terminons notre mémoire par une conclusion générale.

Chapitre 1

La Classification des images satellites

Introduction

La télédétection est une technique qui permet, à l'aide d'un capteur, "d'observer" et d'enregistrer le rayonnement électromagnétique, émis ou réfléchi, par une cible quelconque sans contact direct avec celle-ci. Le traitement et l'analyse des informations véhiculées par le rayonnement enregistré permettent d'accéder à certaines propriétés de cette cible : géométriques (position, forme et dimensions), optiques (réflexion, transmission, absorption, etc.) et physicochimiques (température, teneur en eau, chlorophylle foliaire, phyto-masse, matière organique du sol, . . .), etc.

Généralités sur la télédétection

Définition de la télédétection

La télédétection est la technique qui permet d'obtenir de l'information sur la surface de la Terre sans contact direct avec celle-ci. La télédétection englobe tout le processus qui consiste à capter et à enregistrer l'énergie d'un rayonnement électromagnétique émis ou réfléchi, à traiter et à analyser l'information, pour ensuite mettre en application cette information.

Dans la plupart des cas, la télédétection implique une interaction entre l'énergie incidente et les cibles [13].

Processus de la télédétection :




FIGURE 1.1 – Processus de la télédétection [2]

1. 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.
2. 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.
3. 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.
4. Enregistrement de l'énergie par le capteur (D) : Une fois l'énergie diffusée ou émise par la cible, elle doit être captée à distance (par un capteur qui n'est pas en contact avec la cible) pour être enfin enregistrée.
5. 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).

6. 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.
7. 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 [12].

Détection passive et active

Une autre possibilité de distinguer les satellites d'observation de la Terre est de comparer les capteurs utilisés. En général, il existe des capteurs passifs qui mesurent la lumière solaire réfléchie ou le rayonnement thermique, et des capteurs actifs qui utilisent leur propre source de rayonnement [21].

capteur active




FIGURE 1.2 – Capteur active

Les capteurs active (par exemple les radars et les scanners laser) émettent un rayonnement artificiel pour surveiller la surface de la Terre ou les caractéristiques atmosphériques. Les radars sont des instruments d'imagerie tandis que les altimètres radar et les diffusiomètres ne sont pas des images. Radar est l'abréviation de Radio Detection and Ranging, une méthode de détection et de télémétrie

des caractéristiques de la surface terrestre. Les satellites radar utilisent de courtes impulsions de rayonnement électromagnétique dans la gamme spectrale des micro-ondes, ils ne dépendent donc pas de la lumière du jour et ne sont guère affectés par les nuages, la poussière, le brouillard, le vent et les mauvaises conditions météorologiques. Ils mesurent les impulsions radar réfléchies par le sol, analysent l'intensité du signal afin de récupérer des informations sur la structure de la surface terrestre, et détectent le temps écoulé entre l'émission et le retour des impulsions. Les résultats peuvent être utilisés pour mesurer les distances. Selon la mission du satellite, différentes opérations et procédures sont utilisées pour traiter les signaux en informations viables.

capteur passive

Les capteurs passifs détectent le rayonnement solaire réfléchi par la terre et le rayonnement thermique dans le visible et l'infrarouge du spectre électromagnétique. Ils n'émettent pas leur propre rayonnement, mais reçoivent la lumière naturelle et le rayonnement thermique de la surface de la terre. La plupart des capteurs passifs utilisent un scanner pour l'imagerie, par ex. LANDSAT. Équipés de spectromètres, ils mesurent des signaux sur plusieurs bandes spectrales simultanément.




FIGURE 1.3 – Capteur passive

Caractéristiques des images

L'imagerie satellitaire ou imagerie spatiale, désigne la prise d'images depuis l'espace, par des capteurs placés sur des satellites. Visuellement, les images satellitaires ressemblent beaucoup à des photos, mais elles contiennent bien plus d'informations. Les caractéristiques fondamentales des images de télédétection sont :

- la résolution spectrale.
- la résolution spatiale.

Résolution spatiale

La résolution spatiale est la taille du plus petit élément qu'il est possible de distinguer sur l'image. Elle est également couramment définie comme étant la taille du pixel. Sur une image, les objets qu'il sera possible de discerner dépendront de la résolution spatiale du capteur utilisé. Généralement, plus la résolution spatiale augmente, plus la superficie de la surface visible par le capteur diminue : une image très haute résolution couvrira une portion de territoire plus restreinte qu'une image moyenne résolution. Au moment du choix des images à traiter, il convient donc de choisir le bon compromis selon la taille des objets les plus petits que l'on veut observer, et l'échelle à laquelle on souhaite observer un processus [4].




FIGURE 1.4 – Résolution spatiale

Résolution spectrale

La résolution spectrale décrit la capacité d'un capteur à utiliser de petites fenêtres de longueurs d'onde. Plus la résolution spectrale est fine, plus les fenêtres des différents canaux du capteur sont étroites. Dans une image satellitaire, l'information sur les couleurs est décomposée en différents canaux ou bandes spectrales. Chaque bande est une image en niveaux de gris, composée de pixels ayant chacun une valeur de réflectance pour un intervalle de longueur d'ondes donné. On parle ainsi de "bande du bleu", du "rouge, du proche infrarouge", etc. Chaque bande va couvrir une portion plus ou moins large du spectre électromagnétique. Par exemple, la bande du bleu correspond à des longueurs dans un intervalle autour de 480 nm, celle du rouge autour de 600 nm.

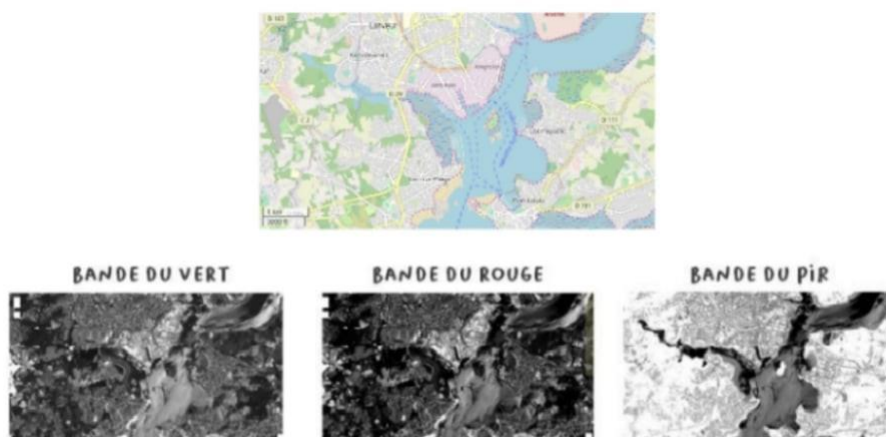


FIGURE 1.5 – Bandes spectrales de l'image satellitaire

Paramètres influant sur le contenu d'une image satellitaire

Le contenu des images de télédétection est fortement lié à certains paramètres qui dépendent des caractéristiques du satellite. Il s'agit notamment de :

La définition de l'image :

La taille des phénomènes étudiés doit être nettement plus grande que celle des pixels, d'où l'importance de la résolution spatiale du satellite [20].

Les canaux disponibles :

Les valeurs radiométriques d'un pixel dépendent de ses propriétés optiques. Ainsi, dans le cas d'un pixel de végétation, la réponse dans les canaux du visible (vert et rouge pour SPOT) est fonction de la teneur en pigments foliaires des végétaux alors qu'elle dépend surtout de la structure des feuilles dans le proche infrarouge (PIR) et de la teneur en eau dans le moyen infrarouge (MIR).

La date de prise de vue :

Elle doit être en relation avec les thèmes à extraire, et de ce fait, nécessite une bonne connaissance du terrain. Ce paramètre est d'autant plus important que le thème étudié évolue rapidement. C'est par exemple le cas en agriculture.

La classification des images satellites

Définitions

Qui permet le partitionnement de l'image en régions homogènes appelées classes, ces dernières sont construites à partir des attributs de pixels (niveau de gris, texture, etc.).

La classification a pour but d'identifier les classes auxquelles appartiennent les objets. Elle consiste à regrouper des ensembles de pixels similaires en classes tout en se basant sur les valeurs radiométriques des pixels ou en intégrant les relations de voisinage entre eux. La classification des images satellite peut être définie comme la partition de l'image en ensembles de pixels représentant une même occupation du sol [20].

Types de classification

Il existe plusieurs types de classifications : supervisée, non supervisée, hiérarchique, partitionnement, floue, exclusive, etc.




FIGURE 1.6 – Principe de classification

Classification non supervisée

Dans le cas de la classification non supervisée, l'opérateur ne dispose d'aucune information a priori sur la zone d'intérêt. Aucune information externe à l'image n'est donc introduite. Le classement des pixels est effectué uniquement selon le critère de la ressemblance spectrale.

L'étiquetage thématique est réalisé, s'il est souhaité, après la classification par interprétation des classes spectrales produites.

Algorithme de la classification non supervisée :

1. Les données sont classées en fonction de leurs caractéristiques spectrales, sans aucune information a priori sur la nature des objets à classer. L'interprète intervient pour fixer un nombre de groupes, des seuils, ... (en anglais non-supervised classifications).
2. Le principe de la classification non-supervisée est d'attribuer automatiquement chaque pixel à une classe suivant sa signature spectrale. L'algorithme le plus utilisé est le cluster ISODATA. Cet algorithme utilise de multiples itérations.
3. Tout d'abord, des clusters sont arbitrairement construits. Ensuite, les pixels sont attribués au cluster le plus proche. Puis, la moyenne de chaque cluster est calculée sur la base des nouveaux pixels assignés au cluster. Les clusters sont regroupés si le centre de 2 clusters est plus proche qu'un certain seuil,

ou si le nombre de pixels dans une classe est trop petit. Les clusters sont séparés dans le cas où l'écart type dépasse une certaine valeur, ou si le nombre de pixels est 2 fois supérieur au seuil du nombre minimal de pixels. La seconde et troisième étape sont répétées jusqu'à ce que les changements entre les itérations soient moindres [20].

Il existe plusieurs méthodes de classification non-supervisé, nous pouvons citer :

- K-means clustering : Cette méthode vise à partitionner n observations en k clusters dans lesquels chaque observation appartient au cluster dont la moyenne est la plus proche (centres de cluster ou centroïde de cluster) en minimisant la variance intera-classe.
- KNN (k-nearest neighbors) :est un algorithme standard de classification qui repose exclusivement sur le choix de la métrique de classification. Il est « non paramétrique », c'est à dire,seul k doit être fixé(le nombre de voisins à considérer), et se base uniquement sur les données d'entraînement (Figure 1.7) [25].

Classification supervisée

La classification supervisée consiste à affecter un objet à des classes dont le nombre est connu, ayant une signification et une interprétation bien précise et disposant d'une population de base. La classification supervisée est, en général, issue d'un apprentissage avec des données initiales (échantillons) qu'un expert va classer et qui serviront de modèles aux futurs objets classés.

Pour la classification supervisée on dispose d'échantillons (des vérités terrain) donc un nombre fini de classes. Ce type de classification nécessite l'intervention d'un expert .

