الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
المدرسة الوطنية العليا للتكنولوجيا
Ecole national supérieur de technologie
Département : Génie électrique Et Informatique Industrielle

Mémoire de fin d'études en vue de l'obtention du diplôme

Master

-Filière-

Télécommunications

-Spécialité-

Système de Télécommunications et Réseaux

- Thème –

Etat de l'art sur les méthodes de classification appliquées aux images hyperspectrales

Réalisé par

HAMRARAS Hiba

OUNNAR Maissa Cerine

Les membres de Jury :

Mme. CHIALI Imane	Présidente	M.C.B
Mme CHOUAF Seloua	Promotrice	M.A.A
Mme.BOUCHAMA Samira	Examinatrice	M.C.B
M.ABBADI Belkacem	Examinateur	M.C.B

Alger, le 02/07/2023

Année universitaire 2022 –2023

Etat de l'art sur les méthodes de classification appliquées aux images hyperspectrales

HAMRARAS Hiba, OUNNAR Maissa Cerine, CHOUAF Seloua

Département de Génie électrique et informatique industrielle

Ecole Nationale Supérieure de Technologie

Alger, Algérie

Email : h_hamraras@enst.dz ; m_ounnar@enst.dz ; seloua.chouaf@enst.dz

***Résumé*— L'analyse des images hyperspectrales (IHS) est un outil remarquable qui permet d'étudier finement la diversité de la constitution d'une zone d'intérêt (par exemple, la couverture terrestre). Parmi les outils d'analyse des images, la classification représente l'un des axes de recherche les plus adressés par la communauté de l'IHS. Son objectif principal est d'assigner une étiquette de classe à chaque pixel, en se basant sur un ensemble d'observations dont les classes seraient connues. Cependant, elle est souvent confrontée à des défis majeurs tels que la malédiction de la dimensionnalité et le manque d'échantillons constituant la vérité du terrain, exploitée lors de l'entrainement des modèles automatiques. Dans cet article, nous nous proposons d'aborder l'imagerie hyperspectrale en exposant ses applications et caractéristiques, avant de nous intéresser aux méthodes classiques et récentes de la classification IHS. De plus, nous illustrons par le bien d'une étude comparative, les résultats des méthodes communément utilisées afin d'exposer leur pouvoir avéré à répondre aux besoins récurrents liés au domaine de l'IHS.**

Mots-clés : Imagerie hyperspectrale, classification d'images, apprentissage profond.

I. INTRODUCTION

Les avancées technologiques des capteurs optiques au fil des décennies ont engendré une grande quantité d'informations, permettant d'atteindre les résolutions spatiales, spectrales et temporelles nécessaires. Parmi ces progrès majeurs se trouvent les images hyperspectrales (IHS).

L'imagerie hyperspectrale est une technologie émergente, basée sur la spectroscopie imagée. Elle permet la collecte instantanée de centaines d'images, liées à des longueurs d'ondes étroites et contigües, représentant une même zone spatiale. Contrairement à l'œil humain, qui ne possède que trois récepteurs sensibles aux ondes bleue, verte et rouge, les capteurs imageurs hyperspectraux mesurent les rayonnements électromagnétiques issus d'une large gamme spectrale qui s'étend généralement du visible au proche infrarouge. Les données collectées sont organisées sous forme tridimensionnelle, appelée cube hyperspectral, où deux dimensions renseignent sur l'étendue spatiale de l'image et la troisième dimension traduit son contenu spectral [1].

Ces images offrent de riches descriptions spectrales, ce qui a permis d'adresser de nouveaux domaines d'application mais aussi a posé de nouveaux défis technologiques à l'analyse des données [2]. Grâce à la résolution spectrale élevée, les capteurs d'images hyperspectrales sont capables d'extraire des informations subtiles sur les objets et les matériaux. Ces informations sont utilisées dans diverses tâches de détection, de quantification [3] et d'identification liées à des domaines variés tels que l'urbanisme [4], l'agriculture de précision [5] et la surveillance [6].

En effet, les propriétés des images obtenues par un système d'imagerie hyperspectrale sont définies par plusieurs caractéristiques clés qui les distinguent des autres types d'images. Ces caractéristiques comprennent la résolution spatiale, la résolution spectrale et la résolution radiométrique.

- La résolution spatiale évalue la finesse des détails dans une image, similaire aux images conventionnelles. Elle mesure la capacité du capteur à distinguer de petits objets adjacents.

- La résolution spectrale évalue la finesse du spectre obtenu pour chaque pixel. Elle indique la capacité du capteur à distinguer deux longueurs d'ondes voisines. Elle exprime également la distance entre deux bandes spectrales adjacentes.

- La résolution radiométrique évalue la finesse de l'intensité mesurée à chaque point du spectre. Elle représente la capacité du capteur à discriminer de petites variations d'énergie électromagnétique. Le nombre de bits utilisés pour la numérisation de l'image détermine le nombre maximum de niveaux d'intensité pouvant être mesuré.

Les systèmes panchromatiques ou multispectraux enregistrent une image de la scène sur trois à dix bandes spectrales, tandis que les systèmes IHS capturent des centaines de bandes spectrales contiguës. Les systèmes multispectraux ont une résolution spectrale (rapport entre la longueur d'onde centrale et la largeur de la bande spectrale) d'environ 10, tandis que celle des systèmes IHS est d'environ 100. Les systèmes multispectraux acquièrent des images dans des bandes de longueurs d'ondes larges et irrégulièrement espacées, tandis que les systèmes IHS utilisent des bandes spectrales régulièrement espacées, permettant ainsi d'obtenir un enregistrement spectral quasi-continu pour chaque pixel.

