

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Département : Génie électrique Et Informatique Industrielle

Mémoire de projet de fin d'études pour l'obtention du diplôme

d'Ingénieur d'Etat en Télécommunications

Spécialité

Systèmes de Télécommunications et Réseaux

Thème

Implémentation et évaluation de modèles profonds à base de CNN multidimensionnels, pour la classification des images hyperspectrales de télédétection

Réalisé par

Hiba HAMRARAS
Maissa Cerine OUNNAR

Présenté et soutenu publiquement le (02/07/2023)

Composition du Jury :

Présidente	Mme. CHIALI Imane,	M.C.B	ENST
Encadrante	Mme. CHOUAF Seloua,	M.A.A	ENST
Examinatrice	Mme. BOUCHAMA Samira,	M.C.B	ENST
Examineur	M. ABBADI Belkacem,	M.C.B	ENST

Dédicace

Je dédie ce travail

À ma famille qui m'a offert une éducation précieuse et dont l'amour a façonné la personne que je suis aujourd'hui.

À Mes chers parents, Nabyla et Boualem, ont fait d'innombrables sacrifices, prodigué leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études, Votre amour infini et vos sacrifices ont forgé mon chemin. Je vous suis reconnaissante pour tout ce que vous avez fait, Votre soutien inconditionnel restera à jamais gravé.

À mon frère jumeau Rafik et à ma chère sœur Hania, mes complices de chaque instant, qui m'ont toujours soutenu et encouragé durant ces années d'études. Je dédie ma réussite à mon cher grand-père Maamar, dont l'impact sur ma vie est éternel. Malgré son absence physique, son souvenir reste gravé dans mon cœur. Je sais qu'il aurait été fier de mes accomplissements en tant qu'ingénieure d'État. Que Dieu l'accorde en son vaste paradis. Je souhaite également à ma chère grand-mère Dahira une vie comblée de bonheur, de santé et de sérénité.

À toute la famille Bensaidi, mes oncles, tantes, cousins et cousines, en particulier à mon petit Racim.

À mon adorable binôme Hiba, partenaire d'apprentissage et amie précieuse, qui a rendu notre parcours inoubliable. Notre partenariat restera gravé dans ma mémoire, et je suis certaine que nos chemins continueront de se croiser et de se soutenir mutuellement dans les années

à venir. À mes chères amies Ines, Lina, Nesrine, Célia, Rym, Camélia, Ryane et Kaouthar, vous qui avez enrichi ma vie de votre présence, de votre soutien et de votre amour inconditionnel. Vous êtes les étoiles qui éclairent mon chemin. Puisseons-nous continuer à marcher côte à côte, créant des souvenirs inoubliables et partageant des joies infinies dans cette belle aventure de la vie.

Maïssa Cerine.

Je dédie ce travail

À mes chers parents « Larbi » et « Assia », je tiens à insister tout particulièrement sur mon immense gratitude envers vous. Votre amour inconditionnel, votre soutien indéfectible et vos prières incessantes ont été les fondements de ma réussite dans ce projet de fin d'études.

Vous avez été mes piliers, mes guides et mes inspirations tout au long de ce parcours. Votre présence bienveillante et vos encouragements constants m'ont donné la force et la confiance nécessaires pour surmonter les obstacles et aller de l'avant. Chaque jour, vous avez été là pour moi, me prodiguant des conseils avisés, écoutant mes préoccupations et me rappelant sans cesse que je pouvais atteindre mes rêves. Votre amour inébranlable et votre soutien inconditionnel ont été ma source de motivation constante.

Je ne peux pas non plus oublier mes sœurs bien-aimées, « Bouchra » et « Ikram ». Vous avez été mes complices, mes confidentes et mes plus grandes supportrices. Votre présence à mes côtés, vos encouragements ont été précieux.

À ma chère famille, en particulier à mes tantes et oncles paternels, ainsi qu'à ma famille maternelle "Mahamdi", Je tiens à exprimer ma sincère reconnaissance envers vous tous. Votre présence, votre soutien et votre affection ont été des éléments essentiels de ma réussite dans mon projet.

À ma chère amie et binôme « Maïssa », je tiens à te dédier ces mots sincères, pour notre amitié qui s'est développée et pour notre collaboration passionnée. Main dans la main, nous avons avancé vers nos objectifs, nous nous sommes aidés, au-delà des heures passées à travailler, nous avons partagé rires et complicité, les moments difficiles sont devenus légers. Aujourd'hui, je veux te dire merci, notre projet de fin d'études restera à jamais un témoignage de notre amitié, gravé. Que nos chemins se séparent ou se croisent, je garde précieusement ce lien qui nous rassemble.

Un remerciement spécial à mon amie « Sabeur Imene », dont le soutien indéfectible a été une force motrice tout au long de cette aventure. Tes encouragements, tes conseils et ta présence à mes côtés ont été inestimables. Merci d'avoir cru en moi.

À vous tous, je dédie cette réussite. Votre amour, votre soutien et vos prières ont façonné mon parcours et ont fait de moi la personne que je suis aujourd'hui. Je ne pourrais jamais exprimer suffisamment ma gratitude pour tout ce que vous avez fait pour moi.

Merci du fond du cœur pour tout ce que vous avez fait et continuez de faire pour moi. Je vous aime plus que les mots ne pourraient jamais l'exprimer.

Hiba

Remerciement

Ce projet de fin d'études a été réalisé au sein du département Génie Electrique et Informatique Industrielle (GEII) de l'Ecole Nationale Supérieure de Technologie (ENST) à Alger, Algérie.

Nous remercions premièrement le Dieu tout puissant qui ne cesse de nous protéger.

Nous voudrions tout d'abord adresser nos remerciements et notre reconnaissance à notre encadrante, Mme Chouaf Seloua, Maître Assistante du département GEII à ENST, pour sa patience, sa disponibilité et surtout ses judicieux conseils, qui ont contribué à alimenter notre réflexion.

Nous tenons à exprimer notre profonde gratitude aux membres du jury, pour leur précieuse contribution, leur soutien et temps consacrés à évaluer notre travail.

Nous remercions également toute l'équipe pédagogique de l'Ecole Nationale Supérieure de Technologie et les intervenants professionnels responsables de notre formation, et qui ont contribué à la réalisation de ce travail.

Table des matières

Dédicace	
Remerciement	
Table des figures...	I
Liste des tableaux...	II
Liste des acronymes...	III
Introduction Générale.....	1
ChapitreI Généralités	
I.1 Introduction	3
I.2 Observation de la terre.....	3
I.2.1 Objectif	3
I.2.2 Outils.....	3
I.2.3 Applications	4
I.3 Capteurs de télédétection.....	4
I.3.1 Types.....	4
I.3.2 Caractéristiques communes	6
I.4 Imagerie hyperspectrale (IHS).....	8
I.4.1 Définition	8
I.4.2 Propriétés	8
I.4.3 Avantages.....	9
I.4.4 Applications	10
I.5 Classification et deep learning.....	10
I.6 Classification d'images classiques et de télédétection	12
I.7 Conclusion	14
ChapitreII Classification par les CNN multidimensionnels	
II.1 Introduction	15
II.2 Traitement des données par l'intelligence artificielle et deep learning.....	15
II.3 Architecture de réseaux de neurones à convolution (CNN)	16
II.4 Les réseaux de neurones convolutifs multidimensionnels (CNN-nD)	16
II.4.1 Utilisation	17
II.4.2 Modèles d'implémentation.....	17
II.5 Paramètres d'influence sur l'entraînement.....	20
II.6 Métriques d'évaluation des performances	21
II.7 Conclusion	23

Chapitre III Expérimentations et résultats

III.1	Introduction	25
III.2	Rappels des objectifs à atteindre par le travail	25
III.3	Difficultés et solutions envisagées	25
III.4	Ressources exploitées	26
III.4.1	Le matériel informatique	26
III.4.2	Les outils logiciels	26
III.4.3	Les jeux de données hyperspectrales	27
III.4.4	Les modèles d'implémentation	28
III.5	Protocole expérimental	30
III.6	Présentation des résultats et discussion	31
III.6.1	Phase d'apprentissage	31
III.6.2	Phase de test	35
III.7	Les aboutissements du travail	40
III.8	Conclusion	41
	Conclusion générale	42
	Références bibliographiques	IV

Table des figures

Figure I.1: Les capteurs de télédétection : (a) passifs et (b) actifs	5
Figure I.2 : La présentation d'un cube de données hyperspectrales	8
Figure I.3 : Quelques exemples d'applications liés à l'IHS	10
Figure I.4 : Résultats de classification d'images pour l'identification des tumeurs cérébrales	11
Figure I.5 : Résultats de la cartographie de la végétation par télédétection.	13
Figure II.1 : L'architecture typique des CNNs	16
Figure II.2 : L'architecture d'un CNN-1D pour la classification IHS.....	18
Figure II.3 : L'architecture d'un CNN-2D pour la classification IHS.....	18
Figure II.4 : L'architecture d'un CNN-3D pour la classification IHS.....	20
Figure III-1 : Caractéristiques des principaux jeux de données utilisés pour la classification des IHS	28
Figure III-2 : L'architecture proposé pour CNN1D.....	30
Figure III-3 : L'architecture de « sharma » CNN2D.....	30
Figure III-4 : L'architecture de « chen » CNN3D.....	31
Figure III.5 : Organigramme décrivant la structure du code développé.....	32
Figure III-6.a : Evaluation de la phase d'apprentissage des différents modèles « Validation accuracy »	34
Figure III-6.b : Evaluation de la phase d'apprentissage des différents modèles « Training loss ».....	35
Figure III-7 : Présentation des prédictions et des vérités du terrain.....	36
Figure III-8 : Matrices de confusion formées pour chaque modèle et jeu de données.....	37

Liste des tableaux

Tableau I-1: Récapitulatif des capteurs de télédétection.....	7
Tableau III-1 : Les choix considérés pour les paramètres d'entrainement.	32
Tableau III-2 : Temps d'entrainement pris par chaque modèle CNN pour différents jeux de données.....	32
Tableau III-3 : Evaluation quantitative des modèles par l'accuracy et le kappa pour chaque jeu de données... ..	38
Tableau III-4 : Les F1 scores mesurés par classe, pour chaque modèle.....	40

Liste des acronymes

ACP	Analyse des composantes principales
ALOS	Advanced Land Observing Satellite
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
BDORTHO IRC	Base de Données Ortho-Rectifiée à Très Haute Résolution d'Images Radar Compact
CCNN	Réseaux de neurones convolutifs en cascade
CNN	Réseaux de neurones convolutifs
CRNN	Réseaux de neurones convolutifs récurrents
FN	False negatives
FP	False positives
GLAS	Geoscience Laser Altimeter System
IA	Intelligence artificielle
ICESat	Ice, Cloud, and land Elevation Satellite
IHS	Imagerie hyperspectrale
LiDAR	Light Detection And Ranging
MODIS	Moderate Resolution Imaging Spectroradiometer
RADARSAT	RADio Detection And Ranging SATellite
RNN	Les réseaux de neurones récurrents
ROSI	Reflective Optics System Imaging Spectrometer
SPOT-5	Satellite Pour l'Observation de la Terre
TN	True negatives
TP	True positives

Introduction Générale

L'observation de la Terre par le biais de la télédétection est devenue essentielle pour comprendre les processus environnementaux, gérer les ressources naturelles et surveiller les changements globaux. Les avancées technologiques ont permis le développement de capteurs de télédétection sophistiqués, tels que l'imagerie hyperspectrale, qui offre une résolution spectrale élevée permettant de capturer des informations détaillées sur la composition des objets terrestres. Cependant, l'exploitation efficace de ces données riches en informations représente un défi complexe, nécessitant des méthodes avancées de traitement et d'analyse.

La classification des images hyperspectrales, qui consiste à attribuer des étiquettes à des pixels ou des régions d'intérêt dans une image, est un problème clé dans le domaine de la télédétection. Cette classification permet de distinguer et d'identifier différents types de surfaces terrestres, tels que les forêts, les cultures, les zones urbaines, etc. Cependant les caractéristiques intrinsèques des images hyperspectrales rendent certaines tâches de traitement et d'analyse difficiles à accomplir, surtout lorsque des outils à performances limitées sont employés.

La classification des images hyperspectrales est confrontée à plusieurs défis. Tout d'abord, la dimensionnalité élevée des données pose un problème en termes de traitement et d'analyse, nécessitant des approches spécifiques pour extraire les informations discriminantes. De plus, les bandes spectrales sont souvent fortement corrélées, ce qui peut entraîner une perte d'informations lors de l'utilisation de méthodes linéaires de classification. En outre, la présence de bruit et de données redondantes peut affecter la précision et la fiabilité des résultats de classification. Par conséquent, il devient essentiel d'explorer de nouvelles approches basées sur l'intelligence artificielle pour améliorer la précision et l'efficacité de la classification des images hyperspectrales.

Ce mémoire vise à atteindre les objectifs suivants :

- ✓ Comprendre les principes de base de la télédétection, des capteurs utilisés et de l'imagerie hyperspectrale.
- ✓ Examiner le domaine de l'intelligence artificielle et ses applications dans la classification des images en télédétection.
- ✓ Etudier les modèles d'apprentissage profond utilisés pour la classification des images de télédétection en s'intéressant particulièrement aux modèles à base de CNN et CNN-nD.
- ✓ Réaliser des expériences sur des jeux de données réels afin d'évaluer des performances des modèles de classification choisis.
- ✓ Interpréter et analyser les résultats obtenus, en soulignant les avantages et les limites des approches testées pour la classification des images hyperspectrales.

Ce mémoire est structuré en trois chapitres :

- Le premier chapitre présente une introduction à la télédétection, en mettant l'accent sur les capteurs utilisés pour l'acquisition des données. Nous examinerons également les principes de l'imagerie hyperspectrale et les avantages qu'elle offre par rapport à d'autres techniques de télédétection seront également abordés.

Introduction Générale

- Le deuxième chapitre aborde le domaine de l'intelligence artificielle, en mettant en évidence son importance croissante dans le domaine de la télédétection. Nous présenterons les méthodes classiques de classification des images en télédétection, ainsi que les principaux modèles d'apprentissage profond utilisés dans ce domaine. Une attention particulière sera portée aux CNN et à leur utilisation dans la classification d'images, notamment les CNN multidimensionnels qui sont spécifiquement conçus pour traiter les données multidimensionnelles à grand volume telles que les données hyperspectrales.
- Enfin, le troisième chapitre présentera les expériences menées dans le cadre de ce projet de fin d'études, ainsi que les résultats obtenus. Nous décrirons les jeux de données utilisés, les architectures de CNN mises en œuvre et les métriques d'évaluation utilisées pour mesurer les performances des modèles. Les résultats obtenus seront analysés et discutés en détail afin de faire ressortir les avantages et les difficultés d'utilisation des CNNs multidimensionnels pour la classification.

Chapitre I Généralités

Chapitre I Généralités

I.1 Introduction

L'observation de la Terre à l'aide de capteurs de télédétection est devenue une technologie importante pour l'étude de la Terre. Les progrès technologiques ont conduit au développement de capteurs de précision et de technologies d'imagerie avancées, offrant un large éventail d'applications pour la surveillance de notre environnement.

Les capteurs de télédétection ont des caractéristiques spécifiques qui les rendent adaptés à des applications spécifiques. Certains sont conçus pour une résolution spatiale élevée, tandis que d'autres sont optimisés pour une résolution spectrale élevée. L'imagerie hyperspectrale est une technique d'observation de la Terre qui offre une très haute résolution spatiale et spectrale pour détecter des détails invisibles à l'œil nu.

Dans ce chapitre, nous allons examiner les diverses méthodes d'observation de la Terre, en accordant une attention particulière aux capteurs de télédétection et à l'imagerie hyperspectrale. Nous examinerons également les propriétés de ces capteurs, et comment elles peuvent être employées pour comprendre et surveiller notre environnement, afin de faire face aux défis environnementaux auxquels nous sommes confrontés. De plus, nous discuterons des applications de ces techniques, et de leur utilisation. Enfin, nous introduisons la notion de classification des images et le deep learning.

I.2 Observation de la terre

I.2.1 Objectif

L'humanité a longtemps cherché à observer ce qui existe autour et au-delà de la Terre. Nous retracerons l'évolution de l'observation de la Terre et des planètes d'abord à l'œil nu, puis avec les équipements de haute technologie utilisés aujourd'hui.

