

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8Mai 1945 – GUELMA
Faculté des Sciences et de la Technologie
Département d'Electronique et Télécommunication



Mémoire de Fin d'Etude
Pour l'Obtention du Diplôme de Master Académique

Domaine : **Sciences et Technologie**
Filière : **Electronique**
Spécialité : **Instrumentation**

Téledétection aérienne des déchets de plastiques utilisant
les images hyper-spectrales et l'apprentissage
automatique

Présenter par :

Bouchelaghem Soufyane

Sous la direction de :

Pr. Boudjehem Djalil

Juin 2022

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Remerciement

Les travaux de ce mémoire sont réalisés au niveau du laboratoire de contrôle avance, université 8 Mai 1945 en collaboration avec Pr Marco Balsi de l'université de Sapienza, Italie. Tous les images et les essais prise par Drone (indoor et outdoor) se fais par Pr Marco Balsi (2022)

Je tiens tout d'abord à remercier le bon Dieu le tout puissant et miséricordieux, qui m'a donné la force et la patience d'accomplir ce Modeste travail.

Je tiens à remercier mon encadrant Pr. Boudjehem Djalil d'avoir dirigé ce travail avec compétence et professionnalisme, ses connaissances scientifiques et son esprit d'analyse, pour tous ses conseils précieux, critiques constructives et sa disponibilité pendant la période de mise en œuvre du mémoire, tout ça m'a permis de mener à terme cette recherche.

Mes sincère remerciements à mon deuxième dirigeant Pr. Marco Balsi, professeur à l'université de Sapienza, et Pr. Paolo Fallavollita et Pr. Monica Moroni d'avoir fait l'honneur d'accepter travailler sur ses recherches et de m'inviter humblement à son laboratoire pour un stage à l'université La Sapienza.

Je tiens à remercie aussi tous les enseignants du département d'électronique télécommunication qui ont contribué à ma formation et mes collègues de classe Mouad, Oussama et Ines.

Mes vifs remerciements pour mes parents qui sont à l'origine de ma formation. À mes frères Anis et Mehdi, ma sœur Naila et mes chers amis Aimen, Ala, Abdessalem, Ilyes et Doha d'avoir été toujours à mes côtés, de croire en moi plus que personne d'autre.

Une pensée très reconnaissante pour toutes les personnes, qui ont contribué de près ou de loin directement ou indirectement dans la réussite de la réalisation de ce travail, trouvent ici le témoignage de ma profonde reconnaissance et gratitude pour leur soutien.

Dédicace

Je dédie ce travail à :

Mes chers parents Pour leur soutien, leur patience, leur sacrifice Et leur amour, vous méritez tout éloge, à mes frères et sœur, Pour leurs affections et leur encouragement qui ont toujours été là pour moi.

A ceux qui ont sacrifié, aimer, patienter, donner pour être ce que je suis maintenant, j'espérons être comme vous l'avez souhaité. Que dieu vous garde et vous bénisse.

À mes amis Aimen, Ala, Abdeslam Ilyes, Doha et tout qui m'ont aidé.

Résumé

Une solution hyperspectral basée sur les véhicules aériens sans pilote « Unmanned Aerial Vehicles UAV » pour la détection des paramètres physiologiques de plastiques a été explorée dans un cadre d'apprentissage automatique. Une gamme de mesures complémentaires ont été recueillies sur le terrain d'expérience d'imagerie, basée sur une diversité d'échantillons de polymères plastiques dans des conditions artificiel et naturel. À partir des données de l'UAV, une référence de réflectance blanche précise en position a été produite pour corriger les différences de réponse spectrale en tenant compte de la référence sombre afin de corriger les effets des variations des capteurs de caméra au fil du temps à l'aide d'un système automatisé et en mosaïque méthodologie. Les données de UAV obtenues ont ensuite été utilisées dans un cadre d'apprentissage automatique.