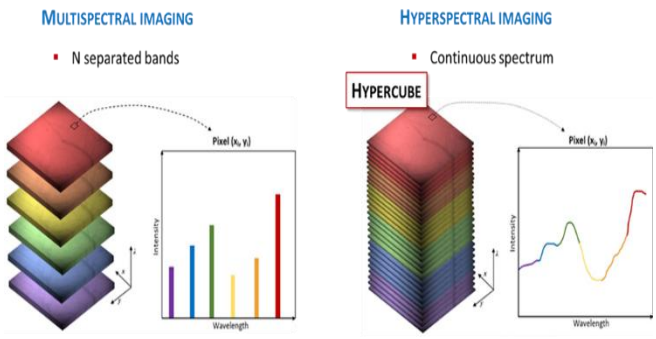
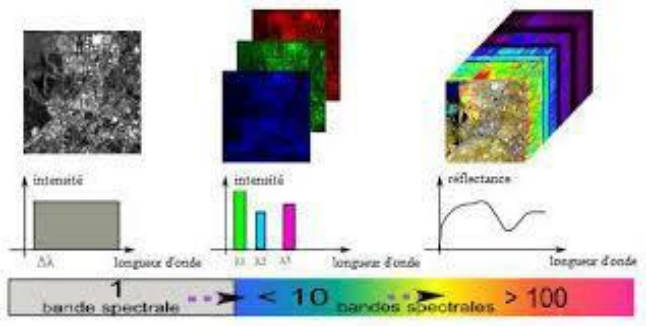


Figure1 : Comparaison des acquisitions multispectrale et hyperspectrale

La figure 1 illustre une imagerie multispectrale (à gauche), ne fournissant que des portions discrètes et discontinues de la gamme spectrale. Imagerie hyperspectrale (à droite), créant l'hypercube à l'aide d'un grand nombre de bandes spectrales contiguës. Le résultat donne un spectre complet pour chaque pixel (xi, yi). Adapté de [7]

Donc les images hyperspectrales fournissent une information plus détaillée des propriétés spectrales d'une scène et permettent de faire une identification et une discrimination plus précises des objets par comparaison à celles fournies par les capteurs multispectraux (figure 2). Plus encore, le passage de l'imagerie multispectrale à l'imagerie hyperspectrale est souvent décrit comme le passage du domaine de la discrimination aux domaines de la



quantification et de l'identification [8].

Figure 2 : Comparaison des images monochromatiques, multispectrales et hyperspectrales.

II. CLASSIFICATION DES IHS

Dans cette section, nous adressons la classification en tant que méthode d'analyse puis nous introduisons ses exigences en listant les principaux traitements appliqués aux données en phase préparatoire.

A. Classification des IHS et son importance dans l'analyse des données hyperspectrales

La classification d'images hyperspectrales représente une mission au sein du domaine de la vision par ordinateur et le plus souvent à la télédétection. Son objectif consiste à extraire des informations pertinentes et précises à partir des images, en attribuant des catégories spécifiques aux pixels hyperspectraux en se basant sur leurs caractéristiques spectrales. Cette méthode de classification permet d'identifier et de différencier divers objets et matériaux présents dans une scène donnée [9].

Cependant l'un des principaux problèmes rencontrés avec le traitement des données à haute dimension, traduite dans le cas de l'IHS par l'amélioration de la résolution spectrale, est la complexité de calcul résultant du traitement du grand volume de ces données [10]. Pour pallier à cela, une phase de traitement est généralement appliquée aux données en amont du processus de classification habituel.

B. Prétraitement des données hyperspectrales

Le prétraitement des données hyperspectrales est une étape essentielle pour améliorer la qualité des données avant leur classification. On parle souvent des corrections radiométriques qui visent à ajuster les valeurs attribuées aux pixels pour prendre en compte les différences de réponses des capteurs, les variations de l'éclairage, etc. [11]. Ces corrections s'appliquent généralement en respectant les étapes suivantes :

- Élimination du bruit

L'élimination du bruit est importante pour améliorer la qualité des données hyperspectrales en réduisant les artefacts indésirables et les variations aléatoires. Les techniques de filtrages spatial et spectral peuvent être utilisées pour réduire le bruit sans compromettre les informations utiles portées par les données [12].

- Correction atmosphérique

Le cas échéant, la correction atmosphérique est nécessaire pour compenser les effets de l'atmosphère sur les données hyperspectrales. L'atmosphère peut causer des distorsions dans les spectres en absorbant ou en dispersant la lumière, ce qui affecte la quantité de rayonnement détectée par le capteur. Des modèles et des algorithmes spécifiques sont utilisés pour estimer et corriger ces effets indésirables [13].

- Normalisation

La normalisation des données hyperspectrales vise à ajuster les valeurs spectrales de chaque pixel dans une plage spécifique. Cela permet de réduire les variations d'échelle entre les bandes spectrales et de garantir que toutes les bandes contribuent de manière égale à la classification. Les techniques de normalisation couramment utilisées incluent la normalisation min-max, la normalisation z-score (ou standardisation) et la normalisation des vecteurs unitaires.

- Décorrelation

Cette étape de traitement est souvent associée à l'ajustement des statistiques de distribution de chaque bande spectrale par centrage (imposant une moyenne nulle aux données) et par blanchiment (leur imposant une variance unitaire) [14].

La décorrelation des données hyperspectrales vise à éliminer la corrélation entre les différentes bandes spectrales.

Il s'agit d'une étape qui se propose de réduire les redondances et d'améliorer la séparabilité des classes dans l'espace des caractéristiques [15].

III. CLASSIFICATION TRADITIONNELLE DES IMAGES HYPERSPECTRALES

Dans le domaine de l'analyse des IHS, différentes approches ont été développées pour la classification des

données. Parmi ces approches, les méthodes traditionnelles de classification hyperspectrale ont été largement utilisées et ont démontré leur efficacité. Par méthodes traditionnelles, nous faisons référence à :

A. Le classificateur du k plus proche voisin (k-NN)

Le k-NN est l'un des classificateurs les plus simples et largement utilisés pour la classification HSI. La méthode k-NN fonctionne sur la règle du vote à la majorité. Il suppose que tous les voisins apportent des contributions égales à la classification du point de test. Une autre caractéristique importante du classificateur k-NN est que la similarité des données est issue du calcul de la distance Euclidienne entre les échantillons, ce qui suppose l'obtention d'une représentation interclasse assez homogène [16].

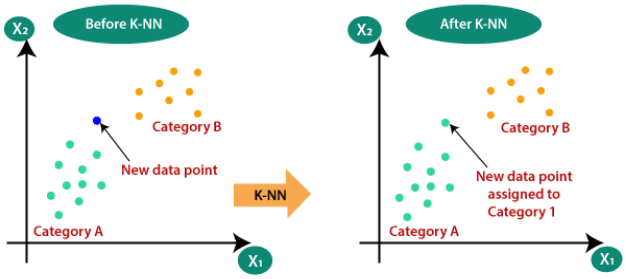


Figure 3 : Principe de classification par k-NN

Donc la méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche [17].

B. Les machines à vecteurs de support (SVM)

C'est un algorithme de classification supervisé qui maximise la marge entre les données et l'hyperplan. Différentes fonctions du noyau sont utilisées pour projeter les données dans des dimensions plus élevées telles que les fonctions linéaire, polynomiale, fonction de base radiale (RBF), etc. [18].