Algorithme de la classification supervisée

Afin de réaliser une classification dirigée, 10 étapes sont à suivre selon une adaptation de celle proposée par Bonn et Rochon [8] :

1. Formuler avec précision les classes thématiques à extraire.
2. Analyser et évaluer l'existence de leur correspondance spectrale.




FIGURE 1.7 – classification k-nearest neighbors

3. Sélectionner les zones d'échantillonnage (zones considérées représentatives des classes à déterminer).
4. Diviser en deux groupes les zones d'échantillonnage : un groupe pour l'établissement des signatures spectrales (zones d'entraînement), et un autre pour vérifier si la procédure produit bien les classes attendues (zones tests).
5. Établir les signatures spectrales.
6. Analyser les signatures spectrales. Sont-elles disjointes dans l'espace spectral? Évaluer leur pouvoir discriminant.
7. Choisir l'algorithme de classification.
8. Effectuer une classification des zones d'entraînement. Établir et analyser la matrice de confusion. Cette première évaluation ne fait qu'orienter l'analyste sur les capacités de la procédure et les difficultés de discrimination entre classes.
9. Effectuer une classification sur les zones tests. Établir et analyser la matrice de confusion. Si les résultats ne sont pas satisfaisants, modifier les zones d'en-

traînement, pour améliorer leur représentativité ou les classes thématiques, ou encore changer la procédure de classification. Cette étape est cruciale, car elle est à la base de l'évaluation de la qualité de l'image classée.

10. Classer l'ensemble de l'image.

Il existe divers méthodes de classification supervisée à savoir :

- Random Forest (ou Forêt d'arbres de décision en français) : est une technique de Machine Learning très populaire et ce parcequ'elle présente de nombreux avantages comparé aux autres algorithmes de data.

C'est une technique facile à interpréter, stable, qui présente en général de bonnes accuracies et qui peut être utilisée pour des tâches de régression ou de classification. Elle couvre donc une grande partie des problèmes de Machine Learning.

Le Random Forest (ou forêt en français) repose sur des arbres que l'on appelle arbre de décision ou arbre décisionnel comme illustre la figure 1.8

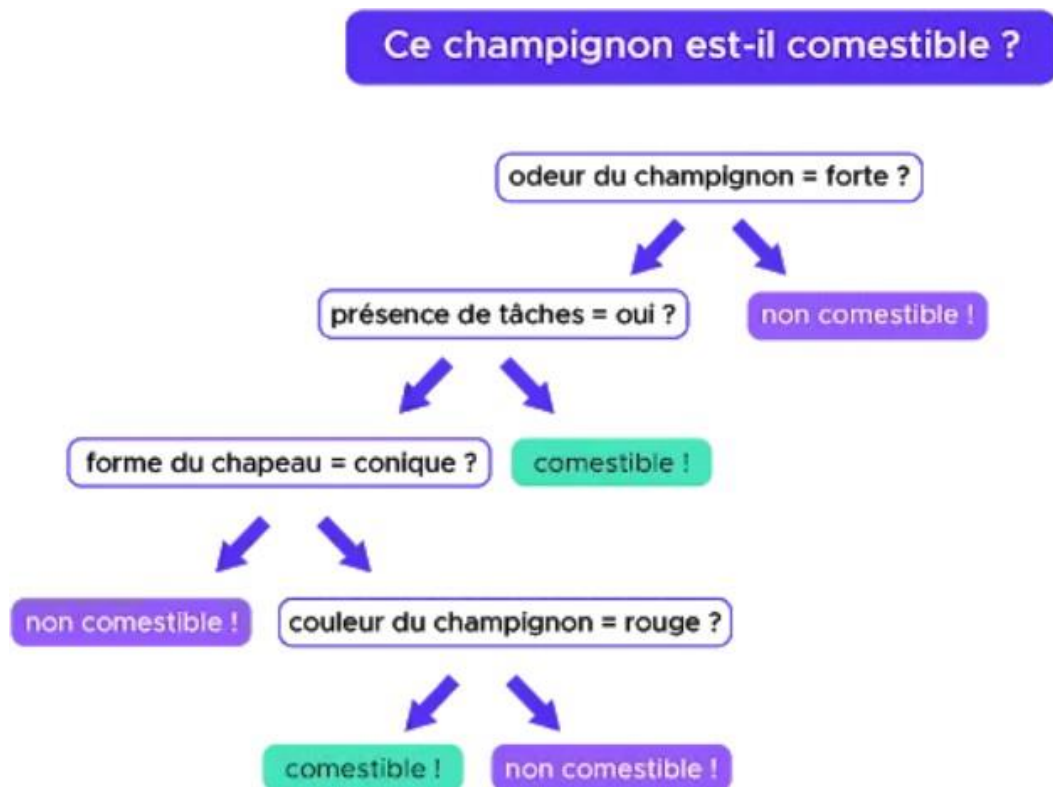


FIGURE 1.8 – Exemple d'arbre de décision

— Les réseaux de neurones convolutionnels : L'un des types les plus populaires de réseaux de neurones profonds est connu sous le nom de réseaux de neurones convolutifs (CNN ou ConvNet). Les CNN convolvent les entités apprises avec les données d'entrée et utilisent des couches convolutives 2D, ils éliminent le besoin d'extraction manuelle des caractéristiques pour classer les images, ils fonctionnent en extrayant des fonctionnalités directement à partir d'images. Ils sont appris pendant que le réseau s'entraîne sur une collection d'images. L'extraction automatique des fonctionnalités rend les modèles d'apprentissage en profondeur très précis pour les tâches de vision par ordinateur telles que la classification d'objets.

Les couches sont organisées en 3 dimensions : largeur, hauteur et profondeur (trois canaux de couleur R, V, B). L'architecture de base de CNN :

1. La partie Calques cachés / Extraction d'entités

Dans cette partie, le réseau effectuera une série de convolutions et d'opérations de regroupement jusqu'à ce que les entités soient détectées ou extraites.

2. La partie Classification

Ici, les couches entièrement connectées serviront de classificateur au-dessus de ces caractéristiques extraites pour attribuer une probabilité pour que l'objet sur l'image soit ce que l'algorithme prédit qu'il est.

et ce bien illustré dans la figure 1.9.




FIGURE 1.9 – Une architecture CNN

conclusion :

Grâce au satellite ultra sophistiqué et au matériel rigoureusement utilisé, la télédétection a tendance à se développer d'avantage. Elle a investi des domaines scientifiques divers. Dans les domaines des sciences spatiales et surtout en ce qui concerne le traitement de l'imagerie satellitaire, la télédétection est un moyen scientifique d'avant . garde qui permet de donner des informations de plus en plus précises que précieuses sur les objets, les surfaces et les profondeurs les plus inexplorés de notre univers. Parmi les méthodes qui nous procurent des informations, nous pouvons citer la classification à partir des images satellites. Le prochain chapitre, traite les détails de Deep Learning.

Chapitre 2

Le Deep learning pour la classification des images

Introduction

Afin d'exploiter une image satellite et en tirer les informations utiles, nous devons appliquer des techniques informatiques tel que les techniques de classification. Nous allons introduire dans ce chapitre, la méthode de classifications du Deep Learning.

Définition de l'apprentissage automatique(machine learning)

L'apprentissage automatique ou Le machine learning en anglais, est un concept qui fait de plus en plus parler de lui dans le monde de l'informatique, et qui se rapporte au domaine de l'intelligence artificielle. Encore appelé « apprentissage statistique », ce terme renvoie à un processus de développement, d'analyse et d'implémentation conduisant à la mise en place de procédés systématiques. Pour faire simple, il s'agit d'une sorte de programme permettant à un ordinateur ou à une machine un apprentissage automatisé, de façon à pouvoir réaliser un certain nombre d'opérations très complexes.

L'objectif visé est de rendre la machine ou l'ordinateur capable d'apporter




FIGURE 2.1 – Relation entre AI, ML et DL

des solutions à des problèmes compliqués, par le traitement d'une quantité astronomique d'informations. Cela offre ainsi une possibilité d'analyser et de mettre en évidence les corrélations qui existent entre deux ou plusieurs situations données, et de prédire leurs différentes implications.[2]

Les différents procédés d'apprentissage automatique

L'apprentissage automatique implique deux principaux systèmes d'apprentissage qui définissent ses différents modes de fonctionnement. Il s'agit de :[18]

L'apprentissage supervisé la machine s'appuie sur des classes prédéterminées et sur un certain nombre de paradigmes connus pour mettre en place un système de classement à partir de modèles déjà catalogués. Dans ce cas, deux étapes sont nécessaires pour compléter le processus, à commencer par le stade d'apprentissage qui consiste à la modélisation des données cataloguées. Ensuite, il s'agira au second stade de se baser sur les données ainsi définies pour attribuer des classes aux nouveaux modèles introduits dans le système, afin de les cataloguer eux aussi.

L'apprentissage non-supervisé Dans ce mode de fonctionnement du machine learning, il n'est pas question de s'appuyer sur des éléments prédéfinis, et la tâche revient à la machine de procéder toute seule à la catégorisation des données. Pour ce faire, le système va croiser les informations qui lui sont soumises, de manière à pouvoir rassembler dans une même classe les éléments présentant certaines similitudes. Ainsi, en fonction du but recherché, il reviendra à l'opérateur ou au chercheur de les analyser afin d'en déduire les différentes hypothèses.

Les applications d'apprentissage automatique

1. **Marketing en ligne** utilise des outils d'analyse marketing qui s'appuient sur l'apprentissage automatique . Ils évaluent des données définies et peuvent fournir des diagnostics fiables à propos du type de contenu capable d'aboutir à une conversion, des contenus que les clients veulent lire et des canaux marketing les plus efficaces pour conclure une vente.
2. **Support client** les chatbots peuvent s'appuyer sur l'apprentissage automatique. Ils s'orientent en fonction des mots-clés trouvés dans la question de l'utilisateur et, par des questions pour obtenir plus d'informations ou prendre des décisions, dialoguent avec l'utilisateur jusqu'à lui apporter la réponse désirée.
3. **Vente** ce qui fonctionne pour Netflix et Amazon est aussi idéal pour la vente. Grâce au Machine learning, les systèmes peuvent anticiper avec précision les produits et services qui pourraient intéresser les clients sur leur site. Ils peuvent ainsi faire des recommandations détaillées, ce qui facilite la vente avec des gammes de produits très large ou des produits hautement personnalisables.
4. **Informatique décisionnelle** le Machine learning peut aussi servir à visualiser les données importantes de l'entreprise et à rendre différentes prévisions compréhensibles pour les décideurs humains.[1]




FIGURE 2.2 – Les application d'apprentissage automatique [1]

Définition de l'apprentissage profond (deep learning)

Le deep learning est un sous-domaine de l'intelligence artificielle. Le terme désigne toutes les techniques d'apprentissage automatique, c'est-à-dire une forme d'apprentissage basée sur des méthodes mathématiques utilisées pour modéliser les données tel que les machines communiquent et fonctionnent sur la base d'informations stockées.