Deux approches ont été évaluées pour identifier les méthodes non supervisées les plus performantes (LDA et K-NN). Une étude de la stratégie d'apprentissage et de la valeur de l'utilisation des bandes spectrales comme caractéristiques de prédiction a également été effectuée à l'aide du sélecteur de caractéristiques « "mRMR" redondance minimale-pertinence maximale ». Enfin, l'utilité de l'imagerie hyper-spectrale basée sur les UAV a été démontrée en détectant les effets de la lumière solaire et de l'éclairage artificiel sur les différents polymères plastiques en estimant leur impact sur les résultats d'identification.

Abstract

A UAV-based hyperspectral solution for the detection of plastic physiological parameters was explored within a machine learning framework. To do this, an arrange of complementary measurements were collected from a field-based imaging experiment, based on a diversity of plastics polymers samples under artificial and naturel conditions. From the UAV data, positionally accurate white reflectance reference were produced to corrects spectral response differences taking the dark reference into account to corrects the effects of the camera sensor variations over time using a computationally robust automated and mosaicking methodology. The resulting UAV data were then employed into a machine learning framework.

Two approaches were evaluated to identify the best-performing non supervised methods (LDA and K-NN). An investigation of the learning strategy and the value of using spectral bands as prediction features was also performed using minimum-redundancy-maximum-relevance "mRMR" feature selector. Finally, the utility of UAV-based hyperspectral imaging was demonstrated by detecting the effects of sunlight and artificial lighting on the different plastics polymers by estimating their impact on the identification results.

Table des matières

Introduction générale.....	1
-----------------------------------	----------

Chapitre 1

La télédétection des déchets et les images hyper-spectrales

1. Introduction.....	4
2. Historique de télédictiones	4
3. Les images hyper-spectrales	4
3.1. Examinassions de la lumière réfléchie	6
3.2. Imagerie hyper-spectrale	6
3.3. Spectromètre	7
3.4. Application	7
3.5. La différence entre les camera RVB traditionnelle et les cameras hyper-spectrales	7
4. Méthode d'acquisition d'une image hyper-spectrale	8
5. Fonctionnement des caméras hyper-spectrales à balayage linéaire	11
5.1. Composant principaux de la caméras hyper-spectrales à balayage linéaire.....	11
5.1.1. L'objectif.....	11
5.1.2. Spectrographe.....	12
5.1.1.3. Caméra en niveaux gris.....	12
6. Conclusion.....	13

Chapitre 2

Apprentissage automatique et méthodes de classification

1. Introduction	14
2. Définition	14
3. Principe de fonctionnement	14
4. Les modèles de l'apprentissage automatique	15
4.1. Apprentissage supervisé	15
4.1.1 Régression	15
4.1.1.1 Régression linéaire.....	15
4.1.1.2 Arbre de décision	16
4.1.1.3 Forêt aléatoire.....	16
4.1.1.4 Réseau neuronal.....	17
4.1.2 Classification	17
4.1.2.1 Régression logistique	17
4.1.2.2 Machine vectorielle de support	17
4.1.2.3 Naïve Bayes.....	18
4.2. Apprentissage non supervisé	18
4.2.1 Le regroupement	18
4.2.2 Réduction de la dimensionalité	19
4.2.2.1 Les arbres de décision les forêts aléatoires et les réseaux neuronaux	19
5. Méthode de classification	19
5.1. Rédundance minimale pertinence maximum	19
5.2 Analyse linéaire discriminante.....	20
5.3 L'algorithme des K le plus proche voisin « K-NN ».....	21
6. Conclusion.....	22

Chapitre 3

Résultats et simulation

1. Introduction.....	23
2. partie 1	23
2.1 Phase d'apprentissage	23
2.1.1 étape 1.....	23
2.1.2 étape 2.....	24
2.2. Phase de classification	25
3. Partie 2	26
3.1. Catégorie 1 : Avec normalisation et l'élimination de bande	27
3.1.1 étape 1.....	27
3.1.2 étape 2.....	27
3.1.1 étape 3.....	27
3.2 Catégorie 2 : sans la normalisation et l'élimination des bandes.....	33
4. partie 3 : échantillons prise à l'intérieur de la laboratoire.....	39
4.1. Catégorie 1.	39
5. Conclusion.....	50
Conclusion générale.....	51
Références bibliographiques.....	52