Le SVM est généralement un classificateur linéaire associatif avec les fonctions du noyau et la théorie de l'optimisation et est important pour la classification IHS [19]. Les SVM surpassent les méthodes de classification supervisées conventionnelles, en particulier, dans les conditions dominantes telles que l'augmentation du nombre de bandes spectrales et la disponibilité limitée d'échantillons d'apprentissage [20].

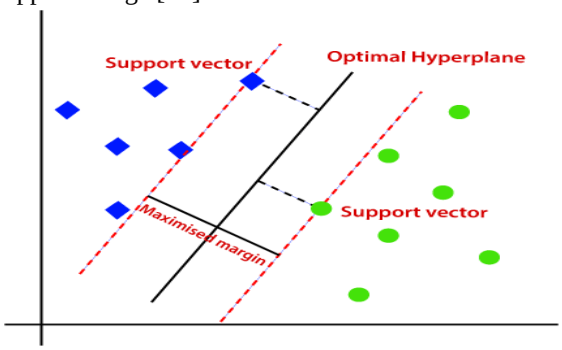


Figure 4 : Principe de classification par SVM.

C. La classification Bayésienne

La classification bayésienne s'apparente à une classification probabiliste simple (dite naïve). Elle repose sur le théorème de Bayes, qui n'est autre qu'un modèle de probabilités.

La méthode de classification naïve bayésienne est très utilisée dans le cadre du machine learning supervisé. Un jeu de données va, par exemple, permettre à l'outil d'apprendre à classer des images de produits en fonction de leur caractéristique (forme, couleur, etc.). Dans le cas de l'apprentissage supervisé, les données d'entrainement étiquetées et annotées sont utilisées pour donner au modèle la capacité de déterminer, par lui-même, les caractéristiques de classification [21]. Ce type de classification permet au modèle d'apprendre rapidement. Il n'est pas nécessaire de fournir un gros volume de données lors de la phase d'apprentissage. Son exécution est de plus très rapide, comparativement à d'autres méthodes de machine learning, plus complexes et lourdes à mettre en œuvre.

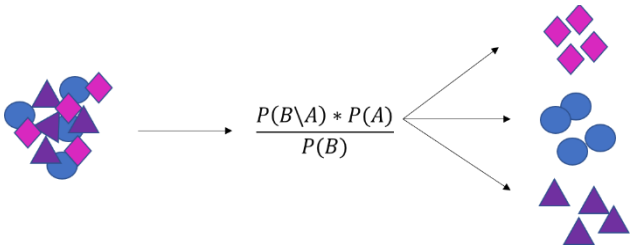


Figure 5 : Principe de classification bayésienne

D. Les réseaux de neurones

Les réseaux de neurones sont une des composantes importantes du domaine de l'intelligence artificielle. Les réseaux de neurones « artificiels », pour les différencier des réseaux de neurones biologiques, sont composés de neurones artificiels simples, petites fonctions mathématiques, qui permettent de former des fonctions complexes très utiles. Par analogie aux neurones biologiques, les neurones artificiels ont pour but de reproduire des raisonnements « intelligents » d'une manière artificielle. Ces neurones peuvent adopter de certaines qualités habituellement propres au biologique, c'est-à-dire, la généralisation, l'évolutivité, et une certaine forme de déduction [22].

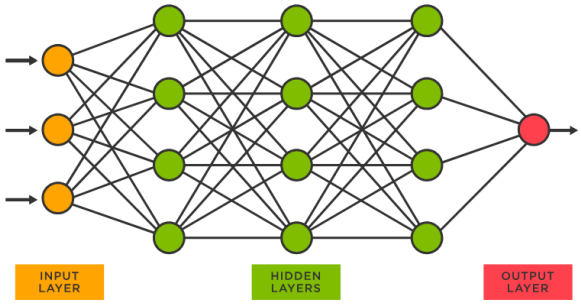


Figure 6 : Structure d'un réseau de neurones

Cette méthode présente plusieurs avantages, desquels nous citons :

- Sa capacité à représenter n'importe quelle fonction, linéaire ou pas, simple ou complexe.

- Sa faculté d'apprentissage automatique à partir d'exemples représentatifs, par « rétro propagation des erreurs ».
- Sa résistance au bruit ou au manque de fiabilité des données.
- La simplicité de sa manipulation, avec beaucoup moins de travail personnel à fournir que dans le cas de l'analyse statistique classique.
- Son comportement peu affecté en cas de faible quantité de données [23]

Mais aussi elle présente des inconvénients tels que :

- L'absence de méthodes systématiques permettant de définir la meilleure topologie du réseau et le nombre de neurones à placer dans la (ou les) couche(s) cachée(s).
- Le choix des valeurs initiales des poids du réseau et le réglage du pas d'apprentissage, qui jouent un rôle important dans la vitesse de convergence.
- Le problème du sur-apprentissage (overfitting) qui constitue un apprentissage au détriment de la généralisation [23]

Il est à noter que les réseaux de neurones sont utilisés dans plusieurs autres domaines dont le traitement de signal, le traitement automatique du langage, le contrôle et le diagnostic, l'optimisation, la simulation, la classification des espèces animales, etc. [24].

IV. LES METHODES AVANCEES DE CLASSIFICATION

L'apprentissage profond (deep learning) est un ensemble de techniques d'apprentissage automatiques qui a permis des avancées importantes en intelligence artificielle dans les dernières années.

Le deep learning (DL) est une approche plus complexe, simulant le principe de fonctionnement des cerveaux humains, qui se basent sur des réseaux de neurones qui effectuent des opérations simples. Les résultats d'une première couche de neurones qui servent d'entrée aux calculs d'une deuxième couche et ainsi de suite. Ce qui commence à appliquer la classification d'images hyperspectrales [25]. Les méthodologies notables incluent le réseau de croyance profonde (DBN), les réseaux de neurones récurrents (RNN), l'encodeur automatique empilé (SAE) et le réseau de neurones convolutifs (CNN).

A. Les réseaux de croyance profonde(DBN)

Sont un développement important dans la recherche DL. Les DBN sont construits en empilant plusieurs couches de Restricted Boltzmann Machines (RBM) qui sont des modèles probabilistes génératifs [26], un Deep Neural Network a une couche d'entrée, une couche de sortie et au moins une couche entre les deux. Plus le nombre de couches est élevé, plus un réseau est dit profond.