L'apprentissage profond est un système avancé basé sur un énorme réseau de neurones artificiels qui sont inspirés par les neurones du cerveau humain. Ces réseaux de neurones sont constitués de plusieurs neurones artificiels où chaque neurone est connecté aux autres neurones. Plus le nombre de neurones est élevé, plus le réseau est profond : C'est le deep learning .Au parti du cerveau humain, chaque neurone reçoit environ 100 000 signaux électriques des autres neurones. Chaque neurone actif peut exciter ou inhiber les neurones qui lui sont connectés. Au parti d'un réseau artificiel, le principe est similaire les signaux transmet entre les neurones. Toutefois, au lieu d'un signal électrique, le réseau de neurones assigne s'appeler poids, à différents neurones par des couche. La dernière couche de neurones répond à ces signaux.

Ces neurones sont connectés les uns aux autres pour traiter et stocker des infor-

mations, comparer tout problème ou situation avec des situations similaires dans le passé, analyser des solutions et résoudre les problèmes de la meilleure façon.[3]

Pour quoi le deep learning ?




FIGURE 2.3 – Deep learning évoluent avec la quantité de données par pour ancien algorithme d'apprentissage. [21]

Les modèles d'apprentissage en profondeur ont tendance peuvent souvent gérer de grandes quantités de données(figure2.3), tandis que les modèles d'apprentissage automatique plus traditionnels cessent de s'améliorer après avoir atteint un point de saturation. Au fil des ans, avec l'avènement du big data et des composants informatiques de plus en plus puissants, de puissants algorithmes d'apprentissage en profondeur à forte intensité de données ont remplacé la plupart des autres méthodes.

figure2.3 : étant donné que nous sommes à l'ère du big data, nous voulons utiliser pleinement les données, donc la capacité à améliorer les performances lorsqu'il y'a une grande quantité de données (le passage à l'échelle) est un vrai rêve.

Architectures de réseaux de neurones profonds

Il existe un grand nombre de variantes d'architectures profondes. La plu-

part d'entre elles sont dérivées de certaines des architectures parentales originale. Il y a deux types apprentissage que classifiées architectures :

- **Supervisé**
 - Les réseaux de neurones convolutifs utiliser pour computer vision
 - Les réseaux de neurones récurrents utiliser pour séries temporelles
- **Non-supervisé**
 - Cartes auto-adaptives utiliser pour détection de features
 - Machines de Boltzmann profondes utiliser pour système de recommandation
 - Auto-encodeurs utiliser pour système de recommandation

Les réseaux de neurones convolutifs

Depuis pas mal d'années les réseaux de neurones convolution prennent vraiment le dessus par rapport aux réseaux de neurones artificiels , CNN est la plus en plus utilisé et populaire ça évolue énormément. Par exemple, on peut penser aux voitures autonomes cette voitures utilisent énormément les réseaux de neurones à convolution par ce qu'elles ont beaucoup d'images à reconnaître. Cette technologie développée par Yann Lecun le père des réseaux de neurones à convolution, il va servir pour classifier des images on va mettre une image en entrée, et elle va passer dans le réseau qui est déjà entraînée et on ressort la catégorie de l'image et on la divise en deux blocs (comme illustre la figure 2.4) :

- **Le premier bloc : feature extraction**, il applique des opérations de filtrage par convolution, c'est à dire il filtre l'image avec convolution et renvoie des images appelées " feature maps " ensuite normalisées ,pooling ,flattening, finalement les valeurs des dernières feature maps sont concaténées dans un vecteur ,ce vecteur permet de définir la sortie.
- **Le second bloc : classification**, les valeurs du vecteur en entrée sont transformées (avec plusieurs combinaisons linéaires et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie. Ce dernier vecteur contient autant des éléments représentent les probabilités que l'image appartienne à la classe

. Chaque élément est donc compris entre 0 et 1, et la somme de tous vaut 1. Ces probabilités sont calculées par la dernière couche de ce bloc (et donc du réseau), qui utilise une fonction logistique (classification binaire) ou une fonction softmax (classification multi-classe) comme fonction d'activation .

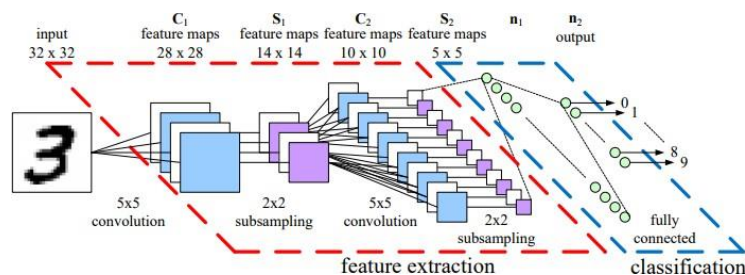


FIGURE 2.4 – Un exemple d'architecture CNN pour une tâche de reconnaissance de chiffres manuscrits.

L'architecture réseau CNN est représentée sur la figure 2.4. Le traitement commence par des couches de feature extraction et se finit par des couches de classification entièrement connectées.

Réseau de neurones récurrents

Un réseau neuronal récurrent RNN est un réseau de neurones dans lequel l'information peut se propager dans deux directions, y compris de la couche profonde à la première couche (voir la figure 2.5). En cela, ils sont plus proches du vrai fonctionnement du système nerveux, qui n'est pas à sens unique. Ces réseaux possèdent des connexions récurrentes au sens où elles conservent des informations en mémoire : ils peuvent prendre en compte à un instant t un certain nombre d'états passés. C'est l'un des algorithmes les plus avancés dans le monde de l'apprentissage supervisé . L'architecture de ce réseau est représentée par :

- un seul neurone en entrée et on a plusieurs sorties
- plusieurs entrées et par contre on a qu'une seule sortie
- plusieurs entrées et on a plusieurs sorties.




FIGURE 2.5 – Schématisation Réseau de neurones récurrents.

Cartes auto-adaptatives (SOMs)

La Carte auto-organisatrice ou carte de Kohonen est un algorithme de classification développé par Teuvo Kohonen learning dès 1982. L'objectif principal d'une carte auto adaptative est de réduire la dimension, c'est qu'ils ont un jeu de données multidimensionnelles avec énormément de dimensions énormément de colonnes de variables. Alors évidemment ils ont aussi beaucoup de lignes mais vraiment le but est de réduire la dimension du jeu de données, c'est à dire de réduire le nombre de colonnes, à la fin on finit avec une carte en deux dimensions qui représente les données (voir la figure 2.6). Donc l'objectif principal est vraiment de réduire le nombre de colonnes en perdant bien entendu le moins d'informations possibles.




FIGURE 2.6 – Schématisation réseau de neurones Cartes auto-adaptatives.

L'algorithme d'apprentissage non supervisé et la méthode de quantification vectorielle, regroupement des informations en classes tout en respectant la topologie de l'espace des observations définit à priori d'une notion de voisinage entre les classes des observations voisines dans l'espace des données appartiennent après classe-

ment à la même classe ou à des classes voisines et les compressions de données multidimensionnelles tout en préservant leurs caractéristiques.

Machines de Boltzmann




FIGURE 2.7 – Schématisation réseau de neurones Machines de Boltzmann.

Le fait que le fonctionnement des machines à Boltzmann est vraiment différent, on a deux couleurs (voir la figure 2.7) n'y a pas de couche de sortie, on a la couche d'entrée qui est en bas et on a la couche de caché et tous sont connectés à tous parce que c'est l'apprentissage non supervisé, l'information va dans tous les sens n'ont pas de direction, l'information elle part des nœuds visibles jusqu'aux nœuds cachés, elle revient dans les nœuds visibles et ainsi de suite. Il est possible d'empiler plusieurs couches de machines de Boltzmann restreintes pour créer des réseaux profonds qui sont plus performants. L'algorithme va générer des états dans ce système, dans la machine de Boltzmann asynchrone, les neurones modifient leur état un à un.

Auto-encodeurs

Les auto-encodeurs sont des algorithmes d'apprentissage non supervisé à base de réseaux de neurones artificiels, qui permettent de construire une nouvelle représentation d'un jeu de données. Généralement, celle-ci est plus compacte, et présente moins de descripteurs, ce qui permet de réduire la dimension du jeu de données. L'architecture d'un auto-encodeur est constituée de deux parties : l'enco-

deur et le décodeur(voir 2.8). L'encodeur est constitué par un ensemble de couches de neurones, qui traitent les données afin de construire de nouvelles représentations dites "encodées". À leur tour, les couches de neurones du décodeur, reçoivent ces représentations et les traitent afin d'essayer de reconstruire les données de départ.




FIGURE 2.8 – Schématisation réseau de neurones Auto-encodeurs.

la comparaison entre l'apprentissage automatique et l'apprentissage en profondeur :

- Le Machine learning s'appuie sur un algorithme qui adapte lui-même le système à partir des retours faits par l'humain. La mise en place de cette technologie implique l'existence de données organisées. Le système est ensuite alimenté par des données structurées et catégorisées lui permettant de comprendre comment classer de nouvelles données similaires. En fonction de ce classement, le système exécute ensuite les actions programmées. Il sait par exemple identifier si une photo montre un chien ou un chat et classer le document dans le dossier correspondant.
- Le Deep learning n'a pas besoin de données structurées. Le système fonctionne à partir de plusieurs couches de réseaux neuronaux, qui combinent

différents algorithmes en s'inspirant du cerveau humain. Ainsi, le système est capable de travailler à partir de données non structurées.

- Avec le Deep learning, le système identifie lui-même les caractéristiques discriminantes des données, sans avoir besoin d'une catégorisation préalable. Le système n'a pas besoin d'être entraîné par un développeur. Il évalue lui-même le besoin de modifier le classement ou de créer des catégories inédites en fonction des nouvelles données ,Tandis que le Machine learning fonctionne à partir d'une base de données contrôlable, le Deep learning a besoin d'un volume de données bien plus considérable. Le système doit disposer de plus de 100 millions d'entrées pour donner des résultats fiables.
- La technologie nécessaire pour le Deep learning est plus sophistiquée. Elle exige plus de ressources IT et s'avère nettement plus coûteuse que le Machine learning , elle n'est donc pas intéressante pour une utilisation de masse par les entreprises.
- Dans l'étape de l'extraction de caractéristiques. Dans les algorithmes de ML traditionnelles l'extraction de caractéristiques est faite manuellement, c'est une étape difficile et coûteuse en temps et requiert un spécialiste en la matière alors qu'en Deep Learning cette étape est exécutée automatiquement par l'algorithme [19] [5].