Les humains ont tenté d'explorer la Terre avec les premiers outils tels que les télescopes. Puis bientôt, l'humanité exploratrice l'a emmené plus loin, l'observant d'abord depuis les airs dans des ballons à air chaud, des vaisseaux spatiaux et des avions. Depuis cinquante ans, l'observation de la Terre est réalisée à l'aide de satellites géostationnaires ou non, qui renvoient des images de la surface de la Terre largement utilisées en météorologie. Ces satellites sont également utilisés pour les télécommunications. Ces satellites sont envoyés en orbite par la navette spatiale [1].

I.2.2 Outils

Pour observer la terre, les scientifiques font appel à la « télédétection ». La télédétection est un moyen utilisé par les scientifiques pour observer la Terre. Elle permet d'acquérir des informations sur un objet ou un phénomène sans contact direct en utilisant des instruments de mesure à distance de la surface terrestre. Ces instruments de mesure peuvent être utilisés dans l'eau, dans l'air ou dans l'espace. Chacun a ses propres caractéristiques et permet d'étudier les propriétés d'un objet ou d'un phénomène sous différents angles. Par exemple, un drone peut couvrir une surface au sol inférieure à 10 km, mais peut repérer des objets de

Chapitre I Généralités

3 cm, tandis qu'un satellite permet d'obtenir l'image d'un territoire de la taille de l'Islande à une résolution allant jusqu'à 35 cm [2].

- Satellites : Les satellites équipés de capteurs optiques et de radars sont utilisés pour l'imagerie satellitaire, la télédétection et la surveillance météorologique.
- Caméra aérienne : La caméra installée sur l'avion est utilisée pour prendre des images à haute résolution à la surface de la Terre, ce qui fait le terrain qui peut être dessiné et surveiller les changements environnementaux.
- Drone : Le drone est équipé de caméras et de capteurs pour surveiller les cultures, les forêts, les zones d'inondation et les zones à risque élevé [3].

I.2.3 Applications

L'observation de la Terre est un domaine en forte croissance, présentant de nombreuses opportunités d'innovation et dynamisé par un large éventail d'applications créant de la valeur dans différents secteurs, tels que l'agriculture de précision, surveillance de l'environnement, la gestion des ressources naturelles et les catastrophes naturelles, l'exploration de gaz et de pétrole ou la météorologie [4]

I.3 Capteurs de télédétection

Les capteurs de télédétection sont des instruments qui permettent de mesurer les propriétés électromagnétiques de la surface de la Terre ou d'une autre planète depuis l'espace. Ces capteurs mesurent différentes bandes du spectre électromagnétique, de l'infrarouge lointain aux ondes radio, en passant par la lumière visible et la lumière ultraviolette [5]. Les données collectées par ces capteurs peuvent être utilisées pour créer des images de la surface de la Terre et cartographier les sols, les cultures, les forêts, les zones humides, les océans, etc. Ils peuvent également suivre l'évolution de ces éléments dans le temps et surveiller les changements environnementaux tels que la déforestation, l'urbanisation, la désertification, la fonte des glaciers, etc.

I.3.1 Types

Il existe différents types de capteurs de télédétection que l'on pourra classer en deux grandes catégories :

I.3.1.1 Les capteurs actifs mesurent la réflexion de la lumière qui a été envoyée vers l'objet.

- ✓ Les capteurs radar : qui emploient des ondes électromagnétiques pour mesurer la réflexion des surfaces terrestres. Ils sont utiles pour cartographier les sols, détecter les changements dans les zones humides et les océans, et surveiller les mouvements de la croûte terrestre. Des exemples de capteurs radar sont RADARSAT, Sentinel-1 et ALOS.
- ✓ Les capteurs LiDAR : qui utilisent des lasers pour mesurer la distance entre la surface terrestre et le capteur. Ils sont utilisés pour cartographier la topographie de la surface

Chapitre I Généralités

terrestre, détecter les changements dans la hauteur de la végétation, et créer des modèles numériques de terrain. Des exemples de capteurs LiDAR sont ICESat et GLAS.

- ✓ Les capteurs de luminescence : sont également actifs, mais la réception a lieu dans une bande spectrale différente de celle de l'émission.
- ✓ Les capteurs d'orientation : mesurent les angles ou les vitesses angulaires de déplacement entre les axes d'un engin spatial et des axes de référence. Il est important de signaler que ces capteurs sont parfois embarqués de manière jumelée à d'autres types de capteurs gyroscopiques ou optiques (tels que les capteurs d'horizon, solaires et stellaires).
- ✓ Les capteurs solaires : transforment l'énergie solaire en électricité.

I.3.1.2 Les capteurs passifs mesurent la réflexion de la lumière naturelle sur la Terre.

- ✓ Les capteurs thermiques : qui mesurent la radiation thermique émise par les surfaces terrestres. Ils sont utilisés pour détecter les incendies, mesurer la température des sols et des eaux, et cartographier les sources de chaleur. Des exemples de capteurs thermiques sont MODIS et ASTER.
- ✓ Les capteurs optiques : qui mesurent la lumière visible et proche-infrarouge réfléctée par la surface terrestre. Ils sont utilisés pour produire des images et des cartes de la surface terrestre, ainsi que pour détecter les changements dans la végétation, les sols, les eaux côtières, etc. il existe des capteurs optiques panchromatiques, multispectraux et hyperspectraux ou les capteurs de spectrométrie (Les capteurs de spectrométrie : qui mesurent les propriétés spectrales de la lumière électromagnétique, comme la réflexion, la transmission et l'émission. Ils sont utilisés pour cartographier la composition chimique et minéralogique des sols, des roches et de la végétation, ainsi que pour détecter les polluants atmosphériques [5]).

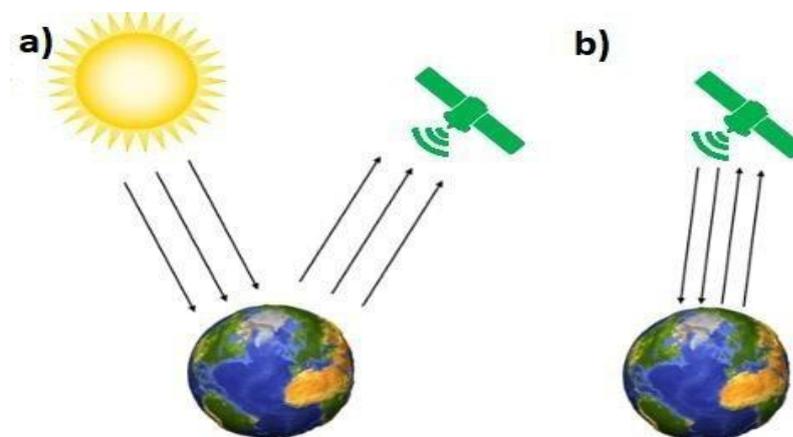


Figure I.1: Les capteurs de télédétection : (a) passifs et (b) actifs.[6]

I.3.2 Caractéristiques communes

Les capteurs de télédétection jouent un rôle crucial dans notre compréhension et notre surveillance de la Terre et de son environnement. Ces dispositifs sophistiqués sont utilisés pour collecter des données à distance, ce qui permet d'obtenir des informations précieuses sur la surface de la Terre, l'atmosphère, les océans et bien d'autres domaines. Les caractéristiques des capteurs de télédétection jouent un rôle essentiel dans leur capacité à détecter, mesurer et enregistrer les propriétés des objets et des phénomènes étudiés. Voici quelques caractéristiques :

- a. **La résolution spatiale** se réfère à la taille de chaque pixel dans l'image. Les capteurs à haute résolution spatiale peuvent distinguer des objets de quelques mètres de taille [8].
- b. **La résolution radiométrique** d'un capteur de télédétection fait référence à sa sensibilité à la variation de l'intensité lumineuse. Une résolution radiométrique plus élevée permet de distinguer de plus petites différences de réflectance ou de rayonnement émis, ce qui est important pour des applications telles que la détection de changements subtils dans les caractéristiques des objets [9].
- c. **La résolution temporelle** se réfère à la fréquence à laquelle le capteur collecte des données sur une même zone. Les capteurs à haute résolution temporelle peuvent fournir des images de la même zone toutes les quelques semaines [7].
- d. **La sensibilité** se réfère à la capacité du capteur à mesurer de faibles niveaux de signal. Les capteurs les plus sensibles peuvent détecter de faibles niveaux de radiation ou de réflexion de la surface terrestre [10]
- e. **Le coût** varie en fonction du type de capteur, de la résolution et de la sensibilité. Les capteurs les plus avancés peuvent être très coûteux, mais ils peuvent fournir des données précises et détaillées sur la surface terrestre [10]

Voici un tableau récapitulatif des capteurs de télédétection :

Chapitre I Généralités

Tableau I-1: Récapitulatif des capteurs de télédétection

Type de capteur	Nature	Propriétés	Classification
Capteur de luminescence	Mesure l'émission de lumière par des objets fluorescents	Détecte des matériaux spécifiques et des réactions chimiques	Classification selon le type d'émission lumineuse
Capteur solaire	Mesure l'énergie solaire	Utile pour la surveillance du rayonnement solaire et l'énergie solaire	Classification selon le type de mesure solaire
Capteur thermique	Mesure les émissions thermiques	Détecte et mesure les différences de température	Classification selon la plage spectrale et la résolution thermique
Capteur optique	Mesure la réflexion de la lumière	Sensible aux changements de lumière, utile pour l'imagerie	Classification selon le spectre électromagnétique
Capteur radar	Mesure la réflexion d'ondes radar	Peut pénétrer les nuages, utile pour l'imagerie sous les nuages	Classification selon la polarisation
Capteur lidar	Mesure la réflexion de la lumière laser	Donne des informations précises sur la topographie et la structure	Classification selon le type de laser et le nombre de retours
Capteur d'orientation	Mesure l'orientation ou l'inclinaison	Utilisé pour la navigation, l'orientation et le suivi des mouvements	Classification selon la technologie utilisée

I.4 Imagerie hyperspectrale (IHS)

I.4.1 Définition

L'imagerie hyperspectrale est une méthode non destructive qui explore le spectre électromagnétique au-delà des trois canaux spectraux (RVB) des caméras couleur conventionnelles. Cette approche permet la détection d'un grand nombre de bandes spectrales allant du visible au proche infrarouge. Elle fournit une information spatiale et spectrale pour chaque pixel de l'image, permettant ainsi l'identification de molécules, de matériaux ou de tissus grâce à leur signature spectrale distinctive [12].

L'imagerie hyperspectrale offre une collecte d'informations extrêmement précises sur la surface terrestre, car chaque bande spectrale peut révéler des caractéristiques uniques de l'objet ou de la scène observés. Toutefois, le traitement de l'imagerie hyperspectrale peut être plus complexe que celui de l'imagerie optique traditionnelle en raison du grand nombre de bandes spectrales mesurées. Cela nécessite l'utilisation d'algorithmes sophistiqués pour extraire les informations pertinentes des données hyperspectrales.

Les images monochromatiques acquises sont regroupées dans un cube hyperspectral, qui contient à la fois des informations spatiales et spectrales de l'échantillon. Ce cube hyperspectral est formé par un empilement d'images monochromatiques. Selon la taille du capteur utilisé, un seul cube peut contenir plusieurs millions de spectres, offrant ainsi une source d'information extrêmement riche [12].

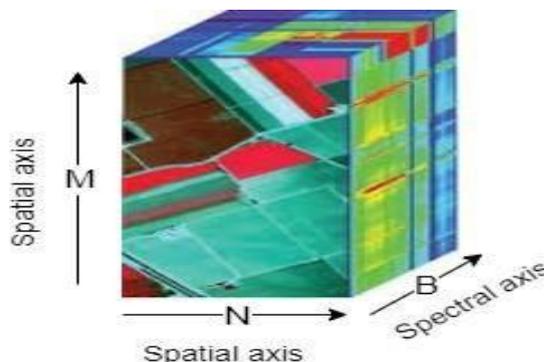


Figure I.2 : La présentation d'un cube de données hyperspectrales. [13]

I.4.2 Propriétés

L'imagerie hyperspectrale présente plusieurs caractéristiques qui la distinguent des autres techniques d'imagerie :

- a. **La résolution spectrale**, Les images hyperspectrales de télédétection offrent une résolution spectrale très élevée par rapport aux images multispectrales traditionnelles. Elle est de l'ordre de centaines de bandes spectrales distinctes et étroites avec une largeur de quelques nanomètres. [14].

- b. **La résolution spatiale**, La résolution spatiale des images hyperspectrales de télédétection peut varier en fonction du capteur utilisé et des spécifications de la mission. La résolution spatiale est généralement exprimée en termes de taille du pixel, c'est-à-dire la taille de chaque élément d'image dans le monde réel.

Les capteurs hyperspectraux peuvent offrir une résolution spatiale allant de plusieurs kilomètres à quelques centimètres. Les capteurs à plus haute résolution, peuvent avoir des pixels de l'ordre de quelques dizaines de centimètres. [15].

- c. **La résolution radiométrique**, Sur le plan radiométrique, les images hyperspectrales de télédétection offrent également une résolution élevée. Elle se réfère à la sensibilité du système IHS pour détecter et quantifier les variations d'intensité lumineuse dans chaque bande spectrale. Une résolution radiométrique plus élevée indique que le système peut discriminer avec précision de faibles variations d'intensité, permettant ainsi une meilleure caractérisation des matériaux et des propriétés radiométriques des objets [16].

I.4.3 Avantages

L'imagerie hyperspectrale présente plusieurs avantages par rapport à d'autres techniques d'imagerie dont :

- a. **Capacité de caractérisation précise des matériaux**, l'IHS permet d'obtenir des signatures spectrales détaillées des matériaux, ce qui facilite leur identification et leur caractérisation précise. Cette capacité est utile dans des domaines tels que la géologie, l'agriculture, la télédétection environnementale, etc. [17]
- b. **Détection d'anomalies et d'informations cachées**, grâce à sa résolution spectrale élevée, l'IHS peut détecter des variations subtiles dans les spectres, révélant ainsi des anomalies ou des informations cachées. Cela peut être appliqué à des domaines tels que la détection de polluants, la surveillance de la santé des cultures, etc. [18]
- c. **Analyse quantitative**, l'IHS permet d'effectuer des analyses quantitatives pour estimer les concentrations de composés chimiques, mesurer des paramètres environnementaux, etc. Cela permet une évaluation précise des propriétés physiques et chimiques des objets et de leur environnement [19].
- d. **Cartographie détaillée des caractéristiques**, l'IHS permet de créer des cartes détaillées des caractéristiques présentes dans une scène, telles que la distribution spatiale des différents matériaux, les indices de végétation, les propriétés chimiques, etc. Cela permet une meilleure compréhension et une analyse approfondie de l'environnement étudié [20].

I.4.4 Applications

L'imagerie hyperspectrale trouve des applications importantes dans l'industrie alimentaire pour assurer la qualité des produits, dans l'agriculture de précision améliorer la gestion des cultures et de détecter les maladies des plantes et les carences nutritionnelles. Dans la surveillance de l'environnement pour surveiller les changements environnementaux tels que la dégradation des forêts, la pollution des sols et de l'eau et la qualité de l'air. Dans le domaine médical pour le diagnostic précis des maladies, dans l'industrie pharmaceutique pour le contrôle qualité des médicaments, et dans l'industrie du recyclage pour faciliter le tri et la séparation des matériaux. Ces applications démontrent le potentiel de l'IHS à améliorer les processus et à garantir des produits de qualité dans différents secteurs industriels [13].