Chacune de ces couches effectue différents types de tri et de catégorisation spécifique dans un processus nommé hiérarchie de caractéristique [27]. La structure simple de DBN est présentée dans la Figure 7.

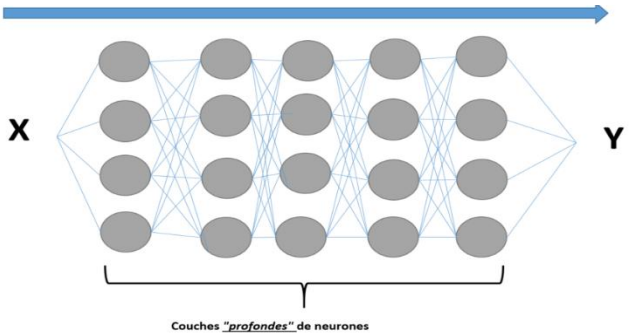


Figure 7 : Structure d'un DBN profond [28]

B. Les réseaux de neurones récurrents(RNN)

Les réseaux de neurones récurrents, sont un type de réseau de neurones largement utilisé dans le domaine de l'apprentissage en profondeur. Les RNN utilisent les sorties précédentes comme entrées supplémentaires et sont parfaitement adaptés au traitement de données séquentielles. Généralement, elles se présentent sous la forme illustrée par la figure 8 [29].

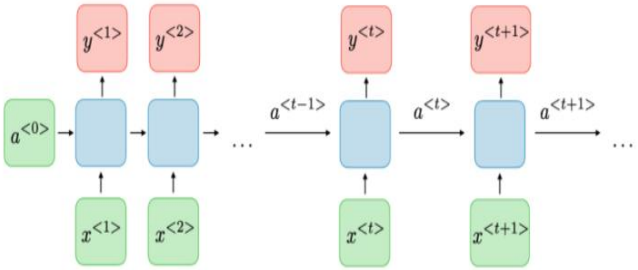


Figure 8 : Architecture d'un RNN [29]

C. Les réseaux de neurones auto-encodeurs

Les auto-encodeurs sont des réseaux de neurones un peu particuliers qui possèdent exactement le même nombre de neurones sur leur couche d'entrée et leur couche de sortie.
Le but pour un auto-encodeur est d'avoir une sortie la plus proche de l'entrée que possible.
Un auto-encodeur a une architecture très spécifique, car les couches cachées sont plus petites que les couches d'entrée.
On appelle ce type d'architecture une architecture en bottle neck (cou de bouteille). L'architecture d'un auto-encodeur est constituée de deux parties : l'encodeur et le décodeur [30].
La figure suivante schématise un auto-encodeur simple, dont l'encodeur (encoder) traite des images (inputs), afin de les représenter comme des points dans un espace à deux dimensions (encoded representation), puis décode cette représentation (decoder), afin de reconstruire des données comparables à celle de départ (outputs) [31].

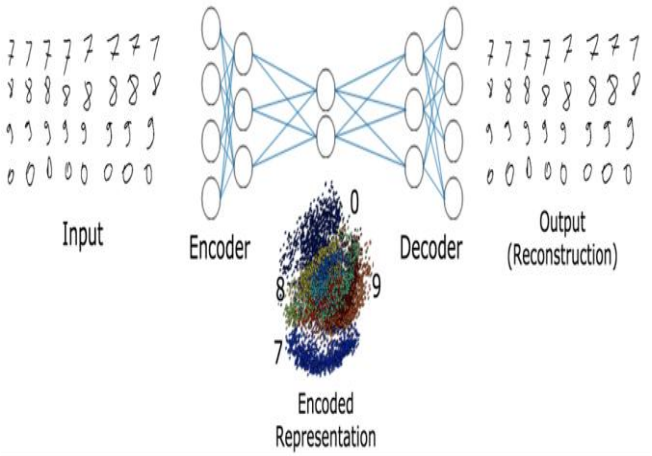


Figure 9 : Structure de base d'un auto-encodeur [31].

D. Les réseaux de neurones convolutifs (CNN)

On appelle réseau neuronal convolutif, ou réseau de neurones à convolution (Convolutional Neural Network), un type de réseau de neurones artificiels utilisé dans la reconnaissance et le traitement des images, et spécialement conçu pour l'analyse des pixels [32]. Les modèles à base de réseaux de neurones à convolution (CNN) sont devenus des outils incontournables pour la classification et l'analyse d'images. Ils ont révolutionné la façon dont les données visuelles sont traitées, en permettant une extraction automatique et hiérarchique des caractéristiques à partir de données brutes. Les couches de neurones entièrement connectés combinent les caractéristiques extraites pour la classification finale. L'architecture générale des modèles à base de CNN comporte plusieurs couches, notamment les couches de convolution, de pooling et de neurones entièrement connectés. Les couches de convolution fonctionnent en appliquant un filtre aux données d'entrée pour identifier leurs fonctionnalités. Ce filtre, connu sous le nom de détecteur de caractéristiques, vérifie les champs récepteurs de l'entrée d'image pour une caractéristique donnée. Cette opération est appelée convolution [33]. Les couches de pooling réduit la dimensionnalité de l'entrée, ce qui la rend plus facile à traiter et nécessite moins de mémoire. Les couches entièrement connectées sont généralement utilisées vers la fin d'un CNN, lorsque l'objectif est de prendre les caractéristiques apprises par les couches convolutionnelles en regroupement et de les utiliser pour faire des prédictions, telles qu'une classe parmi celles définies en entrée est associée comme étiquette [34].
L'architecture CNN est particulièrement utile pour la reconnaissance et la classification d'images, ainsi que pour d'autres tâches de vision par ordinateur, car elle peut traiter de grandes quantités de données et produire des prédictions très précises.
Les CNN peuvent apprendre les fonctionnalités d'un objet à travers plusieurs itérations, éliminant ainsi le besoin de tâches manuelles.
Il est possible de recycler un CNN pour une nouvelle tâche de reconnaissance ou de construire un nouveau modèle basé sur un réseau existant avec des poids entraînés. C'est ce que l'on appelle l'apprentissage par transfert. Cela permet aux développeurs de modèles d'appliquer des CNN à différents cas d'utilisation sans repartir de zéro [35].
Les CNN sont largement utilisés pour identifier des images satellitaires, traiter des images médicales, prévoir des séries chronologiques et détecter des anomalies [36].