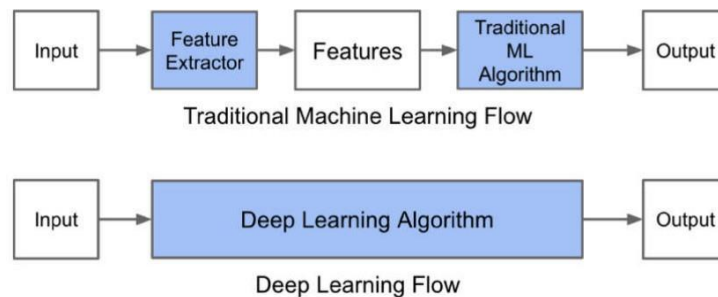


FIGURE 2.9 – Le procédé du ML classique comparé à celui du Deep Learning.

transfer learning

Le Transfer Learning, ou apprentissage par transfert en français, désigne l'ensemble des méthodes qui permettent de transférer les connaissances acquises

à partir de la résolution de problèmes donnés pour traiter un autre problème. Le Transfer Learning a connu un grand succès avec l'essor du Deep Learning. En effet, bien souvent, les modèles utilisés dans ce domaine nécessitent des temps de calcul élevés et des ressources importantes. Or, en utilisant des modèles pré-entraînés comme point de départ, le Transfer Learning permet de développer rapidement des modèles performants et résoudre efficacement des problèmes complexes en Computer Vision ou Natural Language Processing, NLP [23].




FIGURE 2.10 – Approche traditionnelle vs Approche de Transfert Learning.

l'utilisation du Transfer Learning

L'utilisation des méthodes de Transfer Learning en Deep Learning consiste principalement à exploiter des réseaux de neurones pré-entraînés. on peut distinguer 2 types de stratégies :

— **Utilisation de modèles pré-entraînés comme extracteurs de features :**

L'idée est de réutiliser un réseau pré-entraîné sans sa couche finale. Ce nouveau réseau fonctionne alors comme un extracteur de features fixes pour la réalisation d'autres tâches.

Afin d'illustrer cette stratégie, prenons le cas où nous souhaitons créer un modèle capable d'identifier l'espèce d'une fleur à partir de son image. Il est alors possible d'utiliser les premières couches du modèle de réseau de neurones convolutif AlexNet, initialement entraîné sur la base d'image ImageNet pour la classification d'images [23].

— **Ajustement de modèles pré-entraînés :**

Il s'agit d'une technique plus complexe, dans laquelle non seulement la dernière couche est remplacée pour réaliser la classification ou la régression, mais d'autres couches sont également ré-entraîner de manière sélective. En effet, les réseaux neuronaux profonds sont des architectures hautement configurables avec divers hyperparamètres. De plus, alors que les premières couches capturent les caractéristiques génériques, les dernières couches se concentrent davantage sur la tâche spécifique à accomplir. L'idée est donc de geler (c'est-à-dire fixer les poids) de certaines couches pendant l'entraînement et affiner le reste pour répondre à la problématique. Cette stratégie permet de réutiliser les connaissances en termes d'architecture globale du réseau et d'exploiter ses états comme point de départ pour l'entraînement. Elle permet donc d'obtenir de meilleures performances avec un temps d'entraînement plus court. La figure ci-dessous récapitule les principales approches de Transfer Learning utilisées communément en Deep Learning. L'une des exigences fondamen-

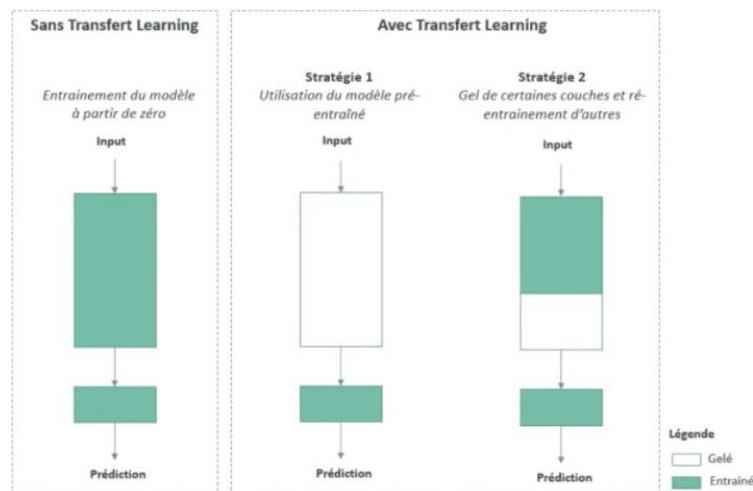


FIGURE 2.11 – Approche de Transfer Learning en Deep Learning,

tales de l'apprentissage par transfert est la présence de modèles qui fonctionnent bien sur les tâches sources. De nos jours, de nombreuses architectures de Deep Learning de pointe sont partagées librement par leurs équipes respectives. Celles-ci s'étendent sur différents domaines tels que la vision par ordinateur et le Traitement du langage nature ou le NLP. Parmi les modèles très fréquemment utilisés, nous pouvons citer : Computer Vision : VGG-16, ResNet-50(détaillé dans le chapitre suivant) [23].

Conclusion

Dans ce chapitre, nous avons présenté la méthode du DeepLearnig dans le but de la classification des images satellites. L'implémentation de cette méthode sera détaillée dans le chapitre suivant.

Chapitre 3

Conception du notre système

Introduction

Après avoir pris connaissance dans le chapitre précédent de la méthode du DeepLearning pour la classification des images, ce chapitre porte sur la construction de notre application.

En effet, nous allons décrire les objectifs de notre travail et présenter les détail de la méthode proposée pour la classification des images satellitaires à base du Deep Learning.

Conception du système

L'architecture générale

Notre système permet de réaliser une classification multispectrale des images satellites selon un réseau CNN profond. L'architecture générale de notre application est exprimée par la figure ci-dessus :

Cette application est réalisée en plusieurs étapes en commençons par la lecture des images à partir de la DataSet jusqu'à la spécification de la classe appropriée de chaque image par le réseau CNN profond.

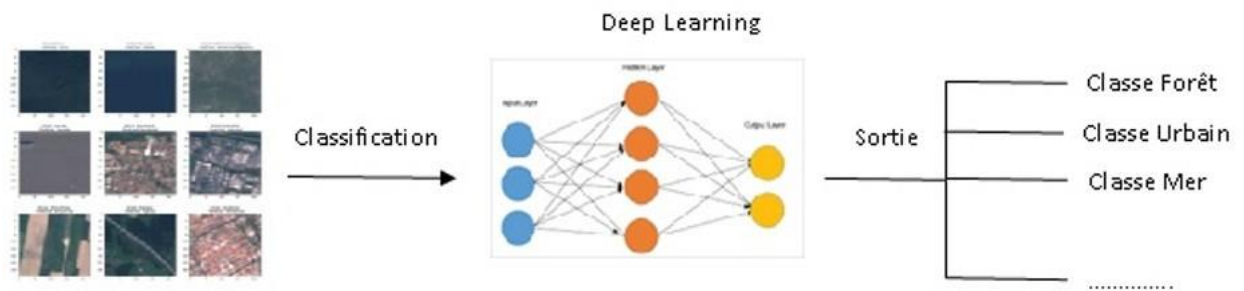


FIGURE 3.1 – L'Architecture globale du System

Architecture détaillée

Après avoir élaborer les spécifications de la structure générale du projet, nous arrivons au cœur de la matière avec la conception détaillée en plusieurs étapes : à partir de la lecture et la collecte des données jusqu'à la mise en œuvre.(Figure3.2)

Lecture et collecte des données

Les données sont une clé très importante dans le processus d'apprentissage, c'est la première étape pour commencer à construire notre module. La sélection de données est réalisée à partir de la base d'images euroset de sentinel-2.

Augmentation de données :

La diversité et le volume des données d'apprentissage jouent un rôle éminent dans la formation d'un modèle d'apprentissage en profondeur robuste. L'augmentation de données est fondamentalement importante pour améliorer les performances des réseaux, elle consiste à augmenter artificiellement la taille de la base de données d'apprentissage en ajoutant des nouveaux exemples créés à partir de déformations des exemples initiaux. L'objectif est que le réseau apprenne des descripteurs spécifiques aux classes d'objets considérées plutôt que des artefacts d'images comme des différences d'illuminations.

Pour l'ensemble d'images de notre base, les techniques d'augmentation des données utilisées sont le retournement horizontal, le retournement vertical, la rotation .

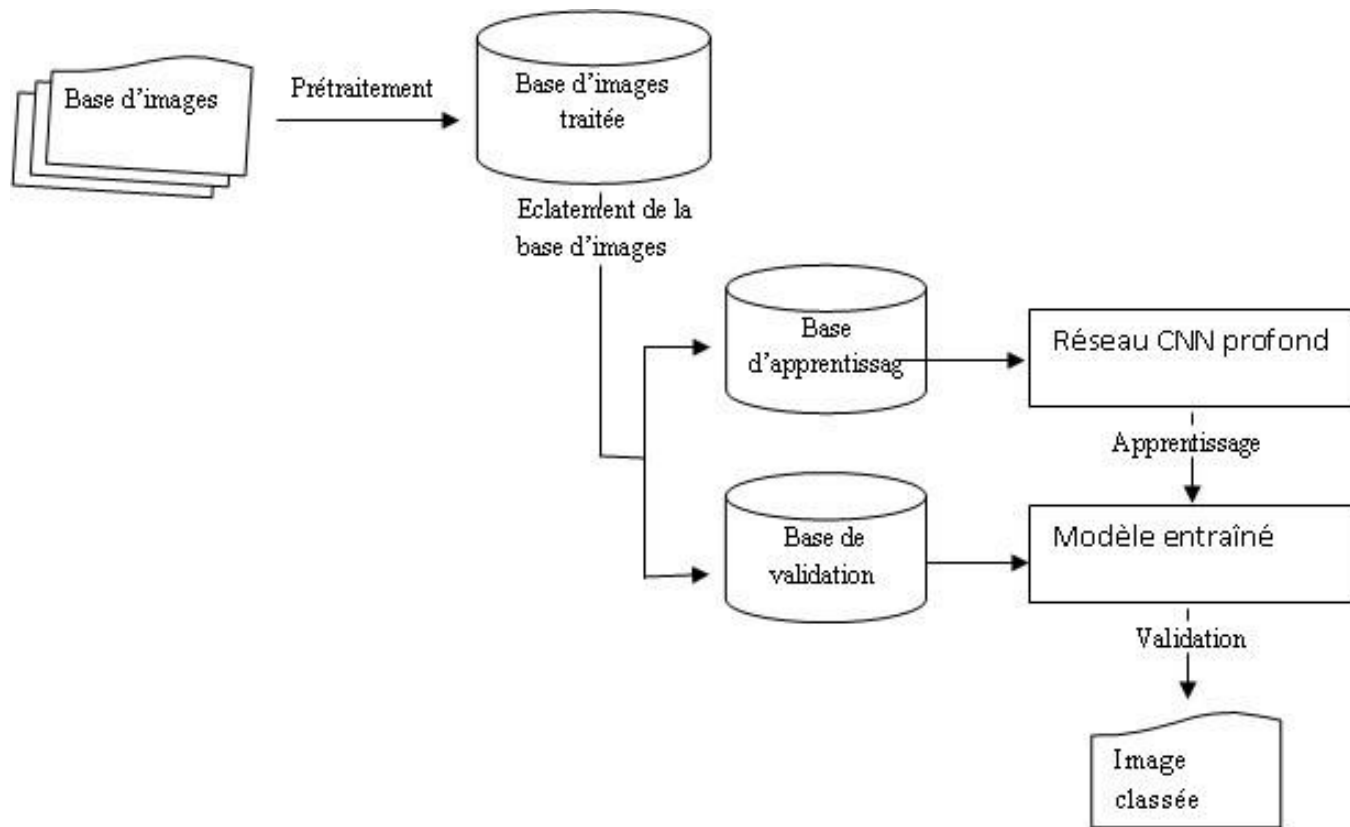


FIGURE 3.2 – L'Architecture détaillée du Système



FIGURE 3.3 – système d’augmentation de la donnée



l’image principale



Rotation



le retournement horizontale



le retournement verticale

FIGURE 3.4 – les techniques d’augmentation des données

Pré-traitement :

Le prétraitement des données est une technique d’exploitation de données brutes. Le prétraitement des données pour l’apprentissage automatique consiste à fractionner l’ensemble des images de la base utilisée en deux sous bases : La première base est utilisée pour l’apprentissage du système et représente 75% de l’ensemble des images, et la deuxième base qui est utilisée pour la validation du système représente 25% de l’ensemble des images de la base d’images.