Liste des figures

Figure 1.a : Animaux étranglés dans du plastique.....	2
Figure 1.b : Zooplancton, la base de la chaîne alimentaire marine en mangeant des microplastiques.....	2
Figure 2 : Images des sites inspectés pour les campagnes sur le terrain. Photographie satellitaire et terrestres de Platamona et Porto Ferro, Sardaigne	2
Figure 3 : Drone utilisé pour les campagnes de mesure et les détails de l'instrumentation à bord.....	3
Figure 4 : Schéma globale du fonctionnement de la détection automatique des déchets.....	3
Figure 5.a : SPECTRUM indiquant la quantité de lumière émise, réfléchi ou transmise par la cible.....	5
Figure 5.b : Spectre est un graphique sur une échelle réflectance et de longueur d'onde de deux types de polymère (PE et PET)	5
Figure 6 : Comparaison entre l'empreinte digitale et la signature spectrale.....	5
Figure 7 : Un dispositif spectral assemblé composé d'un spectromètre linéaire ImSpector NIR17 OEM (Specim, Finlande) est couplé à un Caméra SWIR (Bobcat 32 de Xenics, Belgique) de 256 320 pixels de résolution (50 images Remote Sens. 2021, 13, 1557 5 de 18 par seconde de fréquence d'acquisition maximale).....	6
Figure 8 : Spectromètre qui divise la lumière entrante dans un spectre réfléchi et les résultats sont là Réflectance SPECTRUM mesurant le Réflectance SPECTRA.....	6
Figure 9 : Un spectre complet permet d'obtenir des réponses la nature du spectre et son emplacement.....	7
Figure 10 : Caméra smartphone tire la cible en trois couleurs rouge vert et bleu.....	8
Figure 11 : PVC polymère de plastique avec une référence blanche.....	9
Figure 12 : Spectre du polymère PVC.....	9
Figure 13 : Les différentes caméras hyper-spectrales avec leur différente gamme de longueurs d'onde.....	9
Figure 14 : Les différentes caméras hyper-spectrales avec leur différente gamme de longueurs d'onde.....	9
Figure 15 : Trois minéraux (Hématite, Kaolinite et Quartz) avec leur caractéristique spectrale dans différentes gammes de longueurs d'onde pour identifier l'information.....	10
Figure 16 : L'imagerie spectrale prise dans des différents environnements.....	10
Figure 17 : Caméras hyper-spectrales à balayage linéaire.....	11
Figure 18 : Les composants clés d'une caméra hyper-spectrale à balayage linéaire.....	11
Figure 19 : Projection de l'objectif sur la cible et le capteur de la caméra et l'enregistrement d'image en résultat d'un feuillet noir et blanc.....	12
Figure 20 : Spectrographe d'imagerie.....	12
Figure 21 : Caméra en niveaux de gris et l'emplacement de chaque information spectrale.....	13
Figure 2.1 : Graph présente la régression linéaire.....	16
Figure 2.2 : Graph présente l'arbre de décision.....	16
Figure 2.3 : Graph présente la forêt aléatoire.....	16
Figure 2.4 : Graph présente la régression linéaire.....	17
Figure 2.5 : Graph présente la régression logistique.....	17
Figure 2.6 : Graph présente la machine vectorielle de support.....	18
Figure 2.7 : Graph présente la Naïve Bayes.....	18
Figure 2.8 : Graph présente le regroupement.....	19