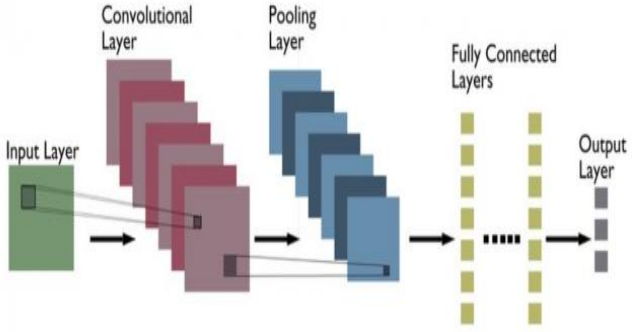


Figure 10 : Architecture typique d'un CNN [37]

E. Les modèles basés sur les CNN

- VGGNet

Le modèle VGG est un réseau neuronal profond qui a atteint des performances de pointe lors du défi de reconnaissance visuelle à grande échelle ImageNet en 2014, et a été largement utilisé comme référence pour les tâches de classification d'images et de détection d'objets [38].

- GoogLeNet

GoogLeNet est un réseau de neurones à convolution profonde développé par des chercheurs de Google. Il a été introduit en 2014 et a remporté le ILSVRC (ImageNet Large-Scale Visual Recognition Challenge) cette année-là, avec un taux d'erreur parmi les cinq premiers [38].

- ResNet

ResNet est un modèle d'apprentissage en profondeur bien connu, qui a été présenté pour la première fois dans un article de Shaoqing Ren, Kaiming He, Jian Sun et Xiangyu Zhang. En 2015, une étude intitulée Deep Residual Learning for Image Recognition a été publiée. ResNet est l'un des modèles d'apprentissage en profondeur les plus utilisés et les plus efficaces à ce jour [39].

Il existe d'autres modèles basés sur les CNN desquels nous citons les suivants :

- Modèle Chen (CNN-3D)

Ce modèle utilise plusieurs couches de convolution et de mise en commun pour extraire les caractéristiques profondes des HSI, qui sont utiles pour la classification des images et la détection des cibles. Le modèle est formé à l'aide d'un algorithme de rétro propagation et plusieurs stratégies telles que la régularisation L2 pour éviter le sur ajustement dans la modélisation des données de classe [40].

- Modèle Sharma (CNN-2D)

Le modèle utilise une combinaison de réseau neuronal convolutif (CNN) et AdaBoostSVM pour la sélection de bande discriminative dans les images hyperspectrales.
La méthode proposée surpasse les méthodes de pointe existantes pour la reconnaissance faciale sur deux ensembles de données de visage hyperspectraux standard [41].

Notons que les modèles à base de CNN offrent de nombreux avantages car 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 [42].

V. ÉVALUATION ET COMPARAISON

Dans cette section, nous définissons les mesures d'évaluation des performances couramment utilisées. De plus, une étude comparative entre les méthodes sera établie

A. Outils d'évaluation des performances

L'évaluation des performances des méthodes de classification des images hyperspectrales repose sur plusieurs mesures dont :

- La matrice de confusion

La matrice de confusion est une mesure de base pour évaluer les performances d'une méthode de classification.
Elle présente les résultats de la classification en comparant les classes réelles aux classes prédites. La matrice de confusion permet de calculer d'autres mesures de performance telles que la précision (accuracy), le rappel (recall), les scores F1, l'exactitude globale (anglais), le Kappa de Cohen, etc., que nous présentons dans cette suite :

- La précision

La précision est la mesure du pourcentage de pixels correctement classés pour une classe donnée. Elle indique la capacité de la méthode de classification à attribuer correctement les pixels à leurs classes réelles.

- Le rappel

Le rappel, également appelé taux de vrais positifs, mesure la capacité de la méthode de classification à identifier tous les pixels d'une classe réelle donnée. Il est calculé en divisant le nombre de pixels correctement classés pour une classe donnée par le nombre total de pixels de cette classe.

- Les scores F1

Le score F1 est une mesure qui combine la précision et le rappel en une seule valeur. Il permet d'évaluer l'équilibre entre ces deux métriques pour une classe donnée. Un score F1 élevé indique une classification correcte et complète.

- L'exactitude globale :

L'exactitude globale est la mesure du pourcentage total de pixels correctement classés pour toutes les classes. Elle fournit une évaluation globale des performances de la méthode de classification.

- Le Kappa de Cohen

Le kappa de Cohen est une mesure statistique qui évalue l'accord entre les classes réelles et les classes prédites, en prenant en compte l'accord qui pourrait être obtenu par hasard. Il est souvent utilisé pour corriger l'exactitude globale en tenant compte de l'accord aléatoire.

- La courbe de caractéristique de l'opérateur (ROC) :

La courbe ROC est utilisée pour évaluer les performances des méthodes de classification binaire. Elle représente le taux de vrais positifs en fonction du taux de faux positifs pour différents seuils de classification. L'aire sous la courbe ROC (AUC) est une mesure très courante de la performance de classification [43] [44] [45].

B. Comparaison des méthodes traditionnelles et avancées

Au cours de cet exposé, les jeux de données hyperspectraux Indian Pines et Pavia University seront utilisés à titre d'illustration
Le tableau 1 extrait de la référence [46], présente les performances de deux méthodes de classification, D-CNN et SVM, appliquées à différents jeux de données. Les pourcentages indiqués représentent les taux de précision obtenus par chaque méthode pour la classification des données dans chaque jeu.
Pour Indian Pines, les D-CNN ont obtenu un taux de précision de 90.18% pour la classification des données alors que les SVM ont obtenu un taux de précision de 87.54%.
Pour Pavia University, les D-CNN ont obtenu un taux de précision de 92.64% alors que les SVM ont obtenu un taux de précision de 90.42%. Ces résultats indiquent que, dans les deux cas, les D-CNN ont surpassé les SVM en termes de taux de précision

TABLE I. MESURES DE L'ACCURACY ET DU COEFFICIENT KAPPA OBTENUES POUR DIFFERENTS MODELES DE CLASSIFICATION POUR LES JEUX DE DONNEES INDIAN PINES ET PAVIA UNIVERSITY [46]

Base de données	D-CNN(%)	SMV(%)
Indian Pines	90.18	87.54
Pavia University	92.64	90.42

Le tableau 2 compare les performances de différentes méthodes de classification (SVM, 1D NN, 1D CNN, RNN, 2D+1D CNN, 3D CNN) sur les mêmes jeux de données précédents. Les mesures d'évaluation utilisées sont la précision et le Kappa.