FIGURE 3.5 – Formation des bases d’images d’apprentissage et de validation à partir de la base globale

Conception de l’architecture du modèle(resnet-50)

Dans les réseaux de neurones, et pour obtenir une meilleure précision, il serait avantageux d’approfondir les couches. Or, lors de l’ajout de couches supplémentaires à un système existant (l’augmentation de la profondeur du réseau), la précision devient saturée. La rétro-propagation peut donner des valeurs inhabituelles. Cela finira par augmenter le taux d’erreur du réseau. Dans les réseaux de neurones traditionnels, il était impossible d’entraîner un réseau comportant plus de 25 couches. ResNet (Residual Network) vient pour soulever ce problème et donner une solution à cette problématique. ResNet 50 est une variante des réseaux ResNet, il est composé de 50 couches de profondeur et a la particularité d’introduire des connexions résiduelles. Contrairement aux réseaux de neurones convolutifs qui ont une architecture linéaire (un empilement de couches dont chaque sortie est uniquement connectée à la couche suivante) (figure 3.5 A), dans un réseau résiduel, la sortie des couches précédentes est reliée à la sortie de nouvelles couches pour les transmettre toutes les deux à la couche suivante (figure 3.5 B)

Le modèle Resnet50 offre aussi l’avantage d’être directement disponible dans pytorch (un de nos frameworks de prédilection avec scikit-learn)

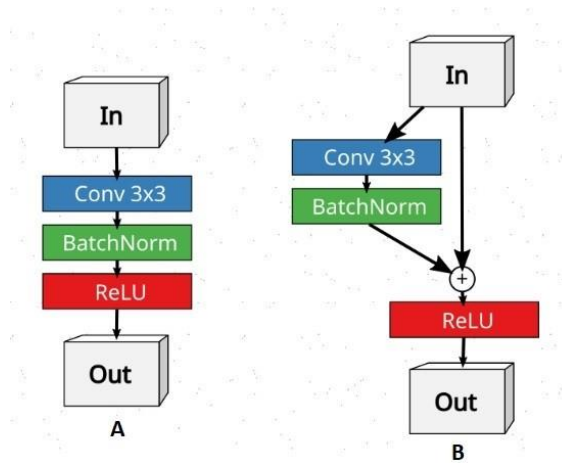


FIGURE 3.6 – architecture d’un réseau de neurones convolutif sans (A) et avec (B) connexion résiduelle




FIGURE 3.7 – Architecture Resnet50

l'apprentissage :

C'est la phase la plus importante de notre système, nous allons former un réseau de neurones artificiels avec une architecture spécifique que pour obtenir le meilleur résultat de précision et moins de perte de données pour classifier des images satellitaire.(voir la figure 3.8)

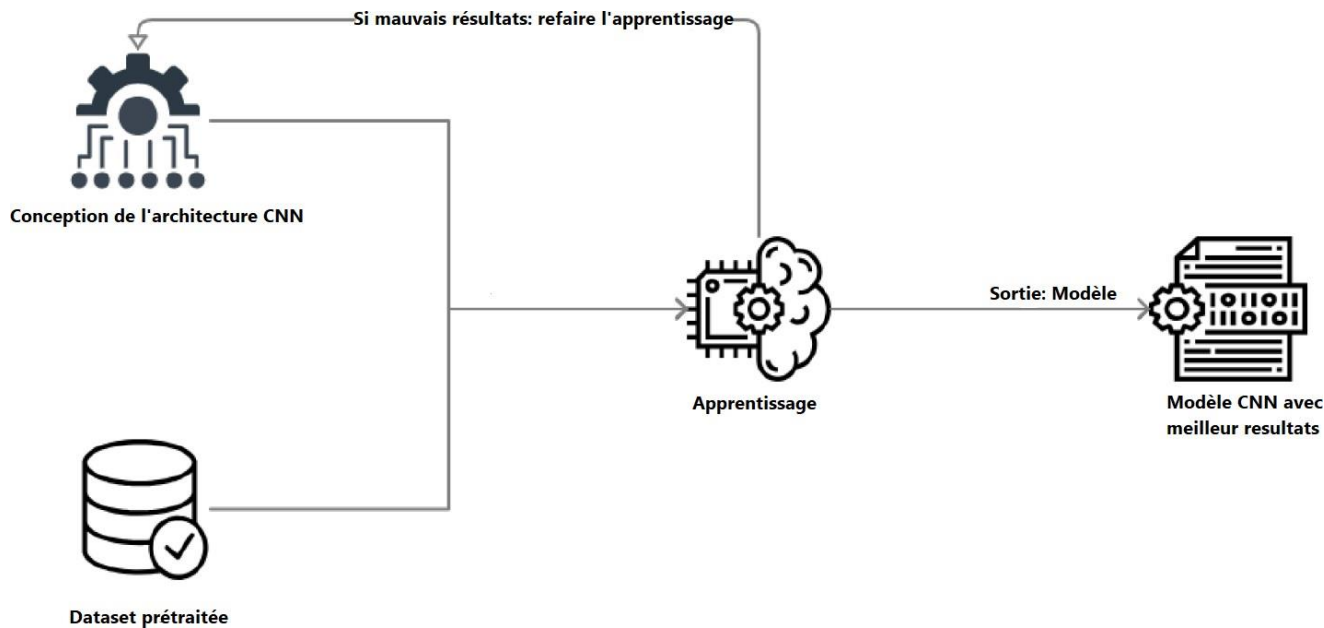


FIGURE 3.8 – l'apprentissage

l'apprentissage passe par 4 phases :

- 1-conception d'architecture.
- 2-prétraitement de data set.
- 3-Apprentissage.
- 4-Modele obtenu.

On répète l'étape d'apprentissage jusqu'a obtenir le résultat souhaité du notre modèle.

Conclusion

Dans ce chapitre, nous avons détaillé les étapes à suivre pour la réalisation mettre directant l'objectif de projet .

Nous avons aussi présenté les étapes nécessaire de notre application. Le chapitre suivant est consacré à l'implémentation du notre système ainsi qu'aux résultats obtenus .

Chapitre 4

implémentation, résultats et discussions

Introduction

Ce chapitre dresse la synoptique de la démarche suivie pour aboutir à notre objectif. Nous allons dans un premier temps présenter les ressources utilisées et dans un second temps nous exposerons les résultats obtenus, présenterons les différentes interfaces de l'application réalisée ainsi que la discussion et l'interprétation des expérimentations et des résultats obtenus.

Environnements et outils de développement

Framework et environnement de travail

Notre système est développé sous l'environnement :

- Processeur : Intel(R) Core(TM) i5-8265U CPU @ 1.60GHz 1.80 GHz
- Mémoire installée (RAM) : 8,00Go
- la carte graphique kaggle (tesla)

Languages de programmation

Afin de mettre en œuvre notre application, nous avons utilisé le langage de programmation Python qui est un langage de programmation de haut niveau interprété (il n'y a pas d'étape de compilation) et orienté objet avec une sémantique dynamique. Ce langage est très sollicité par une large communauté de développeurs et de programmeurs :

- Python est un langage simple et facile à apprendre.
- Il permet une bonne réduction du coût de la maintenance des codes.
- Les bibliothèques (packages) python encouragent la modularité et la réutilisabilité des codes.
- Python et ses bibliothèques sont disponibles (en source ou en binaires) sans charges pour la majorité des plate-formes et peuvent être redistribués gratuitement.¹



FIGURE 4.1 – python

Outils de développements

Nous avons utilisé plusieurs outils pour le développement de notre système à savoir :

1. Matplotlib : Matplotlib est une bibliothèque de traçage disponible pour le

1. <https://docs.python.org/fr/3/tutorial/>

langage de programmation Python en tant que composant de NumPy, une ressource de traitement numérique de données volumineuses. Matplotlib utilise une API orientée objet pour intégrer des tracés dans les applications Python.[16]

2. Numpy : Est une bibliothèque permettant d'effectuer des calculs numériques avec Python. Elle introduit une gestion facilitée des tableaux de nombres, des fonctions sophistiquées(diffusion), on peut aussi l'intégrer le code C / C ++ et Fortran.²
3. PIL : Pillow est une bibliothèque de traitement d'image, qui est un fork et successeur du projet PIL (Python Imaging Library). Elle est conçue de manière à offrir un accès rapide aux données contenues dans une image, et offre un support pour différents formats de fichiers tels que PPM, PNG, JPEG, GIF, TIFF et BMP. Pillow dispose de capacités de traitement d'images relativement puissantes, et a pour but d'offrir une solide base à toute application générale de traitement d'images³
4. Pandas : est une librairie python qui permet de manipuler facilement des données à analyser [14] :
 - manipuler des tableaux de données avec des étiquettes de variables (colonnes) et d'individus (lignes).
 - ces tableaux sont appelés DataFrames, similaires aux dataframes sous R.
 - on peut facilement lire et écrire ces dataframes à partir ou vers un fichier tabulé.
 - on peut faciliter tracer des graphes à partir de ces DataFrames grâce à matplotlib.Pour utiliser pandas : `import pandas`
5. Pytorch : PyTorch est une bibliothèque, développée par Facebook, écrite en Python pour se lancer dans le deep learning. À partir de plusieurs variables, elle peut servir à réaliser le calcul de gradients ou à utiliser des tableaux multidimensionnels obtenus grâce à des tenseurs spécifiques.

2. <http://www.numpy.org/>

3. <https://pypi.org/project/Pillow/>



FIGURE 4.2 – pytorch

6. Scikit-Learn : C'est une librairie Python qui donne accès à des versions efficaces d'un grand nombre d'algorithmes courants. Elle offre également une API propre et uniformisée. Par conséquent, un des gros avantages de Scikit-Learn est qu'une fois que vous avez compris l'utilisation et la syntaxe de base de Scikit-Learn pour un type de modèle, le passage à un nouveau modèle ou algorithme est très simple. La librairie ne permet pas seulement de faire de la modélisation, elle peut assurer également des étapes de preprocessing ce que nous verrons dans la suite de l'article [24].