Figure 2.9 : L'utilisation de l'analyse discriminante sur les observations pour déterminer l'emplacement d'une limite entre les classes de réponse.....	20
Figure 2.10 : L'analyse discriminante linéaire.....	21
Figure 2.11 : Plus proches voisins (K-Nearest Neighbors « K-NN »).....	22
Figure 3.1 : Phase d'apprentissage.....	23
Figure 3.2 : Un cube contient les images de différentes couches en trois dimensions.....	24
Figure 3.3.a : Spectre de deux polymère PE et PET avec l'élimination des bandes non utiles.....	24
Figure 3.3.b : Les différentes classes de la détection (rouge plastique, noir non plastique).....	24
Figure 3.4 : Emplacement des objets pour la phase de classification.....	25
Figure 3.5.a : Identification de polymère PE.....	25
Figure 3.5.b : Identification de polymère PE.....	26
Figure 3.6 : Phase d'apprentissage (indoor).....	27
Figure 3.7.a : Les spectres avant la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	28
Figure 3.7.b : les spectres après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	28
Figure 3.8_3.17 : Les spectres normalisé de chaque polymère détecté.....	28
Figure 3.18_3.27 : Les classes de séparation après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	30
Figure 3.28_3.38 : Les résultats après na normalisation de tous les échantillons utilisés dans la phase de classification.....	31
Figure 3.39_3.48 : Les spectres sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	33
Figure 3.49_3.58 : Les classes de séparation sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage	35
Figure 3.59_3.68 : Les résultats sans la normalisation de tous les échantillons utilisés dans la phase de classification.....	37
Figure 3.69_3.78 : Les résultats de K-NN de tous les échantillons utilisés dans la phase de classification	38
Figure 3.79: Phase d'apprentissage (outdoor).....	39
Figure 3.80.a : Les spectres avant la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	40
Figure 3.80.b : Les spectres après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	40
Figure 3.81_3.90 : Les spectres normalisés de chaque polymère détecté.....	40
Figure 3.91_3.100 : Les classes de séparation après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage	42
Figure 3.101_3.110 : Les résultats après la normalisation de tous les échantillons utilisés dans la phase de classification.....	43
Figure 3.111_3.121 : Les spectres sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	45
Figure 3.122_3.131 : Les classes de séparation sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage	47
Figure 3.132_3.41 : Les résultats sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.....	49

Liste d'abréviations

MRMR	Minimum-Redundancy-Maximum-Relevance
LDA	Linaire Discriminante Analysis
K-NN	K Nearst Neighbor
UVA	Unmanned Vehicle Ariel
RVB	Rouge Vert Blue
PVC	Polymère Chlorure de Vinyle
PET	Polymère Téréphtalate d'Éthylène
PLA	Polymère d'Acide Lactique
PC	Polymère Carbonates
PE	Polymère Éthylène
PP	Polymère Propylène

Introduction Générale

Les plastiques sont partout, de la nourriture à l'eau, et même dans notre corps, ce qui rend difficile de comprendre la vie moderne sans eux. Il est estimé que de 8 à 10 millions de tonnes de déchets plastiques entrent dans nos océans chaque année, ce qui a des effets dévastateurs sur diverses espèces marines. Des images de nombreux animaux qui étaient étranglés ou empêtrés dans du plastique (Figure 1.a). De plus, ces déchets plastiques se décomposent en minuscules morceaux appelés microplastiques, qui peuvent causer de graves dommages à de nombreuses espèces marines. Les microplastiques sont si répandus qu'ils ont été découverts dans la région la plus profonde de l'océan, la fosse Mariana [2], et le zooplancton, la base de la chaîne alimentaire marine, ont été attrapés en mangeant des microplastiques (Figure 2.b). Des microplastiques ont même été découverts dans le placenta humain et les systèmes digestifs [3]. C'est un problème grave qui nécessite une attention immédiate. Depuis 1950 sur ces neuf milliards de tonnes près de 79% a été accumulé dans les décharges ou l'environnement naturel avec le reste étant recyclé ou brûlé. Le taux mondial de fabrication de plastique a augmenté de façon exponentielle, atteignant aujourd'hui plus de 350 millions de tonnes par an [4], en supposant que le statu quo se poursuive, ce taux devrait augmenter.