En analysant les résultats, on note que pour le jeu de données Indian Pines, la méthode 1D NN obtient le meilleur taux de précision de 83.13% ±0.84, suivi de près par 1D CNN avec 82.99%±0.93. Les SVM ont également obtenu une performance solide avec un taux de précision de 81.43%.

En termes de valeur de Kappa, 1D NN a la valeur la plus élevée de 0.807 ±0.009, suivi de près par 1D CNN avec 0.806 ±0.011.

Pour le jeu de données Pavia University, les méthodes 3D CNN et 2D+1D CNN affichent les meilleures performances en termes de précision, avec des taux de 84.32% ±0.72 et 83.80% ±1.29 respectivement. 1D CNN suit de près avec un taux de 81.18% ±1.96.

En termes de valeur de Kappa, les 3D CNN et 2D+1D CNN ont les valeurs les plus élevées, avec 0.799 ±0.009 et 0.792 ±0.016 respectivement.

En conclusion, les performances varient en fonction des méthodes de classification et des jeux de données manipulées. Dans l'ensemble, les méthodes basées sur les réseaux de neurones, telles que 1D NN, 1D CNN, 2D+1D

CNN et 3D CNN, semblent obtenir de meilleures performances que SVM et les RNN. Cependant, il est important de noter que les performances des différentes méthodes peuvent être sensibles à la nature spécifique des jeux de données utilisés.
Il convient également de noter les incertitudes associées aux mesures, qui indiquent la variabilité des performances sur plusieurs évaluations. Les intervalles de confiance donnent une idée de la fiabilité des estimations des performances.
En résumé, les méthodes basées sur les réseaux de neurones, en particulier les modèles 3D CNN et 2D+1D CNN, semblent être les plus performantes pour les bases de données illustrées, tandis que les SVM et RNN obtiennent des résultats légèrement inférieurs.

TABLE II. RESULTATS EXPERIMENTAUX DE DIVERS MODELES SUR INDIAN PINES ET, PAVIA UNIVERSITY [47]

Method	Indian Pines		Pavia University	
	Accuracy	K	Accuracy	K
SVM	81.43	0.788	69.56	0.592
1D NN	**83.13**±0.84	**0.807**±0.009	76.90±0.86	0.711±0.010
1D CNN	82.99±0.93	0.806±0.011	81.18±1.96	0.759±0.023
RNN	79.70±0.91	0.769±0.011	67.71±1.25	0.599±0.014
2D+1D CNN	74.31±0.73	0.707±0.008	83.80±1.29	0.792±0.016
3D CNN	75.47±0.85	0.719±0.010	**84.32**±0.72	**0.799**±0.009

VI. APPLICATIONS ET DEFIS

A. *Applications de la classification hyperspectrale*

La classification d'images hyperspectrales joue un rôle important et a été investiguée dans de nombreuses applications, notamment l'aménagement urbain, le suivi des changements fonciers, interprétation de scènes, la gestion des ressources [48], le diagnostic médical, l'analyse environnementale, l'agriculture, la surveillance et la sécurité, le contrôle des aliments et bien d'autres que l'on pourrait rassembler dans la figure ci-dessous:

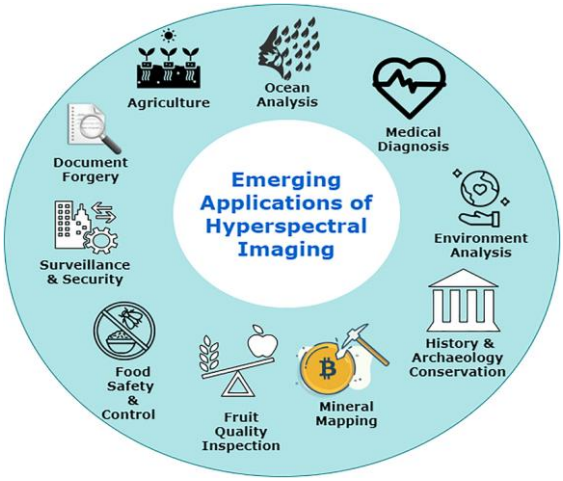


Figure 11 : Les applications de la classification d'IHS [49]

B. *Les défis*

Depuis leur apparition, l'analyse et les opérations sur les images hyperspectrales ont été confrontées à plusieurs difficultés. Initialement, la qualité des capteurs hyperspectraux qui était médiocre, avec des données insuffisantes, ce qui engendrait des problèmes liés à la technologie de spectroscopie. Cependant, grâce aux avancées de la science appliquée, ces problèmes ont été en partie résolus. Certains des problèmes bien connus comprennent [50] :
- L'absence des images sans bruit : Les spectromètres initiaux étaient peu efficaces, ce qui entraînait des bruits provenant de la vapeur d'eau, des polluants atmosphériques et d'autres perturbations atmosphériques. Des efforts ont été déployés pour produire des données hyperspectrales de haute qualité pour l'observation de la Terre, en développant des spectromètres performants combinant imagerie numérique, spectroscopie et extraction de caractéristiques spatio-spectrales [51].
- Entraves à l'extraction des caractéristiques : La redondance entre les bandes spectrales contiguës entraîne la disponibilité d'informations dupliquées, ce qui rend difficile la récupération optimale et la discriminative des caractéristiques spatio-spectrales [52].
- La grande variabilité spatiale et similarité interclasse : Les données hyperspectrales collectées peuvent contenir une variabilité excessive au sein des classes. La faible résolution spatiale contribue également à la similarité interclasse dans les régions frontalières, ce qui crée des incohérences et des incertitudes pour les algorithmes de classification utilisés [53].
- L'insuffisance des échantillons d'apprentissages étiquetés : Les spectromètres aériens couvrent des zones restreintes, ce qui limite le nombre d'échantillons d'apprentissage pour les modèles de classification [54]. De plus, l'étiquetage manuel des pixels nécessite beaucoup de temps et de ressources [55].
- Le manque d'équilibre entre les échantillons interclasses : Le déséquilibre des classes, où certaines classes ont un grand nombre d'occurrences, rend difficile l'amélioration de la précision de la classe minoritaire sans compromettre la précision de la classe majoritaire [56].

- La dimensionnalité élevée : Les images hyperspectrales contiennent plus d'informations dans de nombreux canaux, ce qui augmente les erreurs d'estimation et présente un défi pour les algorithmes de classification supervisée en raison de la malédiction de la dimensionnalité [57].