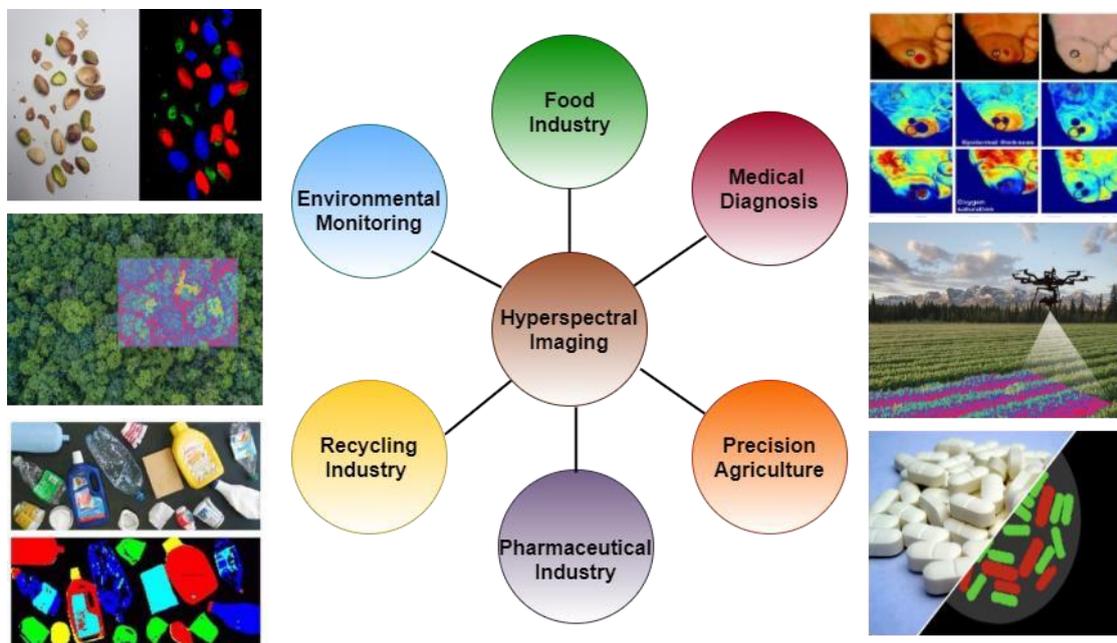


Figure I.3 : Quelques exemples d'applications liés à l'IHS. [13]

I.5 Classification et deep learning

La classification est une application centrale du deep learning (DL) qui trouve des applications dans de nombreux domaines tels que la vision par ordinateur, le traitement du langage naturel, la bioinformatique, et bien d'autres. Cette technique permet de catégoriser et d'attribuer des étiquettes ou des classes à des données en fonction de leurs caractéristiques, ce qui est crucial pour analyser des ensembles de données massives et complexes. [21]

Le deep learning s'inscrit dans le domaine plus vaste de l'intelligence artificielle (IA), qui vise à conférer aux systèmes informatiques des capacités cognitives similaires à celles des êtres humains. Le deep learning est une approche spécifique de l'IA qui se concentre sur l'apprentissage automatique de représentations hiérarchiques à partir de données brutes.

Chapitre I Généralités

La classification est une tâche fondamentale de l'apprentissage automatique, et le deep learning a révolutionné ce domaine grâce à sa capacité à extraire des caractéristiques complexes et à capturer des relations non linéaires dans les données. Les réseaux de neurones profonds, tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN), sont couramment utilisés pour la classification en raison de leur aptitude à modéliser des données hautement structurées, comme les images et les séquences.

Dans le domaine de la vision par ordinateur, par exemple, les CNN ont engendré d'importantes avancées dans la reconnaissance et la détection d'objets, la segmentation d'images, et d'autres tâches de classification. Ces réseaux sont capables d'apprendre des caractéristiques visuelles à partir des données d'apprentissage, leur permettant ainsi de généraliser et de reconnaître des objets avec une grande précision dans de nouvelles images. [22]

De même, dans le traitement du langage naturel, les RNN et les transformers ont révolutionné la classification de texte, la traduction automatique, la génération de texte, et d'autres tâches liées au langage. Ces modèles peuvent apprendre des représentations sémantiques des mots et des phrases, ce qui leur permet de comprendre et d'interpréter le langage humain avec une précision accrue. [23]

Au-delà de ces domaines spécifiques, la classification basée sur le deep learning est appliquée dans divers secteurs industriels. Par exemple, dans le domaine de la santé, les modèles de deep learning sont utilisés pour la classification d'images médicales, permettant ainsi une détection plus précise des maladies et des anomalies. Dans le secteur financier, la classification des données de marché et des comportements des clients revêt une importance cruciale pour la prise de décisions d'investissement et la détection de fraudes. [24]

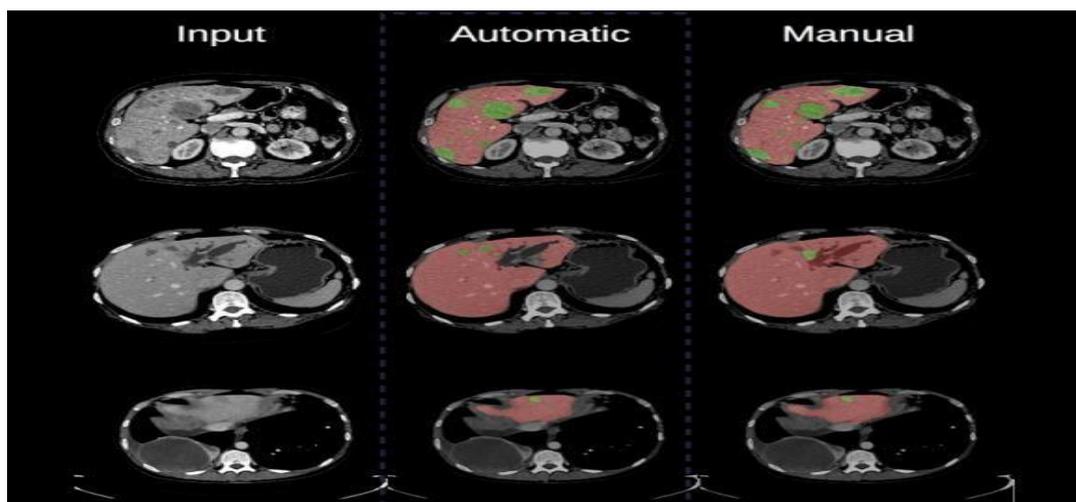


Figure I.4 : Résultats de classification d'images pour l'identification des tumeurs cérébrales. [25]

Chapitre I Généralités

La figure (I.4) montre la segmentation de lésions dans un organe à l'aide de techniques d'apprentissage automatique, à partir d'une image source de tomographie assistée par ordinateur (CT scan) (à gauche), réalisée par une architecture de réseaux de neurones convolutifs (au centre) et manuellement (à droite). [25]

I.6 Classification d'images classiques et de télédétection

La classification des images revêt une importance fondamentale dans le domaine de la vision par ordinateur, trouvant des applications variées telles que la surveillance, la cartographie, la télédétection, et bien d'autres. Son objectif est d'attribuer des étiquettes ou des catégories aux images en fonction de leurs caractéristiques visuelles. Il est essentiel de comprendre la différence entre la classification des images classiques et celle des images de télédétection afin de saisir pleinement leur contexte et leurs spécificités. [26]

Dans un cadre plus large, la classification des images classiques et des images de télédétection s'inscrit dans le vaste domaine de la vision par ordinateur et de l'apprentissage automatique. La vision par ordinateur vise à doter les systèmes informatiques de capacités de compréhension visuelle similaires à celles des êtres humains, tandis que l'apprentissage automatique permet aux systèmes de reconnaître et de généraliser des motifs à partir de données d'entraînement. [27]

La classification des images classiques concerne la catégorisation d'images numériques traditionnelles, comme des photographies ou des images capturées par des caméras. Dans ce contexte, l'objectif est de classer des objets, des scènes ou des personnes en fonction de leurs caractéristiques visuelles. Les techniques de classification des images classiques peuvent utiliser des caractéristiques extraites manuellement, telles que les textures, les couleurs, les formes, ou des descripteurs spécifiques pour effectuer la classification.

En revanche, la classification des images de télédétection se focalise sur la catégorisation d'images obtenues à partir de capteurs montés sur des satellites, des avions ou d'autres plateformes de télédétection. Les images de télédétection sont souvent multidimensionnelles et renferment des informations dans des bandes spectrales (par exemple, les images hyperspectrales) ou des informations de profondeur (par exemple, les images LIDAR). Cette classification joue un rôle crucial dans l'analyse des données de télédétection, permettant la détection de changements environnementaux, la surveillance des cultures, la cartographie des ressources naturelles, et bien d'autres applications. [28]

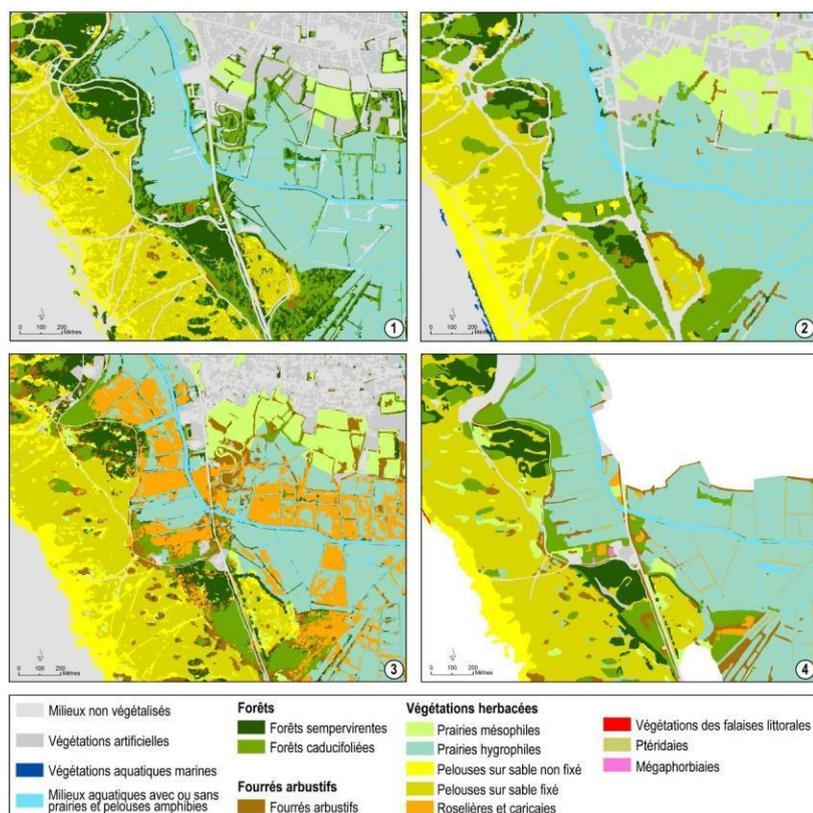


Figure I.5 : Résultats de la cartographie de la végétation par télédétection.[29]

La figure (I.5) présente un extrait au 1/10 000 des cartes issues du traitement des trois types d'images sur le site des dunes de la Sauzaie et marais du Jaunay au niveau « Types de formations végétales » (1 : BDORTHO IRC ; 2 : SPOT5 ; 3 : Worldview-2 ; 4 : Carte de terrain simplifiée élaborée en 2009). [29]

Les techniques avancées de deep learning, notamment les réseaux de neurones convolutifs multidimensionnels (ou CNN multidimensionnels), peuvent être bénéfiques pour la classification des images dans les deux cas. Ces CNN multidimensionnels sont spécialement conçus pour traiter des données d'images complexes et sont capables d'apprendre des caractéristiques discriminantes à partir des données brutes, sans nécessiter d'extraction manuelle de ces caractéristiques. Cette approche permet une meilleure généralisation et une précision accrue dans la classification des images. [30]

En résumé, la classification des images classiques et des images de télédétection constitue une application clé de la vision par ordinateur et de l'apprentissage automatique. Ces deux domaines se rejoignent grâce à l'utilisation de techniques de classification telles que les CNN multidimensionnels, qui permettent une catégorisation précise des images en fonction de leurs caractéristiques visuelles. L'évolution des techniques de classification et l'intégration du deep learning continueront de jouer un rôle essentiel dans la compréhension et l'exploitation des images dans divers domaines d'application.

I.7 Conclusion

La télédétection est une technique largement utilisée pour observer la Terre, grâce à des capteurs spécialisés. L'imagerie hyperspectrale est de plus en plus populaire, offrant une résolution spatiale et spectrale élevée, permettant de détecter des détails invisibles à l'œil nu. Elle est utilisée dans diverses applications telles que la surveillance de la végétation, la détection de polluants atmosphériques et le suivi du changement climatique. La classification des images de télédétection est une application majeure, utilisant le deep learning pour extraire des caractéristiques complexes et classifier différents types de paysages, bâtiments et végétation. Cependant, les résolutions spatiales et spectrales variables posent des défis nécessitant des techniques adaptées pour assurer une précision optimale.

Chapitre II

Classification par les CNN multidimensionnels

Chapitre II Classification par les CNN multidimensionnels

II.1 Introduction

Ce chapitre se focalise sur l'utilisation des réseaux de neurones convolutifs (CNN), une approche de deep learning, pour la classification des données. Après avoir introduit le sujet de manière générale dans le premier chapitre, nous nous plongeons maintenant dans les détails de l'apprentissage profond et de son application spécifique à travers les CNN.

Le DL est une discipline de l'intelligence artificielle, a révolutionné la façon de traiter et d'analyser les données. Parmi les différents modèles disponibles, les CNN se sont révélés être parmi les plus puissants et les plus utilisés dans le domaine de la classification. Ils sont particulièrement adaptés pour extraire des caractéristiques significatives à partir de données complexes telles que des images, des vidéos ou des séquences temporelles.

II.2 Traitement des données par l'intelligence artificielle et deep learning

L'application de l'intelligence artificielle (IA) et du deep learning dans le traitement des données a provoqué une véritable révolution dans de nombreux domaines, ouvrant ainsi de nouvelles perspectives. Ces techniques permettent d'extraire des informations complexes, de révéler des schémas cachés et de prendre des décisions autonomes à partir de vastes ensembles de données. Dans un contexte plus large, l'intelligence artificielle et le deep learning font partie d'une révolution technologique qui transforme la manière d'interagir avec les données et de résoudre des problèmes. [31]

Le traitement des données est au cœur de nombreuses disciplines scientifiques et industrielles, allant de la finance et de la santé à la robotique et à la recherche spatiale. Traditionnellement, ce traitement impliquait l'utilisation de méthodes statistiques et d'algorithmes classiques, qui pouvaient présenter des limitations quant à leur capacité à extraire des informations complexes et à traiter de grandes quantités de données. C'est là que l'intelligence artificielle et le deep learning ont apporté une avancée majeure.

L'intelligence artificielle est un domaine interdisciplinaire qui vise à créer des systèmes informatiques capables d'imiter certaines fonctions cognitives humaines, comme la perception, la compréhension du langage naturel, le raisonnement et la prise de décision. [32]

Dans le domaine du traitement des données, l'intelligence artificielle et le deep learning ont permis d'importantes avancées. Par exemple, dans le domaine de la vision par ordinateur, les réseaux de neurones convolutifs (CNN) ont révolutionné la reconnaissance d'images et la classification d'objets. Ces réseaux sont capables de "voir" les images en analysant les motifs et les caractéristiques présents dans les données. [33] [34]

De même, dans le domaine du traitement du langage naturel, les modèles de langage basés sur le deep learning, tels que les réseaux de neurones récurrents (RNN) et les Transformers, ont considérablement amélioré la traduction automatique, la génération de texte et la compréhension du langage. [35]

II.3 Architecture de réseaux de neurones à convolution (CNN)

Un CNN est simplement un empilement de plusieurs couches de convolution, pooling, correction ReLU et fully-connected. Chaque image reçue en entrée va donc être filtrée, réduite et corrigée plusieurs fois, pour finalement former un vecteur. Dans le problème de classification, ce vecteur contient les probabilités d'appartenance aux classes.