Le plastique est composé de polymères, qui est l'une des raisons pour lesquelles ne peut pas être décomposé pendant des centaines sinon des milliers d'années, ses composants sont à 99 % de combustibles fossiles, pour cela c'est essentiellement un plan de secours pour les combustibles fossiles si nous pouvons réussir à faire passer notre industrie énergétique à 100 % d'énergie renouvelable. En ce qui concerne la consommation de plastique par habitant, des pays comme les Italie, États-Unis, l'Allemagne, la Norvège et même Algérie ouvrent la voie, mais en ce qui concerne la pollution par le plastique, les pays d'Asie du Sud-Est, L'Afrique subsaharienne et l'Afrique du Nord sont en tête car les pays en développement ne disposent pas des infrastructures de gestion des déchets nécessaires pour maîtriser la pollution plastique [5]. À l'heure actuelle, seulement 20 rivières sont responsables de près de 70 % de la pollution des océans par le plastique. En raison du manque d'infrastructures de gestion des déchets, ces sites sont très courants dans de nombreux pays en développement à travers le monde. La plupart de ces déchets de plastique finissent d'abord près des côtes en raison des rejets de la rivière dans les océans. Au fil du temps, ces déchets plastiques s'accumulent dans des courants océaniques circulaires appelés Gyres, dont le plus connu est le Great Pacific Garbage Patch [6], qui est plus grand que Tamanrasset (la plus grande ville algérienne avec 557,906 km²), pour la plupart, cette pollution n'est pas visible à l'œil nu, Il est difficile pour les gouvernements ou les organisations de suivre les lieux de la pollution plastique côtière, et nous devons nous éloigner des plastiques à usage unique pour la commodité, Par conséquent, des moyens novateurs, rentables et à long terme de surveiller la prévalence des plastiques dans

l'environnement maritime sont nécessaires, et pour cela une procédure efficace de surveillance automatique sur mesure est développée pour identifier les lieux de pollution marine et faciliter les efforts de nettoyage des océans (Figure 2), grâce à l'imagerie hyperspectrale de véhicules aériens sans pilote « Drone » (Figure 3) [1]. Les images hyperspectrales reçues par le drone sont traitées à l'aide des algorithmes de l'intelligence artificielle (classifieurs) pour une décision finale qui porte sur la présence ou l'absence des polymères dans la zone en question.

Dans notre cas nous avons utilisé le KNN et le LDA pour la classification des données.



Figure 1 : (a) Animaux étranglés dans du plastique. (b) zooplancton.



Figure 2 : Images des sites inspectés pour les campagnes sur le terrain. Photographies satellitaires et terrestres de Platamona et Porto Ferro, Sardaigne, Italie.




Figure 3 : Drone utilisé pour les campagnes de mesure et les détails de l'instrumentation à bord.




Figure 4 : Schéma globale du fonctionnement de la détection automatique des déchets

Chapitre 01 : La télédétection des déchets et les images hyper-spectrales

1. Introduction :

Télédétection est un mot technique pour obtenir des informations sur un objet ou un phénomène sans établir de contact physique avec lui et l'ensemble des techniques qui permettent, par l'acquisition d'images, d'obtenir de l'information sur la surface de la Terre (y compris l'atmosphère et les océans), sans contact direct avec celle-ci. La télédétection englobe tout le processus qui consiste à capter et enregistrer l'énergie d'un rayonnement électromagnétique émis ou réfléchi, à traiter et analyser l'information qu'il représente, pour ensuite mettre en application cette information [7]. Télédétection est une discipline scientifique qui rassemble toutes connaissances et techniques d'observation, d'analyse, d'interprétation Gestion de l'environnement basée sur des mesures et des images obtenues à l'aide de plateformes aéroportées, spatiales, terrestres ou maritimes (Bonn, 1993). Comme son nom l'indique, il suppose un accès à distance à l'information sans contact direct avec des objets détectés. Sa définition officielle est : « C'est l'ensemble des connaissances et des techniques pour déterminer les propriétés physiques et Mesurer des objets avec des mesures effectuées à distance sans contact avec le matériau celles-ci » (CCT, 2018).