CONCLUSION

Les auteurs de cet article ont souhaité examiner les méthodes de classification des images hyperspectrales en présentant un détail qui met en évidence les caractéristiques et les applications liées à divers domaines tels que l'agriculture, analyses d'environnement, surveillance et sécurité avec un léger accent sur le domaine de la télédétection.

Ce document explore également les méthodes traditionnelles et avancées de classification hyperspectrale, en analysant leurs différences et en soulignant les avantages des approches les plus récentes.

Finalement, cet article a tenté également d'identifier les défis auxquels est confrontée la classification des images hyperspectrales.

REFERENCES

[1] Nireos. "Hyperspectral Imaging." [En ligne]. Disponible sur : https://www.nireos.com/hyperspectral-imaging. Consulté le 5 juin 2023.

[2] Bioucas-Dias JM, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N, Chanussot J. "Analyse des données de télédétection hyperspectrale et défis futurs." Magazine IEEE de géosciences et de télédétection. 2013; 1(2): 6-36

[3] Zhang L, Zhang L, Tao D, Huang X, Du B. "Détection de cibles de sous-pixels d'image de télédétection hyperspectrale basée sur l'apprentissage métrique supervisé." Transactions IEEE sur les géosciences et la télédétection. 2014; 52(8): 4955-4965

[4] Tong X, Xie H, Weng Q. "Classification de l'occupation du sol urbain avec des données hyperspectrales aéroportées: quelles fonctionnalités utiliser?" IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2013; 7(10): 3998-4009

[5] Gevaert CM, Suomalainen J, Tang J, Kooistra L. "Génération de surfaces de réponse spectrale-temporelle en combinant des images satellitaires multispectrales et des drones hyperspectraux pour des applications agricoles de précision." IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2015; 8(6): 3140-3146

[6] Yuen PW, Richardson M. "Une introduction à l'imagerie hyperspectrale et à son application pour la sécurité, la surveillance et l'acquisition de cibles." Le Journal des sciences de l'imagerie. 2010; 58(5): 241-253

[7] Luca Giannoni et al 2018 J. Opt. 20 044009

[8] Chang CI. Hyperspectral Data Exploitation: Theory and Applications. John Wiley & Sons, 2007.

[9] Benediktsson JA, Sveinsson JR, Johannesson JR. "Hyperspectral image classification: A review." IEEE Geoscience and Remote Sensing Magazine. 2013; 1(2): 5-13

[10] Te-Ming T, Chen CH, Wu JL, Chang CI. "Une méthode de classification rapide en deux étapes pour les données de télédétection de grande dimension." IEEE Transaction on Geoscience and Remote Sensing. 1998; 36(1): 182-191

[11] Schowengerdt RA. Remote Sensing: Models and Methods for Image Processing. 3rd ed., Academic Press, 2007.

[12] Boardman JW. "Removal of atmospheric and illumination effects in hyperspectral data." Summaries of the third annual JPL airborne geoscience workshop. 1993; 93: 7-9.

[13] Chavez PS. "Image-based atmospheric corrections—Revisited and improved." Photogrammetric Engineering and Remote Sensing. 1996; 62(9): 1025-1036.

[14] Plaza A, Benediktsson JA, Plaza J. "Spectral indices in hyperspectral remote sensing of urban areas." Hyperspectral image processing. CRC Press, 2009, pp. 207-235.

[15] Du Q, Sun J. "Orthogonalization and transformation of hyperspectral data for feature extraction." Advances in hyperspectral data processing for remote sensing. CRC Press, 2014, pp. 25-48.

[16] Kuo BC, Yang JM, Sheu TW, Yang SW. "Classificateurs knn et gaussiens basés sur le noyau pour la classification d'images hyperspectrales." IGARSS 2008–2008 IEEE International Geoscience and Remote Sensing Symposium. Vol. 2. IEEE, 2008, pp. II-1006

[17] Boughaba, A., Boukhris, R. "Développement d'un Système de Contrôle de Sécurité de Véhicules Utilisant une Technique d'Imagerie Hyperspectrale." [En ligne]. Disponible sur : https://dspace.univ-ouargla.dz/jspui/bitstream/123456789/17195/1/Boughaba_Boukhris.pdf. Consulté le 8 juin 2023.

[18] Towards Data Science. "Hyperspectral Image Analysis and Classification." [En ligne]. Disponible sur : https://towardsdatascience.com/hyperspectral-image-analysis-classification-c41f69ac447f. Consulté le 1er juin 2023.

[19] Melgani F, Bruzzone L. "Classification d'images de télédétection hyperspectrales avec des machines à vecteurs de support." Transactions IEEE sur les géosciences et la télédétection. 2004; 42(8): 1778-1790

[20] Tarabalka Y, Fauvel M, Chanussot J, Benediktsson JA. "Méthode basée sur SVM et MRF pour une classification précise des images hyperspectrales." Lettres IEEE sur les géosciences et la télédétection. 2010; 7(4): 736-740

[21] Journal du Net. "Classification Naïve Bayésienne : Définition." [En ligne]. Disponible sur : https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501321-classification-naive-bayesienne-definition. Consulté le 3 juin 2023.

[22] (mémoire magister belkadi)

[23] Wikiversité. "Réseaux de neurones : Avantages et possibilités." [En ligne]. Disponible sur : https://fr.wikiversity.org/wiki/Réseaux_de_neurones/Avantages_et_possibilités. Consulté le 7 juin 2023.

[24] Statsoft. "Réseaux de Neurones Automatisés." [En ligne]. Disponible sur : http://www.statsoft.fr/concepts-statistiques/reseaux-de-neurones-automatises/reseaux-de-neurones-automatises.htm. Consulté le 4 juin 2023.

[25] Ghamisi P, Plaza J, Chen Y, Li J, Plaza AJ. "Classificateurs spectraux avancés pour les images hyperspectrales: une revue." Magazine de géosciences et de télédétection de l'IEEE. 2017; 5(1): 8-32

[26] Freund Y, Haussler D. Apprentissage non supervisé de distributions sur des vecteurs binaires à l'aide de réseaux à deux couches. Dans : Avancées dans les systèmes de traitement de l'information neuronale. 1992. pages 912-919

[27] DataScientest. "Deep Neural Network." [En ligne]. Disponible sur : https://datascientest.com/deep-neural-network. Consulté le 6 juin 2023

[28] Wikimedia Commons. "Réseau de Neurone Profond." [En ligne]. Disponible sur : https://commons.wikimedia.org/wiki/File:Reseau_de_neurone_profond.png?uselang=fr. Consulté le 9 juin 2023.