Tous les réseaux de neurones convolutifs doivent commencer par une couche de convolution et finir par une couche fully-connected. Les couches intermédiaires peuvent s'empiler de différentes manières, à condition que la sortie d'une couche ait la même structure que l'entrée de la suivante. Par exemple, une couche fully-connected, qui renvoie toujours un vecteur, ne peut pas être placée avant une couche de pooling, puisque cette dernière doit recevoir une matrice 3D. (Figure II.1)

En général, un réseau de neurones empile plusieurs couches de convolution et de correction ReLU, ajoute ensuite une couche de pooling (facultative), et répète ce motif plusieurs fois ; puis, il empile des couches fully-connected. [38]

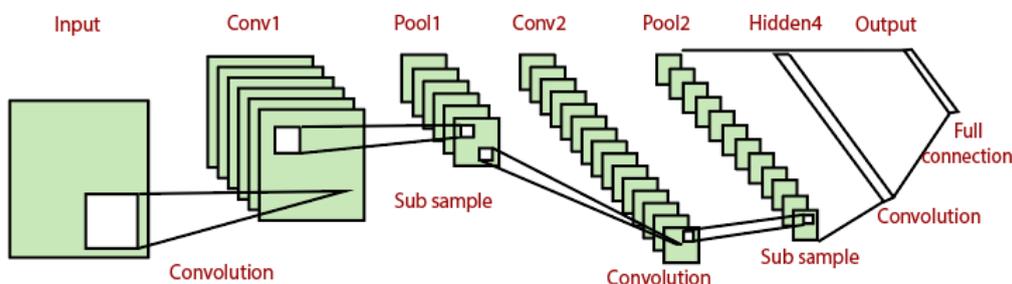


Figure II.1 : L'architecture typique des CNNs. [39]

Les modèles à base de CNN offrent de nombreux avantages. Ils sont capables de capturer des caractéristiques complexes et non linéaires à partir des images, ce qui les rend efficaces pour la classification de divers objets, textures et motifs visuels. De plus, grâce à leur architecture hiérarchique, les CNN peuvent apprendre des représentations de plus haut niveau, ce qui permet une classification plus précise et robuste. [40]

II.4 Les réseaux de neurones convolutifs multidimensionnels (CNN-nD)

Les réseaux de neurones convolutifs multidimensionnels (CNN) représentent une extension des CNN traditionnels, spécialement conçus pour traiter des données présentant des dimensions supplémentaires, comme les images hyperspectrales utilisées en télédétection. Ces réseaux sont adaptés spécifiquement à la classification d'images complexes et offrent des avantages uniques pour l'analyse de données multidimensionnelles.

Dans le cadre plus large de l'apprentissage automatique et de la vision par ordinateur, les CNN ont révolutionné notre approche du traitement des données visuelles en permettant une extraction automatique des caractéristiques à partir des données brutes. Cependant, les

Chapitre II Classification par les CNN multidimensionnels

données hyperspectrales présentent des défis supplémentaires en raison de leur dimensionnalité élevée et de leur richesse en informations spectrales. [41]

Les CNN multidimensionnels sont spécialement conçus pour traiter ces données en capturant les motifs et les relations spectrales qui sont essentiels pour une classification précise des images hyperspectrales. Contrairement aux CNN traditionnels qui opèrent sur des données bidimensionnelles, les CNN multidimensionnels prennent en compte les dimensions supplémentaires, telles que la profondeur spectrale, afin d'extraire des caractéristiques discriminantes à partir des données.

II.4.1 Utilisation

Les CNNs multidimensionnels sont largement utilisés dans le domaine de la télédétection pour la classification d'images hyperspectrales. Leur utilisation permet de résoudre des problèmes complexes tels que la détection d'objets, la cartographie des habitats, l'identification des cultures, etc. Ces réseaux offrent une approche puissante pour extraire des informations pertinentes à partir des données hyperspectrales et réaliser des tâches de classification précises.

Il est important de noter que le choix du modèle spécifique de CNN multidimensionnel dépendra des besoins et des caractéristiques du problème à résoudre. Différentes architectures, telles que les réseaux de neurones convolutifs en cascade (CCNN) et les réseaux de neurones convolutifs récurrents (CRNN), peuvent être utilisés en fonction des exigences de classification spécifiques. [42]

L'une des particularités des CNNs multidimensionnels est leur capacité à effectuer des convolutions sur des données hyperspectrales, ce qui leur permet d'exploiter les informations spectrales dans le processus de classification. En appliquant des filtres sur chaque bande spectrale, les CNNs peuvent détecter des caractéristiques locales et des relations entre les bandes, améliorant ainsi la précision de la classification. [37]

II.4.2 Modèles d'implémentation

Les réseaux de neurones convolutifs multidimensionnels (CNN) sont des architectures puissantes utilisées pour la classification d'images dans différentes dimensions, qu'il s'agisse de séquences temporelles (CNN1D), d'images bidimensionnelles (CNN2D) ou d'images volumétriques (CNN3D). Ces modèles sont largement adoptés dans divers domaines tels que la vision par ordinateur, le traitement du langage naturel, la bioinformatique et la télédétection.

Dans le domaine plus vaste de l'apprentissage automatique, les CNN ont révolutionné l'approche de la classification d'images en permettant une extraction automatique des caractéristiques pertinentes à partir des données brutes. Chaque type de CNN multidimensionnel est spécifiquement conçu pour traiter des données dans une dimension particulière et exploiter les relations et les structures inhérentes à ces données. [27]

II.4.2.1 Le CNN 1D

Le CNN 1D est utilisé pour l'extraction et la classification de caractéristiques des images hyperspectrales (IHS) en se basant uniquement sur les informations spectrales. Ce modèle exploite les corrélations locales entre les bandes spectrales pour extraire des caractéristiques pertinentes. La structure convolutive en une dimension permet au modèle de capturer les relations séquentielles et de prendre en compte l'ordre des éléments dans la séquence.

Il est construit en empilant plusieurs couches de convolution et de pooling. Les couches de convolution effectuent des opérations de convolution sur les données d'entrée pour extraire des caractéristiques spectrales profondes, tandis que les couches de pooling réduisent la résolution des cartes de caractéristiques.

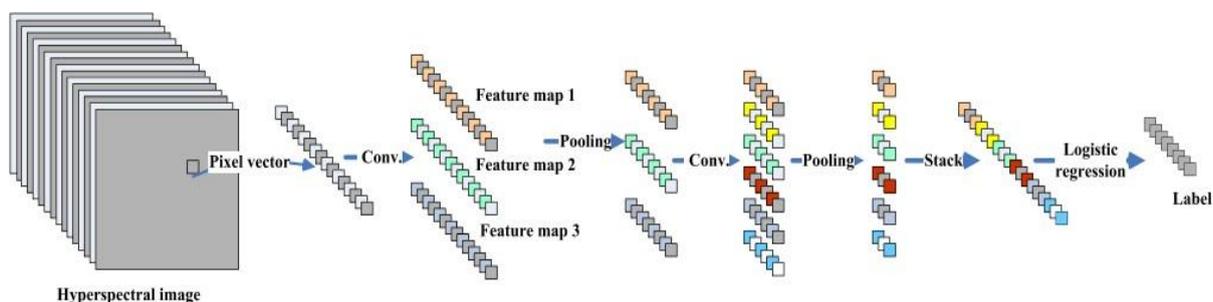


Figure II.2 : L'architecture d'un CNN-1D pour la classification IHS.

Dans l'architecture présentée dans la figure II.2, l'entrée du système est un vecteur de pixels de données hyperspectrales et la sortie du système est l'étiquette du vecteur de pixels. Elle se compose de plusieurs couches de convolution et de pooling, ainsi que d'une couche LR.

Après plusieurs couches de convolution et de pooling, le vecteur de pixels d'entrée peut être converti en un vecteur de caractéristiques, qui capture les informations spectrales du vecteur de pixels d'entrée. Enfin, nous utilisons LR ou d'autres classificateurs pour effectuer l'étape de classification.

II.4.2.2 Le CNN 2D

Le CNN 2D est utilisé pour l'extraction et la classification de caractéristiques spatiales dans les images HSI. Il comprend plusieurs couches de convolution 2D qui appliquent des filtres spatiaux pour extraire des caractéristiques pertinentes à différentes échelles. Les couches de pooling peuvent également être utilisées pour réduire la dimensionnalité des caractéristiques extraites. Ensuite, les couches fully connected (ou entièrement connectées) sont généralement utilisées pour la classification finale.

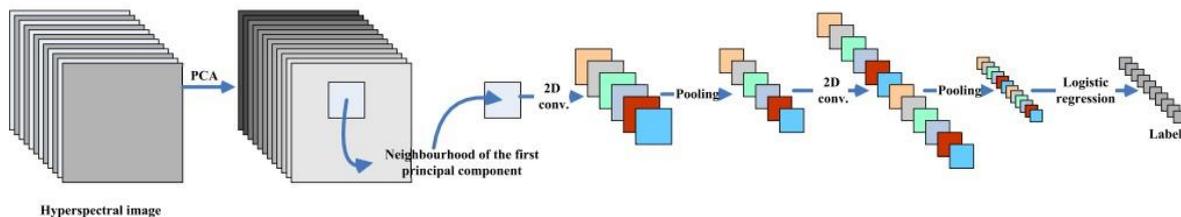


Figure II.3 : L'architecture d'un CNN-2D pour la classification IHS.

La première étape du traitement consiste en une analyse en composantes principales (PCA) combinée à la dimension spectrale, puis le CNN est introduit pour extraire des caractéristiques profondes couche par couche.

En nous basant sur la théorie décrite précédemment, différentes architectures de CNN peuvent être développées. Dans cette section, nous présentons le CNN conçu pour une seule bande (le premier composant principal) de l'HSI. L'architecture est présentée dans la figure II.3.

Nous choisissons des voisinages de taille $K \times K$ autour d'un pixel courant comme entrée pour le modèle CNN 2D. Ensuite, nous construisons un CNN profond pour extraire les caractéristiques utiles. Chaque couche du CNN contient une convolution 2D et un pooling. Lorsque la résolution spatiale de l'image n'est pas très élevée, un noyau de taille 4×4 ou 5×5 peut être sélectionné pour la convolution, et un noyau de taille 2×2 pour le pooling.

Après plusieurs couches de convolution et de pooling, l'image d'entrée peut être représentée par des vecteurs de caractéristiques, qui capturent l'information spatiale contenue dans la région de voisinage $K \times K$ du pixel d'entrée. Ensuite, les caractéristiques apprises sont fournies à l'approche de régression logistique (LR) pour la classification."

II.4.2.3 Le CNN 3D

Le CNN 3D est utilisé pour l'extraction et la classification simultanées de caractéristiques spectrales et spatiales dans les images HSI. Ce modèle exploite à la fois les corrélations spectrales et spatiales en utilisant des opérations de convolution 3D. Les couches de convolution 3D effectuent des opérations de convolution dans les trois dimensions (spectrale, spatiale en x et spatiale en y) pour extraire des caractéristiques profondes qui capturent à la fois les informations spectrales et spatiales des données hyperspectrales.

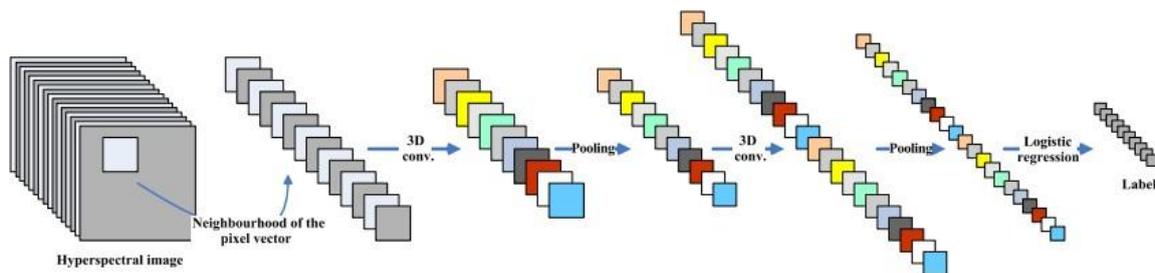


Figure II.4 : L'architecture d'un CNN-3D pour la classification IHS.

La figure II.4 montre l'architecture d'un CNN 3D pour la classification d'images HSI. Nous choisissons des voisinages de taille $K \times K \times B$ autour d'un pixel comme entrée pour le modèle CNN 3D, où B est le nombre de bandes spectrales. Chaque couche du CNN contient une convolution 3D et un pooling. Par exemple, un noyau de taille $4 \times 4 \times 32$ ou $5 \times 5 \times 32$ peut être appliqué à la convolution 3D, et un noyau de taille 2×2 peut être appliqué pour le sous-échantillonnage. Après avoir effectué une profondeur CNN 3D, l'approche de régression logistique (LR) est utilisée pour l'étape de classification.

II.5 Paramètres d'influence sur l'entraînement

L'implémentation des modèles nécessite la spécification de certains paramètres qui influencent leur performance. Voici quelques paramètres couramment utilisés :

- **Batch Size**

Il s'agit du nombre d'échantillons d'entraînement utilisés pour calculer une seule mise à jour des poids du modèle. Le choix du batch size dépend de la taille du jeu de données, des ressources matérielles disponibles et de la capacité de mémoire du système. Des valeurs courantes pour le batch size sont généralement de l'ordre de 16, 32, 64 ou 128.

- **Patch Size**

Il s'agit de la taille du patch ou du noyau utilisé lors des opérations de convolution. Le patch size est spécifié en fonction de la dimension de l'image et de la complexité des caractéristiques à extraire. Des patches plus petits sont généralement utilisés pour détecter des caractéristiques fines, tandis que des patches plus grands sont utilisés pour capturer des motifs plus globaux. Les valeurs de patch size peuvent varier en fonction du modèle et du problème spécifique.

- **Epochs**

Il s'agit du nombre d'itérations complètes sur l'ensemble du jeu de données lors de l'entraînement du modèle. Un plus grand nombre d'époques permet au modèle d'apprendre plus longtemps et potentiellement d'améliorer sa performance. Cependant, il est important de surveiller le surapprentissage, c'est-à-dire lorsque le modèle s'adapte trop précisément aux

Chapitre II Classification par les CNN multidimensionnels

données d'entraînement au détriment de sa capacité à généraliser. Le choix du nombre optimal d'époques dépend de la complexité du problème et peut être déterminé à l'aide de techniques de validation croisée ou de suivi des métriques de performance.

- **Learning Rate**

Il s'agit du taux d'apprentissage utilisé pour mettre à jour les poids du modèle pendant l'entraînement. Le learning rate contrôle la magnitude des mises à jour et affecte la vitesse de convergence et la stabilité de l'apprentissage. Un learning rate trop élevé peut entraîner une divergence ou une instabilité, tandis qu'un learning rate trop faible peut ralentir la convergence. Il est courant d'effectuer une recherche empirique pour trouver le learning rate optimal en utilisant des méthodes adaptatives ou des schémas d'ajustement.

II.6 Métriques d'évaluation des performances

Les résultats obtenus par les modèles d'implémentation peuvent varier en fonction des données, des paramètres et de l'application spécifique. L'évaluation des performances se fait généralement en utilisant des métriques telles que l'accuracy, precision, recall et F1 score. Les résultats peuvent être comparés avec d'autres modèles ou des références existantes pour évaluer leur efficacité dans la tâche de classification d'images. [28][25]

En détaillant chaque paramètre de résultats couramment utilisé pour évaluer les performances d'un modèle CNN-nD :

- **Confusion matrix**

La matrice de confusion est une représentation tabulaire des prédictions du modèle par rapport aux véritables valeurs étiquetées. La matrice de confusion est utile pour évaluer les performances du modèle, notamment pour identifier les erreurs fréquentes et les éventuels biais de classification. [44]

La matrice de confusion peut être exprimée comme suit :

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Figure II.5 : Exemple de matrice de confusion

Chapitre II Classification par les CNN multidimensionnels

La matrice de confusion permet de visualiser le nombre de prédictions correctes (True Positives et True Negative) et incorrectes (False Positives et False Negatives) pour chaque classe.

- **Accuracy**

Il s'agit d'une mesure de la justesse globale du modèle, qui représente le pourcentage de prédictions correctes sur l'ensemble des échantillons de données.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (1)$$

- **Precision**

La précision mesure la capacité du modèle à fournir des résultats précis parmi les prédictions positives. Elle est calculée en divisant le nombre de vrais positifs par la somme des vrais positifs et des faux positifs. La précision est importante lorsque les faux positifs ont un coût élevé ou lorsqu'il est essentiel de minimiser les erreurs de type I.

La précision est calculée en divisant le nombre de vrais positifs (TP) par la somme des vrais positifs et des faux positifs (TP + FP).

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (2)$$

- **Recall**

Egalement appelé sensibilité ou taux de vrais positifs, mesure la capacité du modèle à identifier correctement les cas positifs parmi tous les cas réellement positifs. Il est calculé en divisant le nombre de vrais positifs par la somme des vrais positifs et des faux négatifs. Recall est important lorsque les faux négatifs ont un coût élevé ou lorsqu'il est essentiel de minimiser les erreurs de type II. [45]

Recall est calculé en divisant le nombre de vrais positifs (TP) par la somme des vrais positifs et des faux négatifs (TP + FN).

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (3)$$

- **F1 Score**

Le score F1 est une mesure combinée de la précision et du recall. Un score F1 élevé indique un bon équilibre entre la précision et le recall.