2. Historique de télédiction :

De 1856, date à laquelle, pour la première fois, un appareil photographique a été installé de façon fixe à bord d'un ballon, à la première guerre mondiale, se déroule l'époque des pionniers, pendant laquelle sont explorées les possibilités de la photographie aérienne verticale pour la cartographie ; les lois fondamentales de la stéréoscopie et de la photogrammétrie sont découvertes à la fin du XIXe siècle [8], puis a connu un essor considérable au XIX siècle, intègre les développements les plus récents de la recherche spatiale, de la physique et de l'informatique pour constituer aujourd'hui l'un des outils les plus puissants et les plus flexibles pour la gestion du milieu, la planification et le développement économique.

3. Les images hyper-spectrales :

Une bonne façon de travailler avec des matériaux tels que des débris de plastique pour les identifier ou définir les propriétés cibles est d'étudier comment la lumière interagit avec eux. Cette étude des matériaux d'interactions de lumière est appelée SPERCTROSCOPY, la SPERCTROSCOPY examine comment la lumière se comporte dans la cible et reconnaît les matériaux en fonction de leurs différentes signatures spectrales ou ils peuvent être identifiées à partir du spectre du matériau. Le Spectrum décrit la quantité de lumière dans différentes longueurs d'onde et indique la quantité de lumière émise, réfléchie ou transmise par la cible (figure 4). Le Spectre indique la quantité de certaine couleur que cette lumière contient, la façon habituelle de présenter le spectre est un graphique sur une échelle d'intensité et de longueur d'onde (figure 5.a).



Figure 4 : Spectrum indiquant la quantité de lumière émise, réfléchie ou transmise par la cible




Figure 5 : (a) spectre graphique sur une échelle d'intensité et de longueur d'onde. (b) spectre graphique sur une échelle réflectance et de longueur d'onde de deux types de polymère (PE et PET).

Les signatures spectrales peuvent être comparées aux empreintes digitales, tout comme les empreintes digitales peuvent être utilisées pour identifier une personne, la signature spectrale peut être utilisée pour identifier des matériaux (figure 6).




Figure 6 : comparaison entre l'empreinte digitales et la signature spectrale.

3.1 Examinactions de la lumière réfléchié :

Pour étudier la lumière, on a besoin d'un instrument appelé spectromètre (figure 7) [1] tel que l'utiliser pour recueillir les données de l'expérience décrite au chapitre trois. C'est un instrument qui divise la lumière entrante dans un spectre, la lumière allant à un spectromètre est réfléchié et les résultats sont la Réflectance Spectrum (figure 8).




Figure 7 : Un dispositif spectral assemblé composé d'un spectromètre linéaire ImSpector NIR17 OEM (Specim, Finlande) est couplé à un Caméra SWIR (Bobcat 32 de Xenics, Belgique) de 256 320 pixels de résolution (50 images Remote Sens. 2021, 13, 1557 5 de 18 par seconde de fréquence d'acquisition maximale).




Figure 8 : spectromètre qui divise la lumière entrante dans un spectre réfléchié et les résultats sont là Réflectance SPECTRUM mesurant le Réflectance SPECTRA

3.2. Imagerie hyper-spectrale :

L'imagerie hyper-spectrale ou spectraux-imagerie est une technologie permettant d'obtenir l'image d'une scène dans un grand nombre de bandes spectrales. Elle permet en premier lieu de déterminer la composition chimique d'une surface photographiée et en fournit des indications sur la concentration de ceux-ci et les propriétés physiques. Elle est également utilisée dans différents processus industriels principalement pour la détermination de la qualité des produits. L'imagerie hyper-spectrale est utilisée dans les prises d'images réalisées à bord d'avion depuis les années 1990 et à bord de satellites d'observation depuis la fin des années 2000 [9].

3.3. Spectromètre :

à l'aide d'un spectromètre d'imagerie également appelé caméra hyper-spectrale, on recueille des informations Spectraux, avec cette dernière nous mesurons des centaines de milliers de spectres au lieu d'un spectre unique, les spectres collectés sont utilisés pour former une image de la cible, de sorte que chaque pixel d'image inclut un spectre complet (figure 9), ce qui nous permet d'obtenir des réponses aux questions « quoi », en fonction du spectre et où, en fonction de l'emplacement. Nous pouvons choisir n'importe quelle position de la cible pour obtenir des informations qui signifient une grande quantité d'informations exactes. Les données fournies par l'imagerie hyper-spectrale sont appelées un cube de données car les données hyper-spectrales sont tridimensionnelles (figure 3.2).