Environnement

1. Kaggle : Kaggle est une plateforme web qui accueille la plus grande communauté de Data Science au monde, avec plus de 536 000 membres actifs dans 194 pays et reçoit près de 150 000 soumissions par mois, et qui lui fournit des outils et des ressources puissants pour aider à atteindre tous les progrès de science des données. Kaggle, de la même manière que DataScientest, offre un environnement Jupyter Notebooks personnalisable et sans configuration. Sont accessibles gratuitement des GPU et une grande quantité de données et de codes publiés par la communauté [11]. Kaggle nous offre l'utilisation simultanée de 7 GPU Tesla P100.



FIGURE 4.3 – Kaggle

2. pycharm : PyCharm est un environnement de développement (ou IDE) pour la programmation en langage Python. Destiné aux développeurs informa-

tiques, PyCharm propose un ensemble d'outils spécialisés Python. De nombreuses fonctionnalités d'automatisation de routines sont disponibles ainsi qu'une assistance intelligente au codage. PyCharm est multiplateforme et vous pouvez le télécharger pour votre PC sous Windows ou Linux, ou pour votre Mac sous macOS (Intel ou Apple Silicon) [6].



FIGURE 4.4 – pycharm

3. Qt Designer : est un outil permettant de créer rapidement des interfaces utilisateur graphiques avec des widgets du framework Qt GUI. Il vous offre une interface simple par glisser-déposer pour disposer des composants tels que des boutons, des champs de texte, des zones de liste déroulante, etc.



FIGURE 4.5 – Qt Designer

4. conda : Miniconda est un programme d'installation minimal gratuit pour conda. Il s'agit d'une petite version bootstrap d'Anaconda qui inclut uniquement conda, Python, les packages dont ils dépendent et un nombre d'autres packages utiles, notamment pip, zlib et quelques autres.




FIGURE 4.6 – conda

Implémentation et discussion des résultats

Afin d'implémenter notre modèle d'apprentissage profond CNN, nous avons utilisé le langage Python avec quelques APIs (Application Programming Interface) et des bibliothèques travaillant sur l'apprentissage profond (CNN). L'une des bibliothèques Python les plus puissantes à utiliser pour le développement et l'évaluation de modèles d'apprentissage profond est pytorch.

L'implémentation de notre application s'est réalisée en plusieurs étapes à savoir :

Collecte de données

Pour l'apprentissage et le test de notre système classifieur, nous avons utilisé la base d'image euroset de sentinel-2 dont les caractéristiques sont mentionnées dans le tableau ci-dessous :

Nbr images	Année d'acquisition	Taille(pixels)	Résolution(m)
27000	2017	64 X 64	10

TABLE 4.1 – Description de la base utilisée

Prétraitement des données

L'ensemble d'images utilisé est divisé en deux sous ensembles : un ensemble d'apprentissage représentant 75% de l'ensemble des images et le 25% qui reste sera destiné pour le test de notre système.


```
len(TRAIN_DF.index), len(TEST_DF.index)
```

```
(20250, 6750)
```

FIGURE 4.7 – Prétraitement des données

augmentation des données

On a appliqué trois techniques de data augmentation a notre dataset pour augmenter la performance de l'apprentissage de notre modèle à savoir : Le retournement horizontal, le retournement vertical, la rotation.

```
## Dataset and transformations
train_data_transform = transforms.Compose([
    transforms.Resize(size=(224, 224)),
    transforms.RandomHorizontalFlip(p=0.5),
    transforms.RandomRotation(20),
    transforms.RandomVerticalFlip(p=0.5),
    transforms.ToTensor(),
])
```

FIGURE 4.8 – augmentation des données



l'image principale



Rotation



le retournement horizontale



le retournement verticale

FIGURE 4.9 – Le retournement horizontal, le retournement vertical, la rotation

Réseau de neurone ResNet-50

Pour la classification des images satellites de la base, nous avons utilisé le réseau ResNet-50 défini dans le chapitre précédent. Dans notre cas, le réseau ResNet-50 est composé de :

- Couche d'entrée : composée de 10 neurones relatifs aux 10 classes correspondantes à notre base d'images à savoir : Residential, Industrial, SeaLake, Pasture, Forest, Highway, River, HerbaceousVegetation (Végétation herbacée), AnnualCrop (culture annuelle), PermanentCrop (Culture permanente).
- Couches cachées : qui sont au nombre de 50 couches.
- Couche de sortie : comportant 10 neurones relatives aux 10 classes que représentent les images de la base.

L'apprentissage

Nous avons utilisé 27000 images pour l'apprentissage de notre réseau. L'apprentissage s'est déroulé en 24 tours où chaque tour s'est déroulé en 5,2 mins, soit le total de 2h3min23s pour l'apprentissage complet.



FIGURE 4.10 – statistiques de l'apprentissage

Le taux d'apprentissage (Learning rate) de notre système est jugé bon selon les statistiques de l'apprentissage mentionnées dans la figure 4.10. En effet, nous pouvons remarquer que la précision de l'apprentissage (train d'accuracy) est proche de 1 et que l'erreur de l'apprentissage (train loss) est de 0.

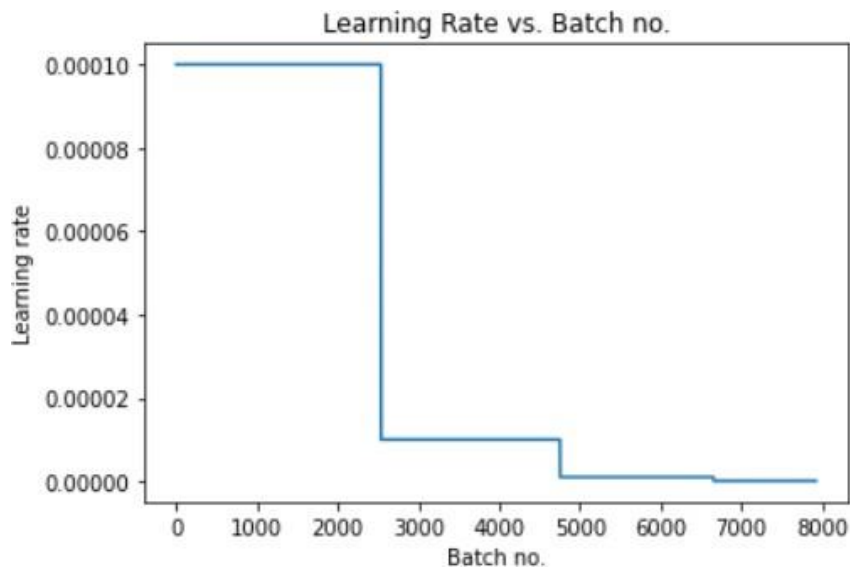


FIGURE 4.11 – taux d'apprentissage

Le graphe de la figure 4.11 représente la courbe de l'erreur d'apprentissage en fonction du nombre d'images utilisées. Nous remarquons que plus le nombre d'images accroît, plus le taux d'erreur diminue. la formule utilisée pour le calcul de loss(erreur) : où t_i est l'étiquette de vérité et p_i dans la probabilité softmax pour la classe i (th)

$$L_{CE} = - \sum_{i=1}^n t_i \log(p_i), \text{ for } n \text{ classes,}$$

FIGURE 4.12 – formule mathématique de loss

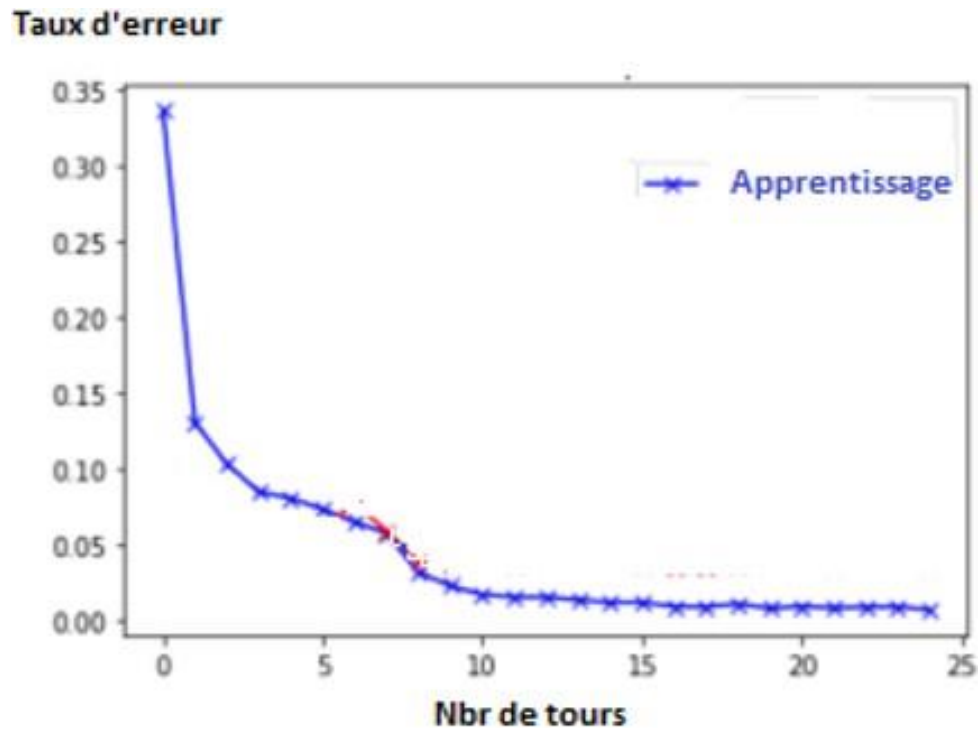


FIGURE 4.13 – validation des pertes

l'interface de l'application

Nous avons développé une interface graphique afin de faciliter la manipulation et le traitement des images satellites. Notre interface est facile à manipuler. En effet elle comporte deux boutons : Browser et le bouton Classification.

- Browser : qui consiste à télécharger les images à classifier.
- Classification : pour lancer le processus de la classification.

Une fois la classification de l'image en question est achevée, la classe appropriée à cette image sera affichée sur l'écran de l'interface.