Le score F1 est calculé en prenant la moyenne harmonique de ces deux métriques et fournit une mesure globale de la performance du modèle.

$$\text{F1 Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (4)$$

Chapitre II Classification par les CNN multidimensionnels

- **Kappa**

Le coefficient kappa est une mesure de la concordance entre les prédictions du modèle et les véritables valeurs étiquetées. Il prend en compte l'accord observé et l'accord attendu par hasard. Un coefficient kappa proche de 1 indique un accord élevé entre les prédictions et les véritables valeurs, tandis qu'une valeur proche de 0 indique un accord au hasard.

$$\mathbf{Kappa = (Accuracy - Agreement\ by\ Chance) / (1 - Agreement\ by\ Chance)} \quad (5)$$

L'accord par hasard est calculé en multipliant les taux d'accord marginaux pour chaque classe.

$$\mathbf{Agreement\ by\ Chance = (Sum\ of\ (Observed\ Row\ Total * Observed\ Column\ Total)) / Total} \quad (6)$$

Il convient de souligner que ces équations représentent des formulations générales qui peuvent être ajustées en fonction des particularités de chaque tâche de classification et des exigences spécifiques de l'application.

De plus, les paramètres de performance mentionnés peuvent varier en fonction de la nature de la tâche de classification, du déséquilibre des classes, des paramètres d'entraînement et des données utilisées. L'évaluation des performances d'un modèle de CNN multidimensionnel doit être réalisée de manière globale, en prenant en compte tous ces aspects afin d'obtenir une vision complète de la qualité du modèle.

II.7 Conclusion

Dans ce chapitre, nous avons exploré l'utilisation des réseaux de neurones convolutifs (CNN) pour la classification de données. Nous avons constaté que le deep learning et l'intelligence artificielle ont révolutionné le traitement des données en permettant l'extraction d'informations complexes et la prise de décisions autonomes à partir de vastes ensembles de données.

Ensuite, nous avons introduit les CNN multidimensionnels, qui sont des extensions des CNN traditionnels spécialement conçues pour traiter des données présentant des dimensions supplémentaires, telles que les images hyperspectrales.

Nous avons également examiné différents modèles d'implémentation des CNN multidimensionnels, tels que le CNN 1D, le CNN 2D et le CNN 3D, qui sont adaptés à différentes dimensions de données. Chacun de ces modèles exploite les relations et les structures inhérentes aux données pour extraire des caractéristiques pertinentes et réaliser des tâches de classification précises.

En conclusion, les CNN multidimensionnels sont des outils puissants pour la classification d'images complexes, en particulier les images hyperspectrales. Ils permettent d'exploiter à la fois les informations spectrales et spatiales pour capturer les caractéristiques discriminantes des données.

Chapitre III

Expérimentations et résultats

III.1 Introduction

Ce chapitre présente les expérimentations réalisées ainsi que les résultats obtenus dans le cadre de ce travail. L'objectif principal est d'exploiter le pouvoir de l'apprentissage profond pour l'adaptation et l'implémentation de modèles de classification basés sur les réseaux de neurones convolutifs (CNN) multidimensionnels dans le domaine de l'imagerie hyperspectrale.

Ce chapitre se concentre sur la conception et l'implémentation de modèles de classification basés sur les CNN multidimensionnels, exploitant l'apprentissage profond pour surmonter les défis inhérents aux images hyperspectrales, tels que leur complexité et leur haute dimensionnalité. L'objectif est d'analyser les performances de ces modèles dans ce domaine.

III.2 Rappels des objectifs à atteindre par le travail

Le présent travail vise à exploiter le pouvoir de l'apprentissage profond pour l'adaptation et l'implémentation de modèles de classification basés sur les réseaux de neurones convolutifs (CNN) multidimensionnels dans le domaine de l'imagerie hyperspectrale.

La classification des images hyperspectrales se concentre sur l'extraction des informations pertinentes à l'échelle pixelique, afin de produire des cartes thématiques où chaque pixel est étiqueté en fonction de la nature de l'objet qu'il représente.

Ainsi, notre travail se focalise sur l'implémentation de modèles de classification basés sur les CNN multidimensionnels, qui tirent parti de l'apprentissage profond pour surmonter les défis inhérents aux images hyperspectrales, tels que leur complexité et leur haute dimensionnalité en analysant les performances de ces modèles.

III.3 Difficultés et solutions envisagées

Parmi les difficultés envisagées pendant l'implémentation de ce travail, nous présentons les problèmes suivants :

- Difficultés avec le fonctionnement des bibliothèques nécessaires à l'exploitation de certaines commandes, surpassées avec l'installation de mises à jour et mises à niveau adaptées aux installations effectuées.
- Problèmes de compatibilité et de conflits avec les logiciels installés sur nos systèmes informatiques. Chose qui a été résolue par l'adoption de l'environnement Anaconda qui permet de créer des environnements virtuels indépendants.
- Grand volume des données nécessitant un temps de téléchargement et de transfert assez important, ce qui nous a mené à travailler de manière locale. Cette solution dépasse le problème de temps mais consomme en revanche en espace de stockage.
- Insuffisance de mémoire vive lors de l'exécution du code relatif à l'implémentation du modèle CNN-3D, ce qui a limité les expériences menées à l'ensemble permis par l'ajustement des paramètres intervenant sur la phase d'entraînement.

Chapitre III Expérimentations et résultats

- Cette même solution a été adoptée pour pallier les temps d'exécutions extrêmement longs et accablants. Chose que nous avons principalement notés pour les modèles 2 et 3D.

III.4 Ressources exploitées

Pour l'implémentation de notre travail, nous présenterons les ressources utilisées y compris le matériel utilisé, les logiciels, la méthodologie et les données avec lesquelles nous avons travaillé.

III.4.1 Le matériel informatique

Nous avons exploité quatre machines dotées de caractéristiques différentes mais en veillant à faire exécuter les tâches semblables sur les machines de caractéristiques comparables afin de ne pas compromettre nos estimations du temps.

III.4.2 Les outils logiciels

Pour réaliser notre partie expérimentale, nous avons utilisé plusieurs logiciels qui nous ont permis de mener à bien nos travaux.

a) Les environnements

Les logiciels clés que nous avons utilisés sont les suivants :

- Python : est un langage de programmation populaire et polyvalent utilisé dans de nombreuses applications telles que le développement web, l'analyse de données, l'apprentissage automatique et la science des données. Python offre une syntaxe simple et facile à apprendre, ainsi que des bibliothèques de modules pour des tâches spécifiques, ce qui en fait un choix privilégié pour les scientifiques des données et les développeurs. Les outils Python les plus couramment utilisés dans le domaine de l'apprentissage automatique comprennent TensorFlow, PyTorch, Keras, Scikit-Learn, Pandas et NumPy.
- VS Code est un éditeur de code source développé par Microsoft qui prend en charge plusieurs langages de programmation, notamment Python. Il fournit des fonctionnalités telles que la coloration syntaxique, la suggestion de code et la détection d'erreurs en temps réel, ce qui facilite le développement d'applications. VS Code est également extensible via des extensions tierces, qui peuvent ajouter des fonctionnalités supplémentaires pour les besoins spécifiques des développeurs.
- Anaconda : est une plateforme de gestion de paquets et d'environnements pour les langages de programmation Python et R. Il comprend un gestionnaire de paquets pour installer et gérer les packages Python/R, ainsi qu'un gestionnaire d'environnement qui permet de créer des environnements Python/R isolés avec des versions spécifiques de packages pour des projets spécifiques. Anaconda est souvent utilisé dans l'analyse de

Chapitre III Expérimentations et résultats

données et l'apprentissage automatique en raison de sa facilité d'utilisation et de sa compatibilité avec de nombreux packages et outils populaires.

b) Les modules et bibliothèques

Le code développé au cours de notre projet permet d'effectuer la classification des images hyperspectrales en lançant les différents modèles CNN1D, 2D et 3D, de manière interactive et via une saisie de lignes de commande. Ce choix nous est venu après consultation des différentes approches suivies par les développeurs de la communauté travaillant sur le DL et l'IHS.

Pour mener à bien ses tâches, le code utilise des modules et des bibliothèques que nous listons ci-dessous :

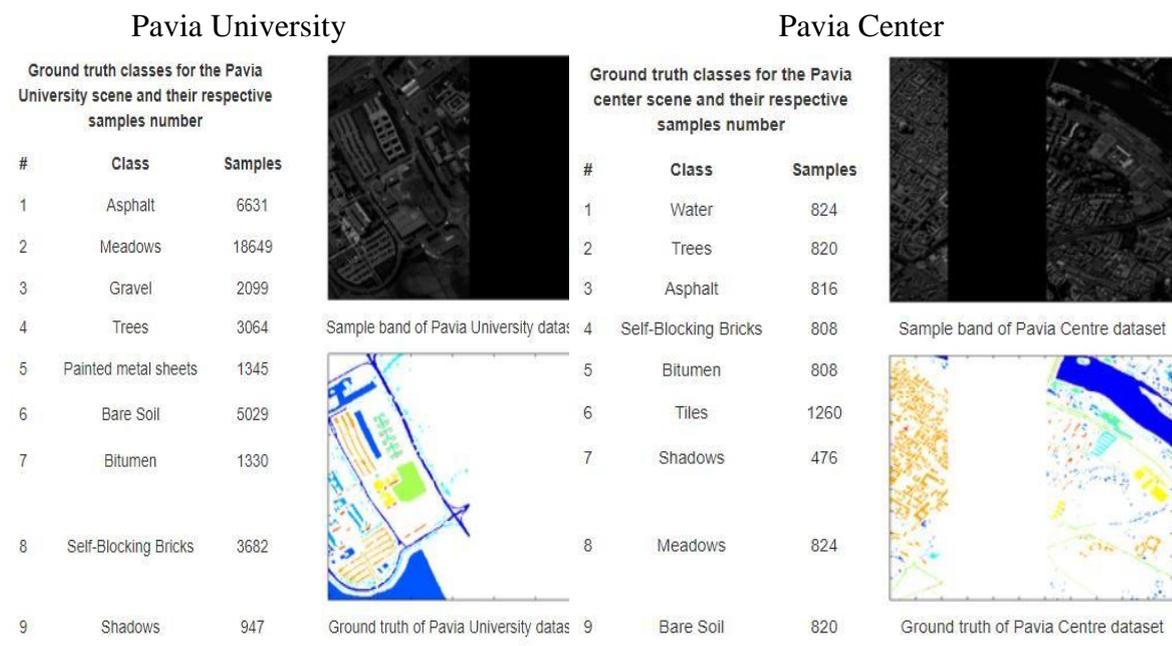
- Le module "argparse" qui permet la spécification des paramètres en ligne de commande où l'on s'intéresse aux choix du jeu de données, au choix du modèle, à la proportion avec laquelle le jeu de données est divisé en ensembles d'entraînement et de test, etc.
- La bibliothèque "PyTorch" pour la mise en place des modèles CNN-nD.
- Les bibliothèques "numpy", "scipy", "scikit-image" et "spectral" pour l'exécution des tâches de traitement, d'enregistrement de nos données.
- Les bibliothèques "seaborn" et "visdom" exploitées principalement pour la visualisation des résultats générés.
- La bibliothèque "sklearn" pour la sélection des hyperparamètres et la répartition des données d'entrée en ensembles d'entraînement et de test.

III.4.3 Les jeux de données hyperspectrales

Malgré le fait que les images hyperspectrales renseignées par une vérité de terrain (connaissance à priori des classes décrivant les entités retrouvées au travers de la scène imagée), soit d'une rareté notable, nous avons pu avoir accès à un certain nombre de jeux de données, avec accès gratuit, grâce à [50]. Ces données représentant des zones géographiques distinctes et avec des caractéristiques variables. Cependant, notre choix s'est porté sur l'utilisation des jeux de données connus par la communauté de l'IHS par les appellations "Pavia University" et "Pavia Center".

Ces jeux de données représentent deux scènes correspondant à la ville de Pavie (en Italie). La proximité géographique des zones couvertes par ces jeux de données permet d'avoir une similarité dans les classes des entités représentées. Par contre, leurs dimensions spatiales sont différentes et par conséquent le nombre des échantillons disponibles sont différents, ce qui nous permet d'évaluer l'influence de cette différence sur la qualité de l'apprentissage atteint pour chaque modèle que l'on se propose d'étudier.

Chapitre III Expérimentations et résultats



Capteur :

ROSIS

Dimensions 610*610 – 103

1096*1096 – 102

(lignes x colonnes

-- bandes) :

Figure III-1 : Caractéristiques des principaux jeux de données utilisés pour la classification des IHS

Pour notre travail, nous avons spécifiquement choisi deux jeux de données, à savoir Pavia University et Pavia Center, afin d'évaluer l'impact de l'extension d'une zone (Pavia University) sur nos résultats. En sélectionnant ces deux ensembles de données, nous allons pouvoir étudier et comparer les performances de notre modèle de classification d'images hyperspectrales en fonction de la zone géographique couverte. Cette approche va nous permettre de comprendre l'influence de l'étendue spatiale des données sur les résultats obtenus et d'analyser les différences dans la reconnaissance des objets entre les deux jeux de données.

Les critères de choix de ces jeux de données sont leurs dimensions et leur représentativité de différents types de couverture de sol. Ces jeux de données ont été largement utilisés par la communauté de traitement d'images hyperspectrales pour évaluer l'efficacité des algorithmes de classification.

III.4.4 Les modèles d'implémentation

Dans notre travail, nous présenterons une sélection de modèles de réseaux de neurones convolutifs (CNN) multidimensionnels proposés par des chercheurs dans le domaine. Ces modèles ont été spécifiquement conçus pour traiter les images hyperspectrales et ont démontré leur efficacité dans des tâches de classification. Nous examinerons en détail chaque

Chapitre III Expérimentations et résultats

modèle, en mettant en évidence leurs caractéristiques distinctives, leur architecture, leurs paramètres et leur méthodologie d'apprentissage. En présentant ces différents modèles, nous cherchons à fournir une vue d'ensemble complète des approches les plus prometteuses dans le domaine de la classification d'images hyperspectrales à l'aide de CNN multidimensionnels. Cela nous permettra de mieux comprendre les avancées récentes et d'évaluer leur pertinence pour notre propre approche expérimentale.

III.4.4.1 Modèle « hu » [47]

Le CNN varie en fonction de la réalisation des couches de convolution et de mise en commun maximale, ainsi que de la manière dont les réseaux sont entraînés. Le réseau contient cinq couches avec des poids, comprenant la couche d'entrée, la couche de convolution C1, la couche de mise en commun maximale M2, la couche de connexion complète F3 et la couche de sortie.

Dans le cas des images hyperspectrales (HSI), chaque échantillon de pixel HSI peut être considéré comme une image 2D dont la hauteur est égale à 1. Par conséquent, la taille de la couche d'entrée est simplement $(n_1, 1)$, où n_1 est le nombre de bandes. La première couche de convolution cachée C1 filtre les données d'entrée $n_1 \times 1$ avec 20 noyaux de taille $k_1 \times 1$. La couche C1 contient $20 \times n_2 \times 1$ nœuds, où $n_2 = n_1 - k_1 + 1$. Il y a $20 \times (k_1 + 1)$ paramètres entraînaibles entre la couche C1 et la couche d'entrée. La couche de mise en commun maximale M2 est la deuxième couche cachée, et la taille du noyau est $(k_2, 1)$. La couche M2 contient $20 \times n_3 \times 1$ nœuds, où $n_3 = n_2 / k_2$. Il n'y a aucun paramètre dans cette couche. La couche de connexion complète F3 a n_4 nœuds, et il y a $(20 \times n_3 + 1) \times n_4$ paramètres entraînaibles entre cette couche et la couche M2. La couche de sortie a n_5 nœuds, et il y a $(n_4 + 1) \times n_5$ paramètres entraînaibles entre cette couche et la couche F3. Par conséquent, l'architecture de notre classificateur CNN propose un total de $20 \times (k_1 + 1) + (20 \times n_3 + 1) \times n_4 + (n_4 + 1) \times n_5$ paramètres entraînaibles.

La classification d'un pixel HSI spécifique nécessite le CNN correspondant avec les paramètres mentionnés ci-dessus, où n_1 et n_5 sont respectivement la taille du canal spectral et le nombre de classes de sortie de l'ensemble de données. Ces choix peuvent ne pas être les meilleurs, mais ils sont efficaces pour les données hyperspectrales générales.