Figure 9 : un spectre complet permet d'obtenir des réponses la nature du spectre et son emplacement

3.4. Applications :

Une image hyperspectral fournit pour chaque pixel une caractéristique du matériau photographié qui prend la forme d'un vecteur à plusieurs centaines de dimensions (autant que de bandes spectrales). Les applications sont nombreuses :

- Domaine de l'agriculture : détermination du stress hydrique, détection de parasites.
- Domaine environnemental : détection et suivi de la pollution, mesure de la qualité de l'air.
- Domaine de l'astrophysique : caractérisation des étoiles et des exoplanètes.
- Domaine culturel : analyse d'œuvres d'art (peintures, fresques) pour restauration.
- Domaine Industrie alimentaire : contrôle qualité, identification de matériaux étrangers
- Industrie minière, analyse des roches Industrie papetière et contrôle qualité du papier [9].

3.5. La différence entre les caméras RVB et les caméras hyper-spectrales :

La caméra hyper-spectrale est utilisée pour recueillir un cube de données comme expliquée précédemment et nous allons découvrir comment les données d'image se diffère entre les types de caméras numérique et hyperspectral.

La caméra smartphone tire la cible en trois couleurs rouge vert bleu ou la combinaison de ces trois couleurs nous donne une image correspond à la vision humaine (figure 10), ces couleurs qui sont en fait de larges canaux de longueur d'onde sont égales à la quantité d'information qui est enregistrée.




Figure 10 : caméra smartphone tire la cible en trois couleurs rouge vert et bleu

Pour la caméra hyper-spectrale la cible est enregistrée de dizaines à des centaines de canaux de couleur étroite (longueurs d'onde). La quantité de longueurs d'onde dépend entièrement de quel type de caméra hyper-spectrale est utilisé. Dans la plupart des cas, la caméra hyper-spectrale recueille des informations également à partir des longueurs d'onde invisibles de la vision humaine. La caméra hyper-spectrale mesure la cible en chaque longueur d'onde qui est localisée et la gamme spectrale des caméras hyper-spectrales créant un spectre complet pour chaque pixel de la cible, l'information spectrale complète recueillie est polyvalente pour la détection d'analyse et l'identification de divers matériaux et composés et tous avec une seule mesure l'imagerie hyper-spectrale.

La spectaux-imagerie combine deux techniques de télédétection, l'imagerie et la spectrométrie. L'imagerie enregistre la distribution spatiale d'un flux énergétique issu de phénomènes de réflexion ou/et d'émission thermique d'un milieu. La spectrométrie mesure les variations.

Dans le domaine électromagnétique du flux énergétique, dépendant de la composition chimique de l'objet observé à laquelle s'ajoute la température de surface dans le domaine émissif. La spectaux-imagerie délivre ainsi une image complexe de trois dimensions dont, deux dimensions représentent l'information spatiale et la troisième l'information spectrale. La richesse de l'information spectrale nécessite pour une bonne interprétation des mesures, une connaissance précise des phénomènes physiques à observer et une maîtrise des moyens à mettre en œuvre pour extraire la caractéristique recherchée

4. Méthodes d'acquisition d'une image hyperspectral :

Plusieurs techniques peuvent être utilisées pour l'acquisition d'une image hyper-spectrale dans le domaine optique (lumière visible et infrarouge). L'instrument dispose d'une optique qui fournit une image à l'entrée d'un spectrographe. Ce dernier utilise un élément dispersif ou à transformation de Fourier [9].

Pour enregistrer des données avec une caméra hyper-spectrale, les éléments clés à prendre en considération sont un éclairage approprié et une référence de réflectance, qui dans la plupart des cas comme le notre une référence blanche (figure 11). Les spectres que nous avons obtenue pour notre cible (déchet de plastique de type polymère PVC) (figure 12) dépendent de la caméra hyper-spectrale utiliser, dans notre cas nous avons utilisé un spectromètre linéaire ImSpector NIR17 OEM (Specim,, couplé à une caméra SWIR (Bobcat 32 de Xenics) d'une résolution de 256 320 pixels (50 images Remote Sens. 2021, 13, 1557 5 de 18 fréquences d'acquisition maximale par seconde) (figure 7).