[29] DataValue Consulting. "Deep Learning : Réseaux Neurones Récurrents (RNN)." [En ligne]. Disponible sur : https://datavalue-consulting.com/deep-learning-reseaux-neurones-recurrents-rnn. Consulté le 2 juin 2023

[30] DataScientest. "Les Autoencodeurs : Modèles d'apprentissage non supervisé." [En ligne]. Disponible sur : https://datascientest.com/les-autoencoders-modeles-dapprentissage-non-supervise. Consulté le 10 juin 2023

[31] Data Analytics Post. "Auto-Encodeur." [En ligne]. Disponible sur : https://dataanalyticspost.com/Lexique/auto-encodeur/. Consulté le 21 mai 2023

[32] LeMagIT. "Réseau Neuronal Convolutif." [En ligne]. Disponible sur : https://www.lemagit.fr/definition/Reseau-neuronal-convolutif. Consulté le 26 mai 2023

[33] DataGen. "CNN - Convolutional Neural Network." [En ligne]. Disponible sur : https://datagen.tech/guides/computer-vision/cnn-convolutional-neural-network/. Consulté le 31 mai 2023

[34] Vitalflux. "Different Types of CNN Architectures Explained with Examples." [En ligne]. Disponible sur : https://vitalflux.com/different-types-of-cnn-architectures-explained-examples/. Consulté le 25 mai 2023.

[35] DataGen. "CNN - Convolutional Neural Network." [En ligne]. Disponible sur : https://datagen.tech/guides/computer-vision/cnn-convolutional-neural-network/. Consulté le 31 mai 2023

[36] Simplilearn. "Deep Learning Algorithm." [En ligne]. Disponible sur : https://www.simplilearn.com/tutorials/deep-learning-tutorial/deep-learning-algorithm. Consulté le 27 mai 2023

[37] Vitalflux. "Different Types of CNN Architectures Explained with Examples." [En ligne]. Disponible sur : https://vitalflux.com/different-types-of-cnn-architectures-explained-examples/. Consulté le 25 mai 2023

[38] DataGen. "CNN - Convolutional Neural Network." [En ligne]. Disponible sur : https://datagen.tech/guides/computer-vision/cnn-convolutional-neural-network/. Consulté le 31 mai 2023

[39] IQ OpenGenus. "Different Types of CNN Models." [En ligne]. Disponible sur : https://iq.opengenus.org/different-types-of-cnn-models/. Consulté le 22 mai 2023

[40] Y. Chen, H. Jiang, C. Li, X. Jia and P. Ghamisi, "Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks," in IEEE Transactions on Geoscience and Remote Sensing, vol. 54, no. 10, pp. 6232-6251, Oct. 2016, doi: 10.1109/TGRS.2016.2584107.

[41] Sharma V, Diba A, Tuytelaars T, Van Gool L. "CNN hyperspectral pour la classification des images et la sélection des bandes, avec application à la reconnaissance faciale."

[42] Zhang C, Bengio S, Hardt M, Recht B, Vinyals O. "Understanding deep learning requires rethinking generalization." arXiv preprint arXiv:1611.03530

[43] Plaza A, Benediktsson JA, Boardman JW. "Recent advances in techniques for hyperspectral image processing." IEEE Geoscience and Remote Sensing Magazine, 7(3), 8-36.

[44] Fauvel M, Benediktsson JA, Chanussot J. "Advances in spectral-spatial classification of hyperspectral images." Proceedings of the IEEE, 101(3), 652-675.

[45] Camps-Valls G, Tuia D, Gómez-Chova L, Malo J. "Hyperspectral image classification and dimensionality reduction: An overview of the supervised methods." IEEE

[46] IntechOpen. [En ligne]. Disponible sur : https://www.intechopen.com/chapters/70188. Consulté le 24 mai 2023.

[47] Audebert N, Le Saux B, Lefèvre S. "Deep Learning for Classification of Hyperspectral Data: A Comparative Review."

[48] L. Mou, P. Ghamisi and X. X. Zhu, "Deep Recurrent Neural Networks for Hyperspectral Image Classification," in IEEE Transactions on Geoscience and Remote Sensing, vol. 55, no. 7, pp. 3639-3655, July 2017, doi: 10.1109/TGRS.2016.2636241

[49] ResearchGate. [En ligne]. Disponible sur : https://www.researchgate.net/figure/Emerging-applications-of-hyperspectral-imaging_fig1_353393226. Consulté le 30 mai 2023

[50] PubMed Central. [En ligne]. Disponible sur : https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9071975/. Consulté le 23 mai 2023

[51] Paoletti ME, Haut JM, Plaza J, Plaza A. "Classificateurs d'apprentissage profond pour l'imagerie hyperspectrale : une revue." Journal ISPRS de photogrammétrie et de télédétection, 158 (décembre), 279–317

[52] Ghamisi P, Yokoya N, Li J, et al. "Avancées en image hyperspectrale et traitement du signal : un état des lieux complet de l'état de l'art." IEEE Geoscience and Remote Sensing Magazine, 5(4), 37–78

[53] Paoletti ME, Haut JM, Plaza J, Plaza A. "Classificateurs d'apprentissage profond pour l'imagerie hyperspectrale : une revue." Journal ISPRS de photogrammétrie et de télédétection, 158 (décembre), 279–317

[54] Chowdhary CL, Patel PV, Kathrotia KJ, Attique M, Perumal K, Ijaz MF. "Étude analytique des techniques hybrides de chiffrement et de déchiffrement d'images." Capteurs, 20(18), p. 5162.

[55] Jia S, Jiang S, Lin Z, Li N, Xu M, Yu S. "Une enquête : apprentissage approfondi pour la classification d'images hyperspectrales avec peu d'échantillons étiquetés." Neuroinformatique, 448, 179–204

[56] Quan Y, Zhong X, Feng W, Chan JC-W, Li Q, Xing M. "Forêt de rotation profonde pondérée basée sur SMOTE pour la classification déséquilibrée des données hyperspectrales." Télédétection, 13(3), p. 464

[57] Hughes G. "Sur la précision moyenne des reconnaisseurs de modèles statistiques." Transactions IEEE sur la théorie de l'information, janvier 1968, 14(1), 55–63.