Dans l'architecture proposée (figure III-2), les couches C1 et M2 peuvent être considérées comme un extracteur de caractéristiques entraînable pour les données HSI d'entrée, et la couche F3 est un classificateur entraînable pour l'extracteur de caractéristiques. La sortie de la mise en commun est la véritable caractéristique des données originales. Dans la structure CNN proposée, 20 caractéristiques peuvent être extraites de chaque hyperspectrale originale, et chaque caractéristique a n_3 dimensions.

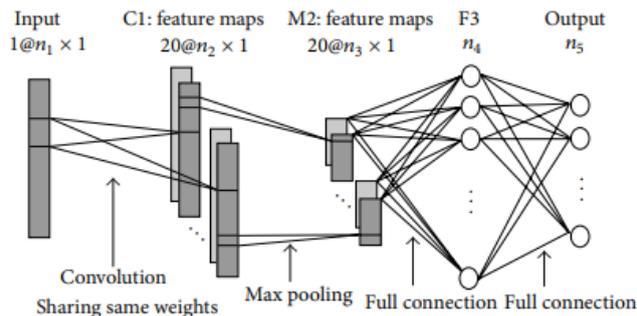


Figure III-2 : L'architecture proposé pour CNN1D

III.4.4.2 Modèle « sharma » [48]

À partir de la littérature, nous avons exploité de nombreuses connaissances sur les bonnes architectures. Pour les petits ensembles de données, il est fortement recommandé de former de petits réseaux. Il s'avère que les réseaux profonds ont de nombreux paramètres à apprendre et un nombre insuffisant d'échantillons d'entraînement conduit à un surajustement.

D'après la figure (III-2), le réseau à 5 couches décrit précédemment est celui qui donne les meilleurs résultats par rapport aux autres réseaux. Notez que le réseau à 3 couches donne les moins bons résultats, et le réseau à 6 couches montre des performances similaires à notre réseau à 5 couches. Dans le réseau à 3 couches, nous avons 2 couches de convolution et 1 couche entièrement connectée, tandis que le réseau à 6 couches est composé de 3 couches de convolution et 3 couches entièrement connectées. L'utilisation du réseau à 5 couches est plus efficace en termes de temps de calcul par rapport au réseau à 6 couches. Nous utilisons donc le réseau à 5 couches comme réseau « sharma ». Le nombre de paramètres pour le réseau à 5 couches est de 20 millions.

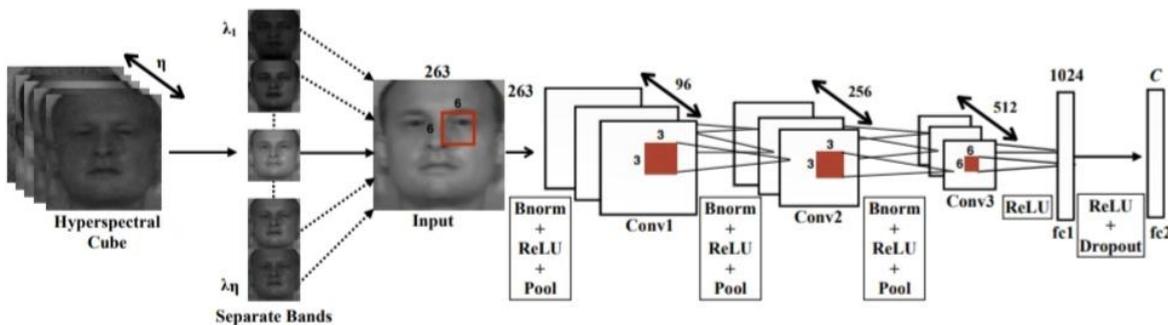


Figure III-3 : L'architecture de "sharma" CNN2D

III.4.4.3 Modèle « chen » [49]

Les images hyperspectrales de télédétection contiennent à la fois des informations spatiales et spectrales. Dans cette section, nous intégrons les caractéristiques spectrales et spatiales pour construire un cadre de classification conjoint spectral-spatial en utilisant un CNN 3D.

Le problème de la haute dimensionalité et du nombre limité d'échantillons d'entraînement rend le surajustement un problème sérieux, en particulier lorsque l'entrée est un cube 3D. Pour gérer le problème du CNN 3D, une stratégie de régularisation combinée basée sur une contrainte de parcimonie est développée, comprenant ReLU (Rectified Linear Unit) et le dropout, appliqué dans la couche entièrement connectée. ReLU est une fonction d'activation non linéaire qui conserve les valeurs positives et fixe les valeurs négatives à zéro. Le dropout est une méthode récemment introduite pour gérer le surajustement. Il met à zéro la sortie de certains neurones cachés lors de la propagation avant, ce qui signifie que ces neurones ne contribuent pas et ne sont pas utilisés dans la rétropropagation. En utilisant ReLU et le dropout, les sorties de nombreux neurones sont nulles, ce qui permet d'obtenir une régularisation parcimonieuse puissante pour le réseau profond et de résoudre le problème de surajustement dans la classification des images hyperspectrales.

Dans le cadre de l'apprentissage supervisé, le nombre d'échantillons d'entraînement disponibles est souvent limité, ce qui pose un défi. Pour résoudre ce dilemme, nous utilisons des échantillons virtuels comme outil prometteur. Les échantillons virtuels sont créés à partir d'échantillons d'entraînement existants en multipliant un facteur aléatoire et en ajoutant du bruit aléatoire. De plus, des échantillons virtuels peuvent être générés à partir de deux échantillons donnés de la même classe avec des ratios appropriés. L'utilisation d'échantillons virtuels est utile pour l'entraînement d'un CNN.

Plutôt que d'utiliser des techniques de régularisation telles que la régularisation L2 et le dropout pour pallier le manque d'échantillons d'entraînement, des échantillons virtuels sont générés et ajoutés aux échantillons d'entraînement afin d'obtenir des performances améliorées.

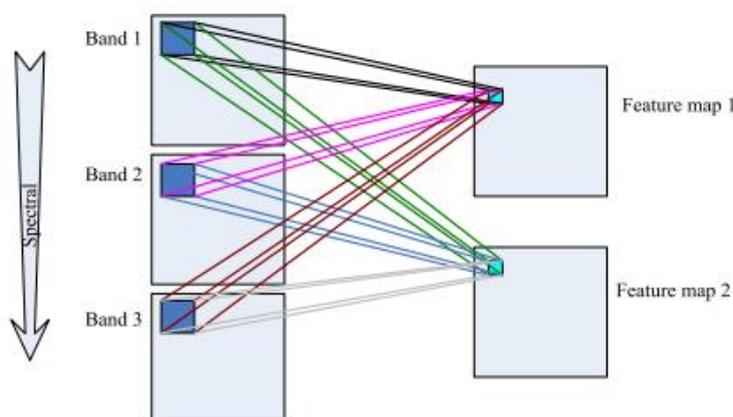


Figure III-4 : L'architecture de « chen » CNN3D

III.5 Protocole expérimental

Nous avons conçu notre système autour d'un code informatique principal, noté Main, qui fait appel à trois routines que nous avons dédié à des tâches bien spécifiques. Ces routines sont notées par : Datasets (pour le chargement et le prétraitement des données), Models (pour la sélection du modèle à implémenter, la définition de son architecture et l'ajustement de ses paramètres d'entraînement) et Utilities (pour l'évaluation des performances du modèles lors de la phase de test) et interagissent entre-elles tel que le montre le schéma suivant :

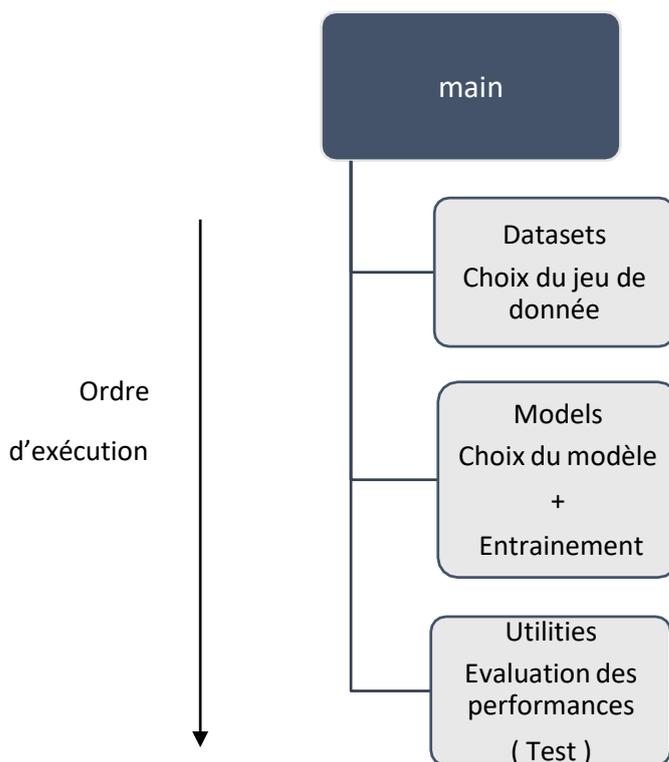


Figure III.5 : Organigramme décrivant la structure du code développé.

III.6 Présentation des résultats et discussion

III.6.1 Phase d'apprentissage

a) Paramètres d'influence

Dans la phase d'apprentissage de notre travail, nous avons mis en œuvre différents paramètres d'influence pour optimiser les performances de nos modèles de classification. Ces paramètres ont été soigneusement sélectionnés pour tenir compte des spécificités des images hyperspectrales et de notre objectif de reconnaissance précise des objets. Parmi les paramètres d'influence que nous avons utilisés sont :

Chapitre III Expérimentations et résultats

- Patch-size : suivant les recommandations des auteurs pour garantir une taille de patch adaptée à nos données hyperspectrales.
- Batch-size : nous avons réduit autant que possible le batch-size, après avoir remarqué que des tests préliminaires montraient une meilleure « Accuracy » lorsque le batch-size était réduit.
- Learning rate : a été choisi de manière empirique, en ajustant progressivement sa valeur pour atteindre une convergence optimale.
- Number of epochs : a été déterminé en tenant compte de contraintes temporelles, en cherchant un équilibre entre le temps d'exécution et la performance du modèle.

Le tableau ci-dessous (III-1) indique les valeurs que nous avons choisies pour les principaux paramètres pour les deux jeux de données :

Tableau III-1 : Les choix considérés pour les paramètres d'entraînement.

<i>Modèles</i>	<i>Batch-size</i>	<i>Learning rate</i>	<i>Number of epochs</i>	<i>Patch-size</i>
<i>Hu « CNN1D »</i>	60	0,01	100	1
<i>Sharma « CNN2D »</i>	60	0,05	30	64
<i>Chen « CNN3D »</i>	60	0,003	25	27

b) Temps d'exécution

Le tableau ci-dessous (III-2) présente une estimation du temps passé par chaque modèle pour terminer l'entraînement (atteindre le learning rate et le nombre d'epochs).

Tableau III-2 : Temps d'entraînement pris par chaque modèle CNN pour différents jeux de données.

<i>Jeux de donnée</i>	<i>Modèles</i>	<i>Temps par époque</i>	<i>Temps total de l'entraînement</i>
<i>Pavia University</i>	<i>Hu « CNN1D »</i>	5 minutes	Environ 8 heures et 30 minutes
	<i>Sharma « CNN2D »</i>	2 heures	Environ 62 heures (2 jours et 12 heures)
	<i>Chen « CNN3D »</i>	5 heures	Environ 130 heures (6 jours)
<i>Pavia Center</i>	<i>Hu « CNN1D »</i>	10 minutes	Environ 17 heures
	<i>Sharma « CNN2D »</i>	4 heures	Environ 124 heures (5 jours)
	<i>Chen « CNN3D »</i>	18 heures	Environ 500 heures (20 jours)

c) Evaluation de l'apprentissage

L'évaluation de la phase d'apprentissage est affichée sous forme de graphiques de « validation accuracy » et de « training loss » pour chaque modèle sur les deux jeux de donnée. Voici les résultats obtenus :

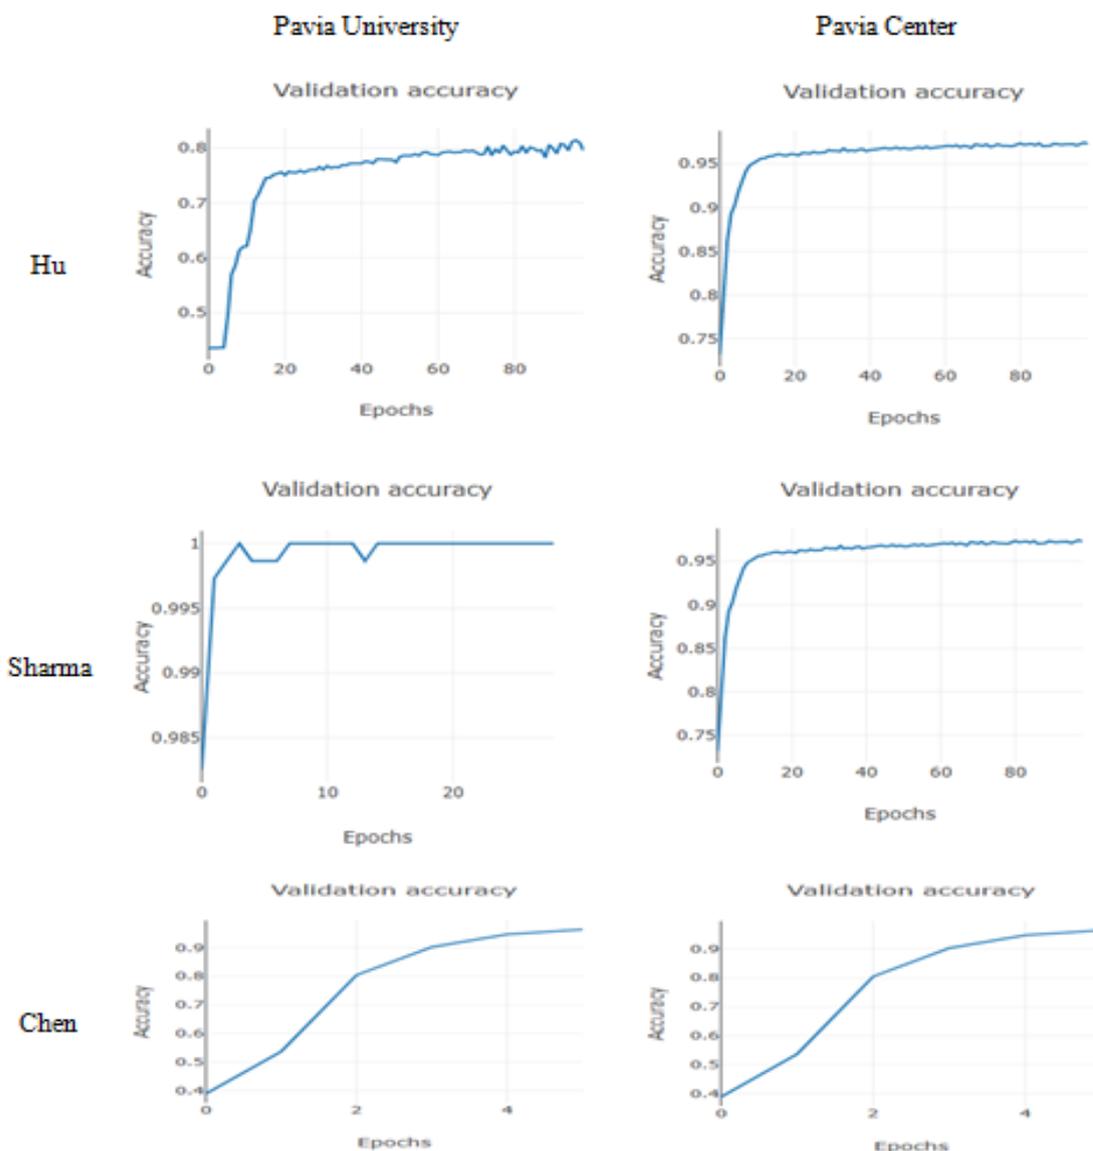


Figure III-6.a : Evaluation de la phase d'apprentissage des différents modèles « Validation accuracy »