FIGURE 4.14 – l'interface

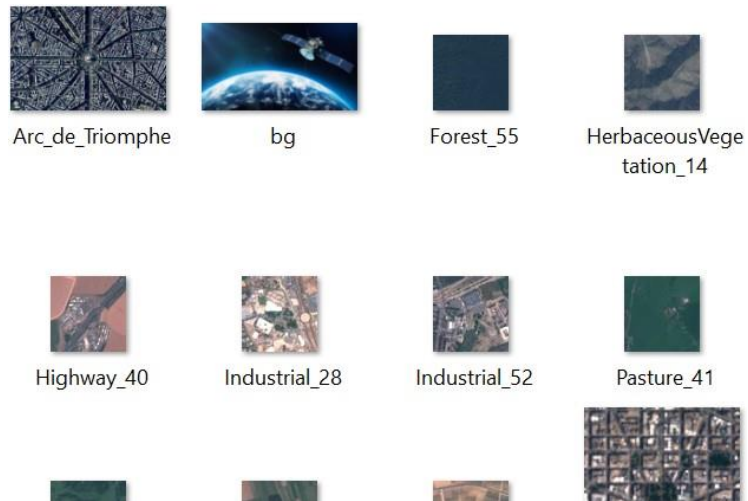


FIGURE 4.15 – Téléchargement des images

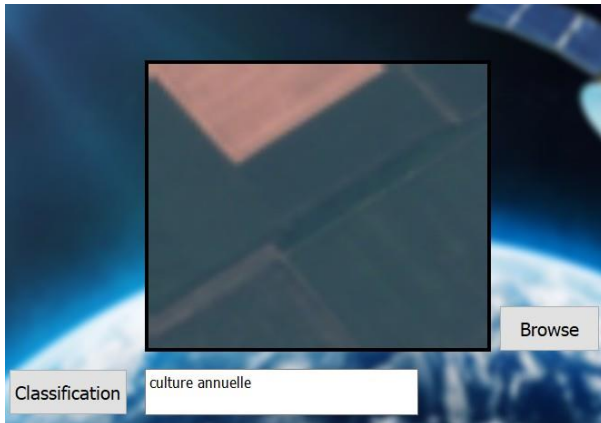


FIGURE 4.16 – classe culture

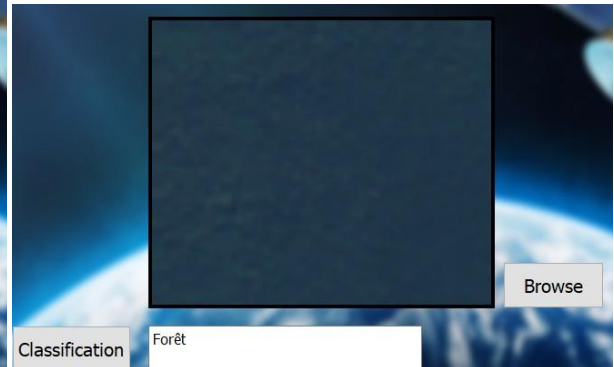


FIGURE 4.17 – Classe Forêt

Validation des résultats

Après l'achèvement de l'étape de l'apprentissage, nous avons procédé à la validation de notre système classifieur avec les 25% images de la base destinées à cette étape. Les statistiques des résultats obtenus sont mentionnées dans la figure ci-dessous.



FIGURE 4.18 – statistiques du Test

L'analyse des statistiques nous révèle que le taux de test est jugé bon. En effet, nous avons constaté une précision de validation (Val accuracy) égale à 0.9739 et une erreur de validation (val loss) proche de 0, soit 0.117.

Nous avons procédé à la classification de quelques images de la base de validation, les classes qui lui en étaient attribuées sont correctes, nous mentionnant les figures ci-dessous quelques unes :

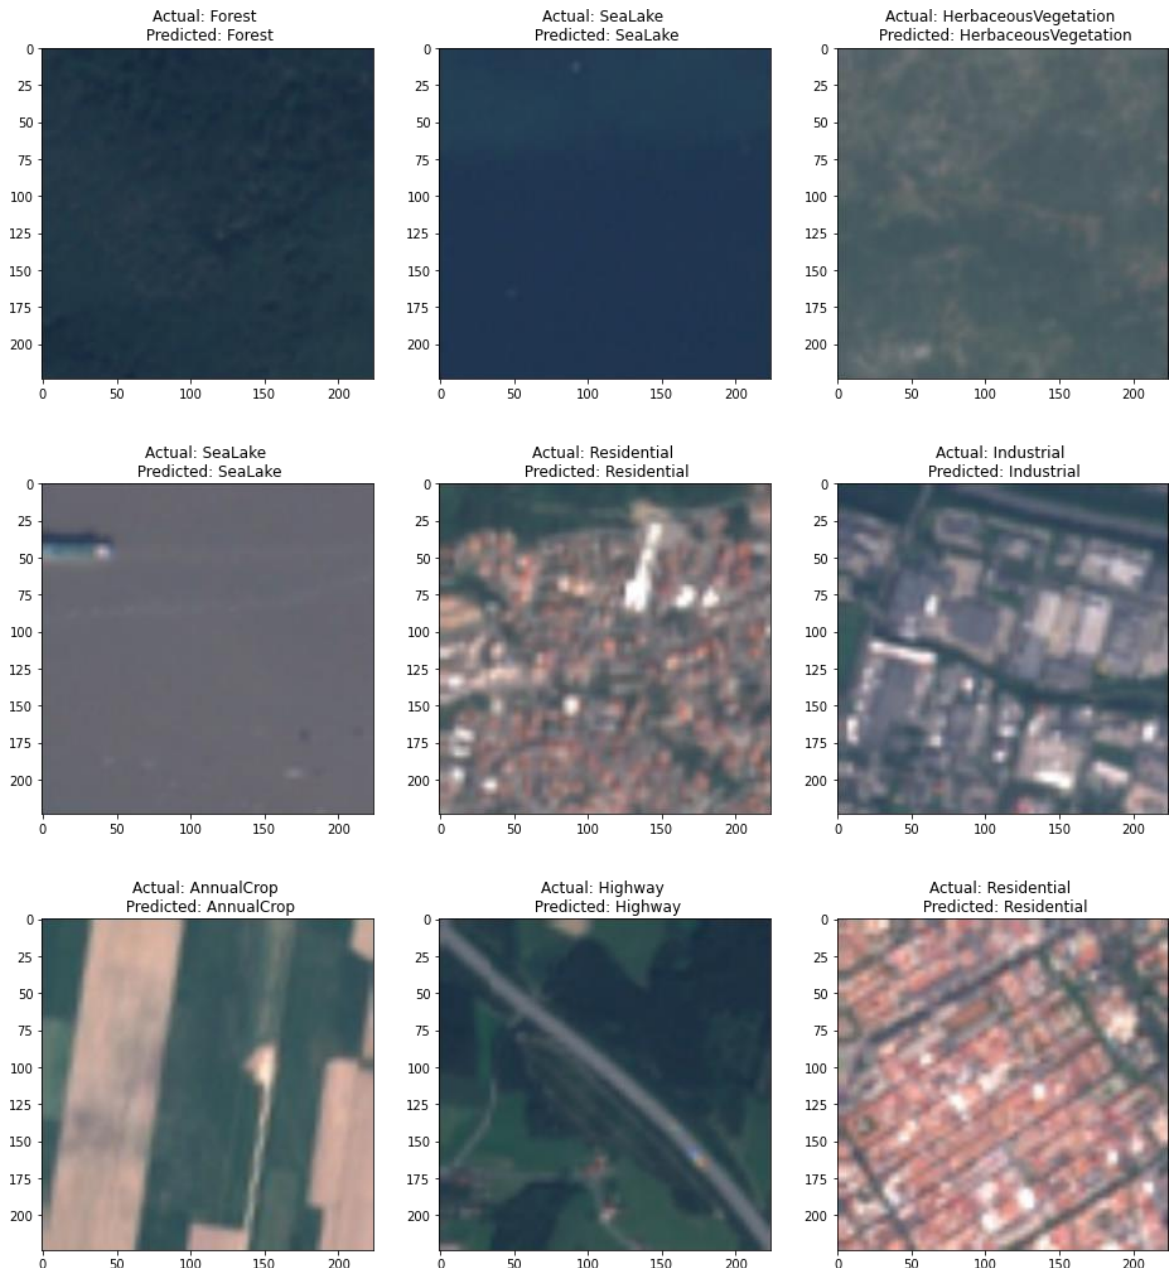


FIGURE 4.19 – exemple de classification

Matrice de confusion

est une matrice qui mesure la qualité d'un système de classification. Chaque ligne correspond à une classe réelle, chaque colonne correspond à une classe estimée. La cellule ligne L, colonne C contient le nombre d'éléments de la classe réelle L qui ont été estimés comme appartenant à la classe C1.

Un des intérêts de la matrice de confusion est qu'elle montre rapidement si un système de classification parvient à classifier correctement.

Exemple Les résultats sont mentionnées dans les figures suivantes.

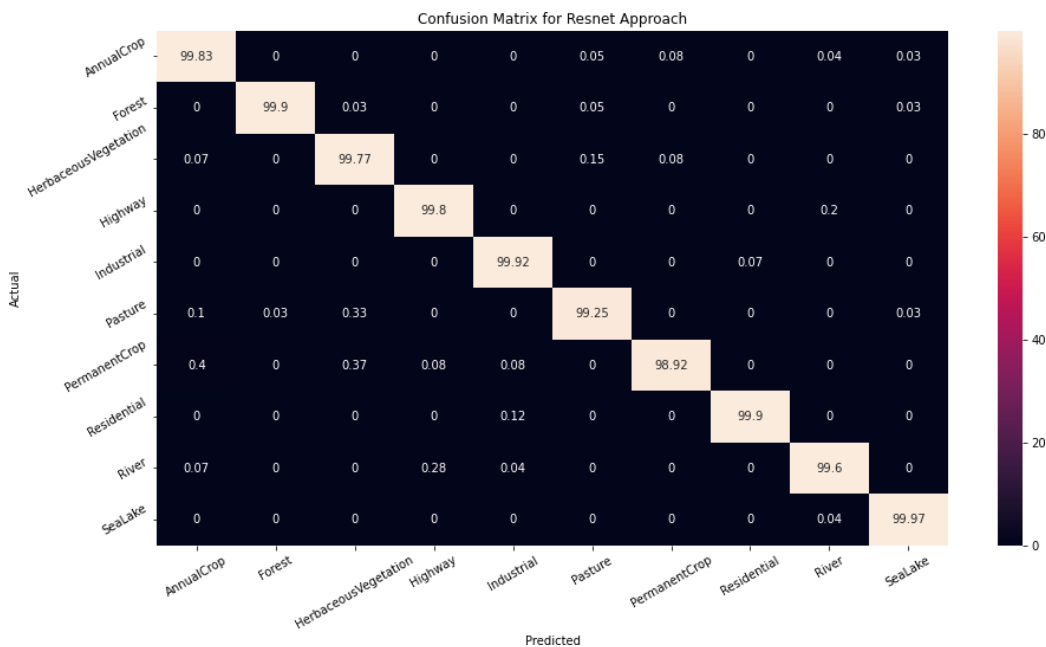


FIGURE 4.20 – matrice de confusion de validation

Nous pouvons constaté que le taux de bon classification est tolérant pour les différentes classes, que ce soit dans l'étape d'apprentissage ou de validation.




FIGURE 4.21 – matrice de confusion-test-

étude comparative

Afin de donner une crédibilité à notre travail, nous avons procédé à une comparaison de notre réseau profond avec quelques méthodes de classification d’images satellite qui se basent sur le deep learning(DL) et le transfer learning (TL), en utilisant le dataset EuroSAT.

nous pouvons constaté que notre modèle est le plus performant du fait que le taux de précision fournit est le plus élevé (99,10%) (Tableau 4.2).