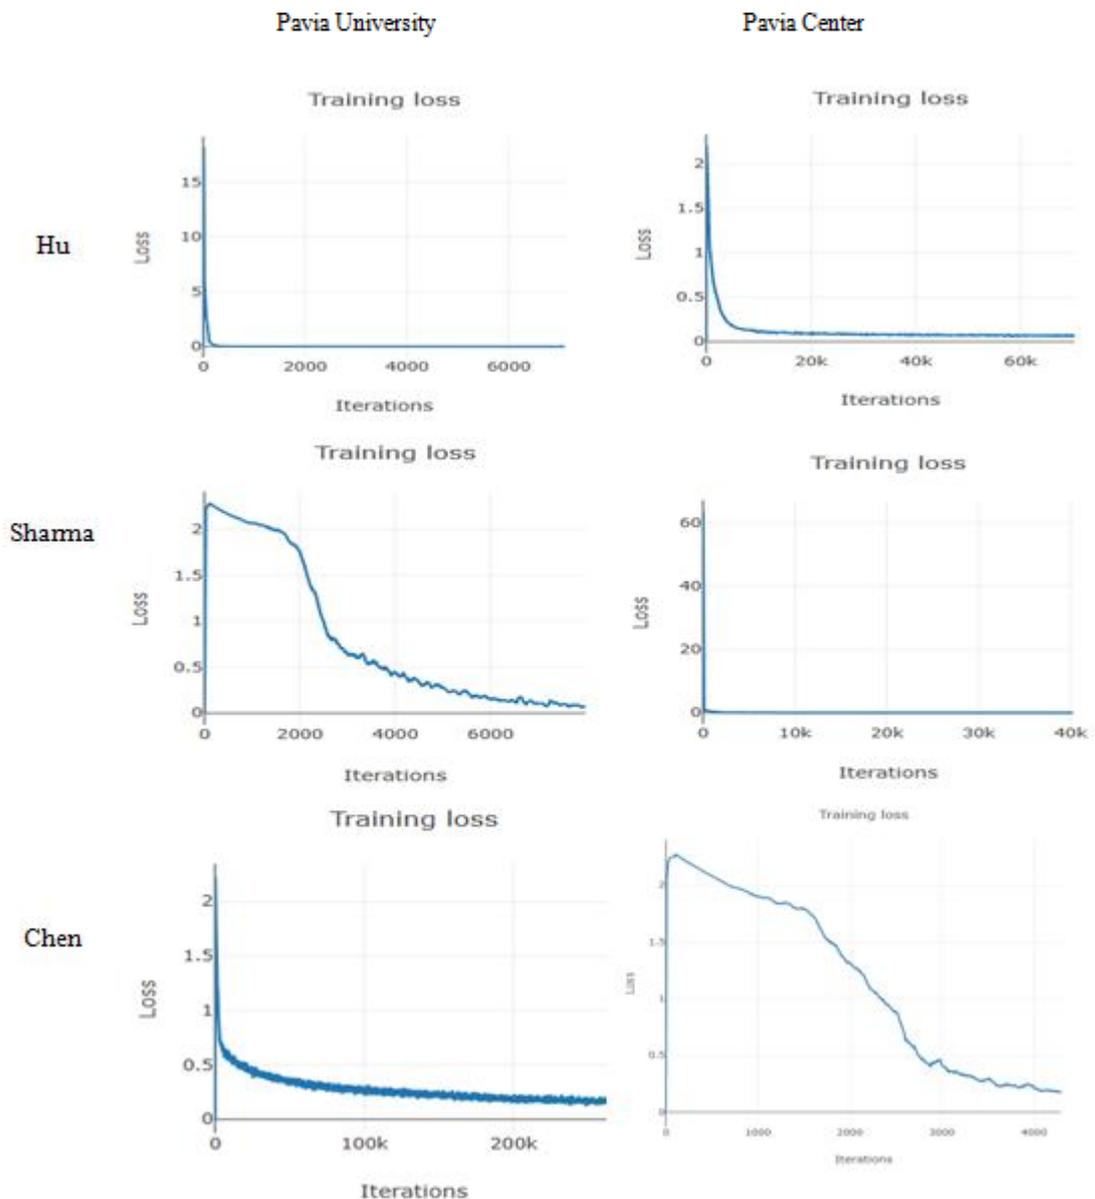


Figure III-6.b : Evaluation de la phase d'apprentissage des différents modèles « Training loss »

En observant le tableau des graphes par les précédentes figures de "validation accuracy" et de "training loss", nous constatons une similarité entre les deux jeux de données. Pour le graphe de "validation accuracy", nous remarquons que la valeur atteint 1 pour la majorité des graphes, ce qui indique la fin de la phase d'apprentissage et suggère que les modèles sont prêts pour la phase de test. Cette performance élevée de validation accuracy est un indicateur de la capacité des modèles à bien généraliser et à reconnaître les classes d'objets dans les données hyperspectrales.

Chapitre III Expérimentations et résultats

En ce qui concerne les graphes de "training loss", nous observons une convergence rapide vers zéro au fur et à mesure de l'évolution des epochs. Cela indique que les modèles ont réussi à réduire l'erreur pendant la phase d'apprentissage et ont appris à bien ajuster les poids et les paramètres du réseau neuronal. Une diminution rapide du training loss suggère une bonne capacité d'apprentissage des modèles et une adaptation efficace aux données hyperspectrales.

III.6.2 Phase de test

Pour la phase de test, nous allons présenter une évaluation qualitative et quantitative des résultats obtenus. Cela nous permettra d'analyser la performance des modèles de classification d'images hyperspectrales.

a. Evaluation qualitative

L'évaluation qualitative consistera à examiner par inspection visuelle les cartes thématiques générées (les résultats de la classification) en vue de détecter la similarité avec les cartes de référence représentant les vérités du terrain. Cette idée nous permet d'avoir une idée à priori sur la qualité de la classification déroulée.

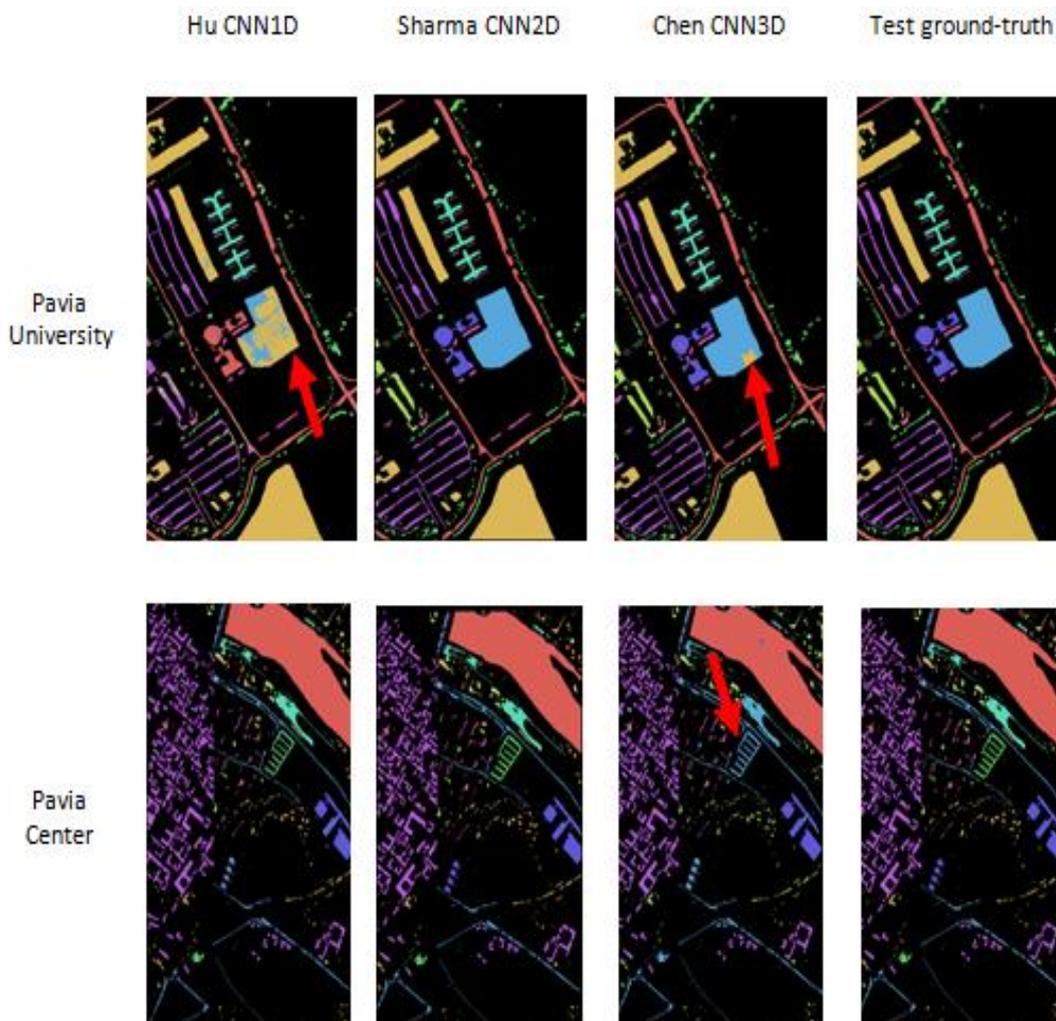


Figure III-7 : Présentation des prédictions et des vérités du terrain

Chapitre III Expérimentations et résultats

La comparaison des différentes images illustrées, nous retenons qu'il y a de fortes ressemblance entre les résultats générés et les références hormis les quelques différences détectables sur certaines régions que nous avons signalées avec des flèches.

Ces erreurs d'attribution des échantillons aux classes peuvent être attribuées à plusieurs facteurs tel que la complexité de la constitution de la scène, la similarité intra-classe, la représentativité insuffisante de certaines classes lors de la phase d'entraînement ou encore la réduction des temps d'exécution du processus d'entraînement limitant l'apprentissage du modèle.

b. Evaluation quantitative

L'évaluation quantitative se basera sur des mesures de performance standard utilisée dans le domaine de la classification d'images. Nous calculerons des métriques telles que l'Accuracy, Recall, les F1 scores et Confusion matrix pour évaluer la précision de la classification et la capacité des modèles à distinguer les différentes classes d'objets.

- **Confusion matrix**

Nous présenterons les matrices de confusion résultantes pour chaque modèle avec les deux jeux de données considérés, dans la figure suivante :

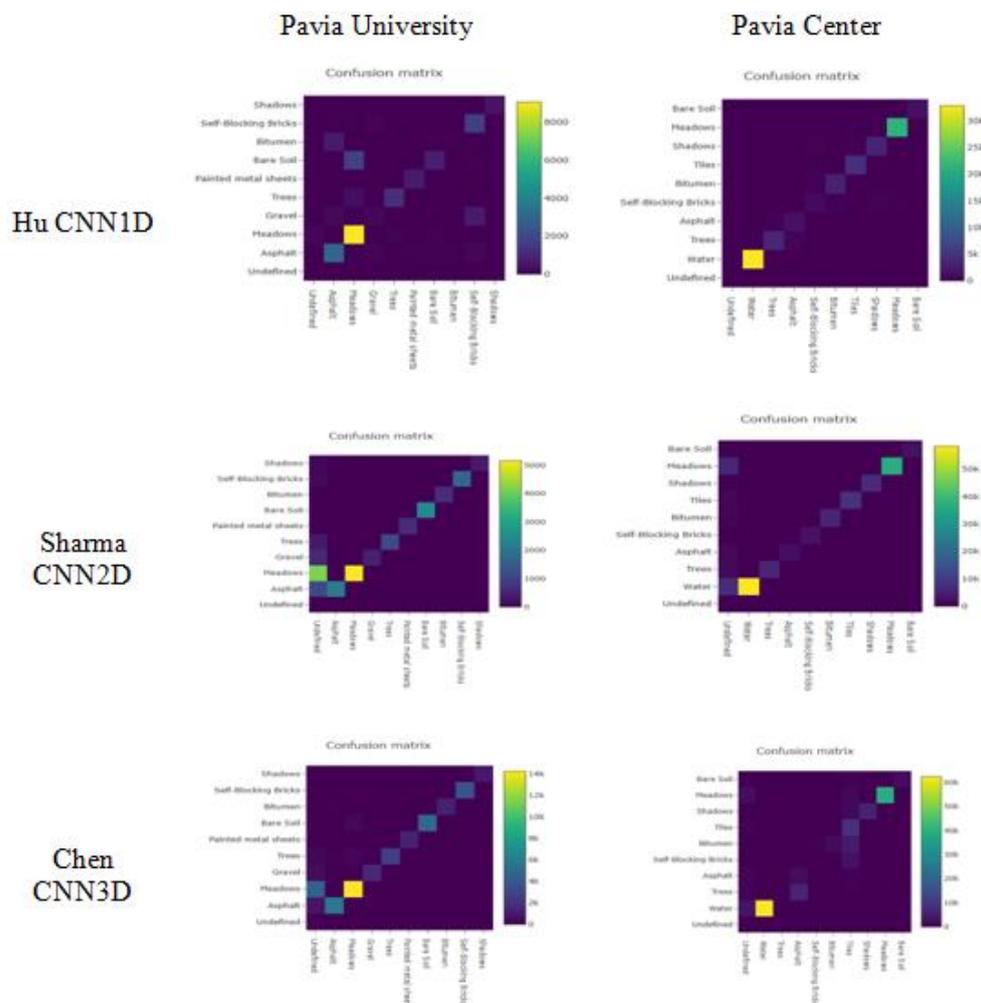


Figure III-8 : Matrices de confusion formées pour chaque modèle et jeu de données.

Chapitre III Expérimentations et résultats

Les matrices de confusion nous permettent d'évaluer la performance de chaque modèle en comparant les prédictions des classes faites par le modèle avec les classes réelles indiquées par les données de référence.

Après avoir analysé la forme de ces matrices de confusion (Figure III.8) et sachant que dans le cas idéal, la matrice de confusion présente une structure diagonale, nous constatons que les modèles implémentés ont réussi à classer correctement la majorité des échantillons pour chaque classe d'objet.

Plus la structure se rapproche de la forme diagonale, plus il y aura une correspondance étroite entre les prédictions du modèle et les classes réelles.

Il est important de signaler que la présence d'un déséquilibre dans la distribution des échantillons entre les classes (certaines sont plus représentées que d'autres) fait que les valeurs se trouvant sur la diagonale n'apparaissent pas avec la même intensité. Toute erreur d'attribution fait apparaître des valeurs de part et d'autre de la diagonale. Plus l'intensité des pixels autour de la diagonale est faible, meilleure la qualité de classification sera.

- **Mesure statistiques**

Nous avons utilisé plusieurs mesures statistiques pour évaluer les performances de nos modèles de classification d'images hyperspectrales. Les mesures utilisées incluent le kappa, Accuracy, les F1 scores.

Ces tableaux ci-dessous présentent les résultats obtenus pour chaque modèle sur les deux jeux de données, en termes de ces mesures statistiques :

Tableau III-3 : Evaluation des modèles par l'accuracy et le kappa pour chaque jeu de données.

	Pavia University		Pavia Center	
	Accuracy	Kappa	Accuracy	Kappa
Hu CNN1D	92.725 %	0.904	97.355 %	0.963
Sharma CNN2D	70.002 %	0.647	87.658 %	0.834
Chen CNN3D	84.882 %	0.811	82.770%	0.761

Chapitre III Expérimentations et résultats

Tableau III-4 : Les F1 scores mesurés par classe, pour chaque modèle.

	Classes	Pavia University	Classes	Pavia Center
Hu CNN1D	Asphalt	0.949	Water	0.999
	Meadows	0.950	Trees	0.933
	Gravel	0.847	Asphalt	0.825
	Trees	0.906	Self-Blocking Bricks	0.687
	Painted metal sheets	0.997	Bitumen	0.925
	Bare Soil	0.875	Tiles	0.949
	Bitumen	0.889	Shadows	0.909
	Self-Blocking Bricks	0.887	Meadows	0.995
	Shadows	0.999	Bare Soil	0.999
Sharma CNN2D	Asphalt	0.801	Water	0.939
	Meadows	0.720	Trees	0.900
	Gravel	0.613	Asphalt	0.773
	Trees	0.882	Self-Blocking Bricks	1.000
	Painted metal sheets	1.000	Bitumen	0.941
	Bare Soil	1.000	Tiles	0.950
	Bitumen	1.000	Shadows	0.985
	Self-Blocking Bricks	0.967	Meadows	0.921
	Shadows	0.904	Bare Soil	0.974
Chen CNN3D	Asphalt	0.927	Water	0.971
	Meadows	0.855	Trees	0.036
	Gravel	0.870	Asphalt	0.348
	Trees	0.924	Self-Blocking Bricks	0.000
	Painted metal sheets	1.000	Bitumen	0.402
	Bare Soil	0.972	Tiles	0.612
	Bitumen	0.979	Shadows	0.885
	Self-Blocking Bricks	0.995	Meadows	0.956
	Shadows	0.989	Bare Soil	0.824

D'après le tableau III-3, les métriques d'accuracy et de coefficient de Kappa indiquent la performance globale des modèles sur les deux jeux de données. Une accuracy élevée et un coefficient de Kappa proche de 1 indiquent une bonne capacité des modèles à reconnaître les classes d'objets. Les valeurs d'accuracy et de Kappa varient selon les modèles et les jeux de données.