Cela est du principalement au fait que notre réseau profond peut aller jusqu’à 55 couches de rofondeur, ce qui accroît bien sur son niveau d’apprentissage.

la formule utilisée pour le calcul de accuracy :

$$\text{Précission} = \frac{\text{nombre des prédictions corrects}}{\text{nombre total de predictions}}$$

FIGURE 4.22 – la formule de préciission(accuracy)

Authors	Model	Bands	Accuracy
Helber et al. [15]	GoogleNet	RGB	98.18%
Helber et al. [15]	ResNet-50	RGB	98.57%
Chen et al. [9]	Knowledge distillation	RGB	94.74%
Chong [10]	VGG16	RGB	94.50%
Sonune [22]	Random Forest	RGB	61.46%
Sonune [22]	ResNet-50	RGB	94.25%
Sonune [22]	VGG19	RGB	97.66%
Li et al. [17]	DDRL-AM	RGB	98.74%
Wiem Mi	wide resnet-50	RGB	99.10%

TABLE 4.2 – Comparaison entre les résultats LULC classification avec EuroSAT dataset

test des résultats

Dans le but de tester la fiabilité de notre réseau profond, nous avons procédé à la classification des images satellites qui n'appartiennent pas à notre base d'images, soit des images du satellite LandSat8 de résolution de 30m de la région de Biskra. Les caractéristiques de ces images sont mentionnées dans le tableau ci-dessous.

Image	Date d'acquisition	Résolution(m)	Classe
Ville Biskra	Février 2022	30	Residential
Barrage Foum El Ghororza	Juin 2022	30	Eau
Ville de Tolga	Juin 2022	30	Forêt

TABLE 4.3 – Caractéristiques des images de Test

Les résultats de la classification sont illustrés dans les figures suivantes (figure 4.22 ; figure 4.23 ; figure 4.24) :



FIGURE 4.23 – Ville de Biskra




FIGURE 4.25 – Région de Tolga



FIGURE 4.24 – Barrage Foug El Ghorza

La première image représente la ville de Biskra, elle contient de l'urbain ainsi que des terres nus et une petite parcelle d'Oasis. Notre système l'a classée comme Résidentiel. Nous jugeons que cette classification est correcte, car la classe dominante dans cette image est l'urbain.

-Pour la deuxième image qui représente le barrage de Foug El Ghorza, elle appartient à la classe Eau, et elle a été classée correctement par le réseau profond.

-La troisième image est une image de la région de Tolga, elle contient deux classes : l'Urbain et le Palmier Dattier. Mais la classe dominante est le Palmier Dattier. Cette image est considérée par notre système comme classe eau. Cela est dû à plusieurs facteurs à savoir :

- La réflectance du Palmier Dattier n'est pas la même que la réflectance de la forêt. Or notre raison n'est pas entraînée pour reconnaître cette classe, d'un côté,
- Et d'un autre côté, la classe la plus proche au Palmier Dattier en terme de réflectance est la classe eau, ce qui explique cette classification.
- Il ne faut souligner également que les images destinées pour le test du réseau profond et celles utilisées pour l'apprentissage n'ont pas la même résolution (30m pour le test et 10m pour l'apprentissage).

Limites du système classifieur et solutions proposées

En se basant sur les résultats obtenus précédemment, et vue la nature de la région de Biskra qui est une Oasis riche en Palmier Dattier, nous suggérons d'enrichir la base d'images avec des images de Palmiers Dattier. Nous pouvons remarquer également que notre système classifieur ne peut détecter qu'une seule classe à la fois. Or une image satellite contient généralement plusieurs classes, ce qui nous conduit à proposer de développer davantage notre réseau profond afin qu'il soit capable de détecter et classer toutes les régions de l'image. Cette opération qui est indispensable pour la réalisation de la carte d'occupation du sol qui est la base de toute étude ultérieure et la mise à jour de la cartographie de notre wilaya.

Conclusion

Dans ce chapitre, nous avons présenté les résultats obtenus après l'implémentation de notre système. Nous avons comparé nos résultats avec d'autres systèmes travaillant sur la même base d'image, et nous avons constaté que notre système est plus performant. Nous avons également présenté une étude critique de notre système classifieur et essayer de proposer des solutions à ces limites.

Conclusion générale

La classification d'image satellite est un axe prépondérant de la Télédétection. Pour estimer et prédire la classification des images, nous avons proposé un modèle automatique fondé sur les réseaux de neurones artificiels et qui se base sur l'apprentissage profond (deep learning). Les réseaux de neurones utilisés ne peuvent aller plus que 25 couches en profondeur, or le réseau utilisé dans notre travail, le ResNet-50, contient 50 couches en profondeur, et peut aller jusqu'à 55 couches. Nous avons utilisé, pour les étapes d'apprentissage et de validation de notre réseau profond, la base d'images Sentinel-2, qui se caractérise par une très grande précision : précision spatiale, précision spectrale et bonne précision temporelle, et qui contient un nombre important d'échantillons couvrant la plupart des classes continues dans une image satellite.

Les résultats de l'apprentissage et de test sont jugés bons comparés à d'autres systèmes classificateurs utilisant la même base d'images. Nous avons procédé, dans un second lieu, au test de notre réseau profond en utilisant des images satellites de régions de Biskra issues du satellite Landsat-8. Les résultats donnés par ces images ne sont plus au moins satisfaisants du fait que ces images ont une résolution plus faible que celles utilisées dans l'apprentissage et la validation, d'un côté, et d'un autre côté, ces images contiennent plusieurs classes à la fois, chose que notre réseau ne s'est pas entraîné à faire. De ce fait, nous proposons d'améliorer davantage notre réseau :

- Vu la nature de la région de Biskra qui est une Oasis riche en Palmier Dattier, nous suggérons d'enrichir la base d'images avec des images de Palmiers Dattier.
- Développons davantage notre réseau profond afin qu'il soit capable de dé-

tecter et classer toutes les régions de l'image. Cette opération qui est indispensable pour la réalisation de la carte d'occupation du sol qui est la base de toute étude ultérieure et la mise à jour de la cartographie de notre wilaya.

Bibliographie

- [1] Applications of machine learning. <https://www.javatpoint.com/applications-of-machine-learning>. [Online; accessed 15-03-2022].
- [2] Machine learning definition. <https://digitalinsiders.feelandclick.com/machine-learning-definition>. [Online; accessed 12-03-2022].
- [3] Tech deep learning : qu'est-ce que c'est? <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/>. [Online; accessed 15-03-2022].
- [4] Comprendre une image satellitaire. <https://cms.geobretagne.fr/content/comprendre-une-image-satellitaire#:~:text=La%20r%C3%A9solution%20spatiale%20est%20la,r%C3%A9solution%20spatiale%20du%20capteur%20utilis%C3%A9.,> 2016. [Online; accessed 10-03-2022].
- [5] Quelles sont les différences entre le deep learning et le machine learning? <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/deep-learning-vs-machine-learning/>, 2020. [Online; accessed 17-03-2022].
- [6] Pycharm. <https://www.zdnet.fr/telecharger/logiciel/pycharm-40369067s.htm>, 22/06/2022. [Online; accessed 2-04-2022].
- [7] Timothée Bailloeuil. *Contours actifs et information a priori pour l'analyse de changements : application à la mise à jour de cartes numériques du bâti urbain à partir d'images optiques de télédétection haute résolution*. PhD thesis, 2005.

- [8] Ferdinand Bonn and Guy Rochon. Précis de télédétection, volume 1 : principes et méthodes. *PUQ/AUPELF, Sainte-Foy*, 1992.
- [9] Guanzhou Chen, Xiaodong Zhang, Xiaoliang Tan, Yufeng Cheng, Fan Dai, Kun Zhu, Yuanfu Gong, and Qing Wang. Training small networks for scene classification of remote sensing images via knowledge distillation. *Remote Sensing*, 10(5) :719, 2018.
- [10] E Chong. Eurosat land use and land cover classification using deep learning, 2020. [Online; accessed 7-04-2022].
- [11] DataScientest. Kaggle : Tout ce qu'il faut savoir sur cette plateforme. <https://datascientest.com/kaggle-tout-ce-qu'il-a-savoir-sur-cette-plateforme>, 20 septembre 2021. [Online; accessed 2-04-2022].
- [12] Herinirina Nicolas Fanantenana, Rajaonarison Ny Ony Narindra Lova Hasina, Rafanomezantsoa Hery, Rakotoarisoa Andriamihaja Jean Claude, and Ahmad Ahmad. Une observation d'un goitre sur dysgénésie thyroïdienne pré-sternale. *Pan African Medical Journal*, 21(1), 2015.
- [13] Mohamed Habbane. *Teledetection passive et processus décisionnel a reference spatiale : application a l'aquaculture en milieu marin*. National Library of Canada=Bibliothèque nationale du Canada, Ottawa, 1998.
- [14] Charles R Harris, K Jarrod Millman, Stéfan J Van Der Walt, Ralf Gommers, Pauli Virtanen, David Cournapeau, Eric Wieser, Julian Taylor, Sebastian Berg, Nathaniel J Smith, et al. Array programming with numpy. *Nature*, 585(7825) :357–362, 2020.
- [15] Patrick Helber, Benjamin Bischke, Andreas Dengel, and Damian Borth. Eurosat : A novel dataset and deep learning benchmark for land use and land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7) :2217–2226, 2019.
- [16] John D Hunter. Matplotlib : A 2d graphics environment. *Computing in science & engineering*, 9(03) :90–95, 2007.

- [17] Jun Li, Daoyu Lin, Yang Wang, Guangluan Xu, Yunyan Zhang, Chibiao Ding, and Yanhai Zhou. Deep discriminative representation learning with attention map for scene classification. *Remote Sensing*, 12(9) :1366, 2020.
- [18] Rachid Mifdal. *Application des techniques d'apprentissage automatique pour la prédiction de la tendance des titres financiers*. PhD thesis, École de technologie supérieure, 2019.
- [19] Rachid Mifdal. *Application des techniques d'apprentissage automatique pour la prédiction de la tendance des titres financiers*. PhD thesis, École de technologie supérieure, 2019.
- [20] HANNANE Amir Mokhtar. *Conception d'un système hybride entre la Méta-heuristique Electromagnétique et l'algorithme de colonie de fourmis pour la classification des images satellitaires*. PhD thesis, Université mohamed boudiaf des sciences et de la technologie d'oran, 2010.
- [21] Erik Reinhard, Wolfgang Heidrich, Paul Debevec, Sumanta Pattanaik, Greg Ward, and Karol Myszkowski. *High dynamic range imaging : acquisition, display, and image-based lighting*. Morgan Kaufmann, 2010.
- [22] N Sonune. Land cover classification with eurosat dataset, 2020. [Online; accessed 7-04-2022].
- [23] Gary B Thomas B, Lina F. Transfer learning : Qu'est-ce que c'est? <https://datascientest.com/transfer-learning>, 21 juillet 2020. [Online; accessed 17-03-2022].
- [24] Thibault V. Scikit-learn : Découvrez la librairie python dédiée au machine learning. <https://datascientest.com/tout-savoir-sur-scikit-learn>, 31 mai 2021. [Online; accessed 20-03-2022].
- [25] Yingquan Wu, Krassimir Ianakiev, and Venu Govindaraju. Improved k-nearest neighbor classification. *Pattern recognition*, 35(10) :2311–2318, 2002.