Les métriques d'accuracy et de coefficient de Kappa permettent de comparer les performances des différents modèles. Cela indique que le modèle Hu CNN1D a montré de meilleures performances. Ceci est en grande partie dû à sa meilleure qualité d'apprentissage atteinte vu la plus faible complexité d'implémentation et d'exécution. Si les ressources matérielles mises à notre disposition nous permettaient d'aller au-delà du nombre d'époque atteint, nous supposons pouvoir aboutir à de meilleurs résultats avec les CNN2D et 3D et ce vu l'intégration des contextes spatial et spectral autour des pixels.

D'après le tableau III-4, les F1 scores pour chaque classe permettent d'évaluer la capacité des modèles à reconnaître spécifiquement chaque classe d'objets. Un F1 score proche de 1 indique

Chapitre III Expérimentations et résultats

une reconnaissance précise de la classe, tandis qu'un F1 score faible peut indiquer des difficultés à distinguer cette classe des autres. Par exemple, les modèles montrent de bonnes performances pour la classe "Water" avec des F1 scores élevés, tandis que la classe "Trees" présente des F1 scores variables selon les modèles. Cette différence peut être justifiée par la considération probable de taux de représentativité différent pour ces deux classes lors du processus d'entraînement. Ce qui pourrait être corrigé en suggérant un choix plus étudié que la considération aléatoire que nous avons adopté lors de nos expérimentations.

III.7 Les aboutissements du travail

Des expériences que nous avons eu l'occasion de mener dans le cadre de ce projet de fin d'études, nous pouvons retenir les aboutissements suivants :

L'exploitation des outils de l'apprentissage profond et plus particulièrement les CNN-nD, pour la classification est une solution prometteuse. Cependant, elle peut d'avérer coûteuse en termes de consommation des ressources matérielles (espace de stockage, mémoire vive, etc.) et en termes de temps d'exécution surtout en présence de données multidimensionnelles à grand volume, tel le cas des images hyperspectrales, qui de par leurs caractéristiques intrinsèques font très rapidement grimper cette complexité à des échelles supérieures.

En effet, notre travail vient mettre l'accent sur les défis pratiques liés à l'analyse et à la classification des images hyperspectrales qui en raison de leur nature multidimensionnelle et de la richesse de leurs informations nécessitent de prendre en compte un certain nombre de considérations supplémentaires.

Par ailleurs, nous avons confirmé que le choix de l'architecture des CNN multidimensionnels était bien adapté au traitement des données portées par le cube hyperspectral, permettant la considération des corrélations spatio-spectrales pour le renforcement de la description des échantillons et l'amélioration probable de la précision de leur classification.

L'extension du jeu de données Pavia University en incluant les données de Pavia Center a conduit à de meilleurs résultats de classification. En comparant les performances des modèles sur les deux jeux de données, il a été constaté que l'ajout des données de Pavia Center a eu un impact positif sur les résultats de classification. Cette observation confirme l'importance de disposer d'un jeu de données diversifié et représentatif pour l'amélioration de la classification des images hyperspectrales. En incluant des données provenant de différentes zones, il devient possible de capturer une plus grande variabilité intra-classes et une meilleure similarité inter-classes, ce qui améliore la capacité du modèle à établir des généralisations plus précises.

En plus de l'adaptation du modèle proposé par Sharma, initialement dédié à une application de reconnaissance faciale, pour répondre aux besoins d'une application différente liée à la télédétection suggèrent que le pouvoir des modèles et les conclusions émises suite à ce travail pourraient être valables si utilisés sur des jeux de données issus d'autres disciplines.

Ce dernier point témoigne de l'importance de la recherche et de l'innovation dans le domaine de l'apprentissage profond, où des modèles préexistants peuvent être adaptés et appliqués à de nouveaux domaines pour résoudre des problèmes assez complexes. Cette capacité d'adaptation ouvre de nouvelles perspectives pour l'utilisation de l'apprentissage profond dans des domaines variés, offrant des solutions efficaces et précises pour des problématiques spécifiques, même au-delà du domaine d'origine du modèle.

III.8 Conclusion

Dans ce chapitre, nous avons introduit notre projet d'exploiter le pouvoir de l'apprentissage profond pour la classification d'images hyperspectrales à l'aide de modèles de réseaux de neurones convolutifs (CNN) multidimensionnels. Nous avons souligné les défis pratiques auxquels sont confrontées les techniques de traitement et d'analyse d'images traditionnelles dans le domaine de l'imagerie hyperspectrale en raison de sa nature multidimensionnelle et redondante.

Conclusion générale

Dans le cadre de ce projet de fin d'études portant sur l'implémentation et l'évaluation des modèles profonds à base de CNN multidimensionnels pour la classification des images hyperspectrales de télédétection, nous avons exploré les techniques avancées de deep learning pour résoudre la tâche complexe de classification. Les résultats obtenus ont démontré l'efficacité et la pertinence des réseaux de neurones convolutifs (CNN) dans le traitement et l'analyse des données hyperspectrales.

Premièrement, nous avons introduit les techniques d'observation de la Terre et les capteurs de télédétection, mettant en évidence l'importance de l'imagerie hyperspectrale dans différentes applications. Nous avons également souligné le rôle crucial de la classification dans le domaine du deep learning, en comparant les caractéristiques des images classiques et des images de télédétection.

Ensuite, nous nous sommes concentrés sur l'utilisation de l'intelligence artificielle et du deep learning pour la classification des images hyperspectrales. Nous avons examiné les principaux modèles de deep learning utilisés couramment, en mettant l'accent sur les réseaux de neurones convolutifs. Nous avons également présenté les réseaux de neurones convolutifs multidimensionnels, spécifiquement conçus pour traiter les données hyperspectrales.

Enfin, nous avons mis en valeur l'évaluation des modèles profonds à base de CNN multidimensionnels. Nous avons décrit la procédure expérimentale adoptée, en détaillant la sélection des jeux de données et les critères de choix. De plus, nous avons présenté les résultats obtenus et mené une discussion sur les performances des modèles "hu", "sharma" et "chen" en utilisant les approches CNN1D, CNN2D et CNN3D.

Ce travail ouvre des perspectives prometteuses pour l'amélioration de la classification d'images hyperspectrales.

Par exemple la fusion des résultats actuels avec des résultats issues d'approches avérées déroulées en pré ou post-traitement, il est possible d'améliorer davantage les performances de la classification.

De plus, le renforcement de ce processus par l'exploitation de différents types de données, tels que les données LiDAR et les images à haute résolution spatiale, permettrait d'enrichir la représentation de l'environnement étudié et par conséquent sa caractérisation lors de la phase d'entraînement.

Enfin, l'application de ces modèles à de plus petites échelles suggérant l'utilisation de caméras spectroscopiques comme c'est le cas dans le milieu industriel (par exemple, domaine agroalimentaire ou pharmaceutique) ouvrirait de nouvelles possibilités d'automatisation et d'amélioration des processus industriels mais aussi une meilleure maîtrise de la phase de modélisation.

Conclusion générale

Toutes ces perspectives offrent des opportunités pour approfondir les connaissances et explorer de nouvelles applications de l'apprentissage profond dans le domaine de l'imagerie hyperspectrale.

En conclusion, nous espérons que les aboutissements de ce projet de fin d'études ont réussi à démontrer le pouvoir non-négligeable des modèles profonds à base de CNN multidimensionnels dans la classification des images hyperspectrales de télédétection. Les résultats ont démontré leur capacité à extraire des caractéristiques discriminantes à partir de données hyperspectrales complexes, aboutissant à des performances de classification améliorées.

Références bibliographiques

- [1] Maxicours. "Observation de la Terre et des planètes dans l'univers." 2023. Disponible sur : <https://www.maxicours.com/se/cours/observation-de-la-terre-et-des-planetes-dans-l-univers>
Consulté le 15 Avril
- [2] AppliSat. "Généralités sur les satellites : observation de la Terre par satellite.". Disponible sur : <https://www.applisat.fr/generalites-satellites/observation-de-la-terre-par-satellite>.
Consulté le 15 Avril 2023
- [3] AgriRéseau. "Observation de la Terre par satellite." Disponible sur : https://www.agrireseau.net/documents/Document_91259.pdf. Consulté le 25 avril 2023.
- [4] PwC France. "Observation de la Terre." Disponible sur : <https://www.pwc.fr/fr/industries/aeronautique-defense-spatial/secteur-spatial/observation-terre.html>. Consulté le 16 Avril 2023.
- [5] Techno-Science. "Définition de l'observation de la Terre." Disponible sur <https://www.techno-science.net/definition>. Consulté le 16 Avril 2023.
- [6] ResearchGate. "Les différents capteurs utilisés en télédétection spatiale : capteurs passifs." Disponible sur : <https://www.researchgate.net/figure/Les-differents-capteurs-utilises-en-teledetection-spatiale-capteurs-passifs>. Consulté le 17 Avril 2023.
- [7] Jensen, J. R. (2016). Remote sensing of the environment: An Earth resource perspective (2nd ed.). Pearson.
- [8] Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2014). Remote sensing and image interpretation (7th ed.). Wiley.
- [9] Campbell, J. B., & Wynne, R. H. (2011). Introduction to remote sensing (5th ed.). Guilford Press.
- [10] Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2014). Remote sensing and image interpretation (7th ed.). Wiley.
- [12] Photon etc. "Imagerie hyperspectrale." Disponible sur <https://www.photonetc.com/fr/imagerie-hyperspectrale>. Consulté le 20 Avril 2023.
- [13] Ahmad, M., Shabbir, S., Roy, S. K., Hong, D., Wu, X., Yao, J., ... & Chanussot, J. "Hyperspectral Image Classification—Traditional to Deep Models: A Survey for Future Prospects." IEEE Transactions on Geoscience and Remote Sensing.
- [14] Plaza, A., Benediktsson, J. A., & Boardman, J. W. (2009). Recent advances in techniques for hyperspectral image processing. Remote sensing of environment, 113(Supplement), S110-S122. doi:10.1016/j.rse.2008.07.017.
- [15] Zhang, Y., Li, Z., Li, J., & Plaza, A. (2021). Hyperspectral image super-resolution: A comprehensive review. IEEE Transactions on Geoscience and Remote Sensing, 59(1), 167-192. doi:10.1109/TGRS.2020.2981396.
- [16] Boardman, J. W. (1998). Multispectral, Hyperspectral, and High Spatial Resolution Remote Sensing Techniques for Improved Urban Environmental Modeling. In Proceedings of the IEEE, 86(11), 2002-2014. doi:10.1109/5.726791.

- [17] Boardman, J. W. (1995). Imaging spectroscopy: Remote sensing of Earth's surface chemical and physical properties. *International Journal of Remote Sensing*, 16(10), 1883-1884. doi:10.1080/01431169508954516
- [18] Kruse, F. A., Lefkoff, A. B., & Boardman, J. W. (1993). The spectral image processing system (SIPS) - Interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2-3), 145-163. doi:10.1016/0034-4257(93)90013-N
- [19] Green, R. O., Eastwood, M. L., Sarture, C. M., et al. (1998). Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sensing of Environment*, 65(3), 227-248. doi:10.1016/S0034-4257(98)00064-9.
- [20] Boardman, J. W., & Kruse, F. A. (1994). Analysis of imaging spectrometer data using N-Dimensional geometry and the geospatial lookup table (GeoSUL). *Remote Sensing of Environment*, 49(1), 14-28. doi:10.1016/0034-4257(94)90087-6.
- [21] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- [22] Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2016). A survey on deep learning for big data. *Information Fusion*, 42, 146-157.
- [23] Géron, A. (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow*. O'Reilly Media.
- [24] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- [25] Polytechnique Montréal. "Des réseaux de neurones profonds identifient les tumeurs.". Disponible sur : <https://www.polymtl.ca/carrefour-actualite/nouvelles/des-reseaux-de-neurones-profonds-identifient-les-tumeurs>. Consulté le 2 Mai 2023.
- [26] Liu, X., Zhang, L., & Yang, J. (2017). Deep learning for remote sensing image classification: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 242-257.
- [27] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [28] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [29] EO.BELSP0. "Les images de télédétection.". Disponible sur : <https://eo.belspo.be/fr/les-images-de-teledetection>. Consulté le 15 Mai 2023.
- [30] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [31] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [32] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.

- [33] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [34] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- [35] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. In *Advances in neural information processing systems* (pp. 5998-6008).
- [36] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255).
- [37] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [38] OpenClassrooms. "Classez et segmentez des données visuelles." 2023. Disponible sur : <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles>. Consulté le 22 Mai 2023.
- [39] JavaTpoint. "PyTorch Convolutional Neural Network Model Implementation.". Disponiblesur : <https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.javatpoint.com%2Fpytorch-convolutional-neural-network-model-implementation>. Consulté le 23 Mai 2023.
- [40] Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2017). Understanding deep learning requires rethinking generalization. *arXiv preprint arXiv:1611.03530*.
- [41] Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 801-818).
- [42] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 4700-4708).
- [43] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)* (pp. 234-241).
- [44] Complex Systems AI. "Métriques pour la classification.". Disponible sur : <https://complex-systems-ai.com/analyse-des-donnees/metriques-pour-la-classification/>. Consulté le 30 Mai 2023.
- [45] Lovely Analytics. "Accuracy, Recall, Precision.". Disponible sur : <https://www.lovelyanalytics.com/2020/05/26/accuracy-recall-precision/>. Consulté le 30 Mai 2023.
- [46] Lee, H., & Kwon, H. (2018). Going deeper with contextual CNN for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5517-5528.
- [47] Hu, W., Huang, Y., Wei, L., Zhang, F., & Li, H. (2016). Deep Convolutional Neural Networks for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and*

Remote Sensing, 54(10), 6232-6251.

[48] Sharma, V., Diba, A., Tuytelaars, T., & Van Gool, L. (sans date). Hyperspectral CNN for Image Classification & Band Selection, with Application to Face Recognition. KU Leuven, ESAT-PSI, iMinds, BIWI, CVL, ETH Zurich.

[49] Chen, Y., Jiang, H., Li, C., Jia, X., & Ghamisi, P. (sans date). Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks. IEEE Transactions on Geoscience and Remote Sensing, 1.

[50] CCWINTCO. "Hyperspectral Remote Sensing Scenes.". Disponible sur : https://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes. Consulté le 5 Juin 2023.

يقدم هذا العمل نهجًا لتصنيف الصور الفضائية فائقة الطيف باستخدام الشبكات العصبية المتراكبة (CNN). تحتوي الصور الفضائية فائقة الطيف على معلومات طيفية مفصلة عبر عدة نطاقات ترددية، مما يجعلها معقدة للمعالجة. الشبكات العصبية المتراكبة، التي استلهمت من عمل المخ البصري البشري، هي نماذج قوية للتعلم الآلي لاستخراج سمات تمييزية من البيانات غير المهيكلة، الكلمات مفتاحية: تصوير فائق الطيف، التعلم العميق، تصنيف الصور الفائقة الطيف، شبكات العصبونات المتراكبة

Résumé

Ce travail présente une approche de classification des images hyperspectrales en utilisant des réseaux de neurones convolutifs (CNN). Les images hyperspectrales contiennent des informations spectrales détaillées sur plusieurs bandes de fréquences, ce qui les rend complexes à traiter. Les CNN, inspirés du fonctionnement du cortex visuel humain, sont des modèles d'apprentissage automatique puissants pour extraire des caractéristiques discriminantes à partir de données non structurées.

Mots-clés : Imagerie hyperspectrale, apprentissage profond, classification des IHS, les réseaux de neurones convolutifs.

Abstract

This work presents an approach to hyperspectral image classification using convolutional neural networks (CNNs). Hyperspectral images contain detailed spectral information across multiple frequency bands, making them complex to process. CNNs, inspired by the functioning of the human visual cortex, are powerful machine learning models for extracting discriminative features from unstructured data.

Keywords: Hyperspectral imaging, deep learning, hyperspectral image classification, convolutional neural networks.