Figure 11 : Un polymère de plastique PVC avec une référence blanche




Figure 12 : Spectre du polymère PVC

4.1 Les types de cameras hyper-spectrales :

Il existe plusieurs caméras hyper-spectrales avec différentes gammes de longueurs d'onde (figure 13). Si la même cible est captée avec deux caméras hyper-spectrales qui ont des gammes de longueurs d'onde différentes, les spectres acquis vont montrer différentes caractéristiques spectrales (figure 14). Différents matériaux et composés ont des caractéristiques spectrales dans différentes longueurs d'onde et une caméra hyper-spectrale ne pas apportera pas une solution à chaque problème.




Figure 13 : les différentes caméras hyper-spectrales avec leur différente gamme de longueurs d'onde.




Figure 14 : les différentes caméras hyper-spectrales avec leur différente gamme de longueurs d'onde.

Un exemple de trois minéraux ont des caractéristiques spectrales dans différentes gammes de longueurs d'onde (figure 15), les caractéristiques plates ne comprennent pas d'informations d'identification alors que les pics et les formes le font, c'est pourquoi il est important de sélectionner une caméra avec une plage de longueurs d'onde idéale pour notre cible.




Figure 15 : trois minéraux (Hématite, Kaolinite et Quartz) avec leurs caractéristiques spectrales dans différentes gammes de longueurs d'onde pour identifier l'information.

Étant donné que les caméras hyper-spectrales mesurent la lumière réfléchiée à partir de la cible, il est important d'utiliser un type d'éclairage approprié, la cible devrait être uniformément éclairée et la lumière devrait avoir une réponse spectrale qui correspond à la gamme de longueurs d'onde des caméras hyper-spectrales.

La source de lumière la plus typique sont les lumières halogènes et la lumière du soleil dans certains cas LED et sources thermiques peuvent être utilisés.

Dans l'imagerie numérique classique, le photographe a besoin de prendre l'équilibre des couleurs en considération ce qui est souvent fait en utilisant la carte grise, de la même manière les effets de l'environnement variée dans l'imagerie hyper-spectrale (figure 16), c'est pourquoi les données enregistrées doivent être équilibrées avec les informations de la référence de réflectance qui est généralement une référence blanche (figure 11).



Figure 16 : L'imagerie spectrales prise dans des différents environnements.

La référence blanche peut être par exemple un panneau qui est inclus dans l'image, mesurant la référence de réflectance corrige également les différences de réponse spectrale entre les caméras hyper-spectrales, en plus la référence de réflectance également prendre la référence sombre en compte, elle corrige les effets des variations du capteur de caméra au fil du temps.

Dans certains produits de caméra hyper-spectrale la référence sombre est recueillie automatiquement, d'autres nécessitent des actions de l'utilisateur. À la fin nous obtiendrons les spectres de réflectance de la cible en corrigeant les données avec des références ou une procédure de calcul appelée transformation de réflectance, ce calcul rend les données enregistrées dans différents environnements comparable.

5. Fonctionnement des caméras hyper-spectrales à balayage linéaire :

Il existe différentes façons de recueillir des données hyper-spectrales, les SPECIMS sont des caméras hyper-spectrales à balayage linéaire (figure 17) elles collectent des informations spectrales et spatiales complètes de la cible ligne par ligne, les lignes imagées ensemble fournissent l'image spectrale finale qui est également appelé un cube de données parfois le terme balai-brosse (push-broom) est utilisé pour la même technologie.

Collection des spectres et les informations spatiales de la cible ligne par ligne




Figure 17 : caméras hyper-spectrales à balayage linéaire.

5.1 Composants principaux de la caméra hyper-spectrale à balayage linéaire :

Les composants clés d'une caméra hyper-spectrale à balayage linéaire sont :

Un spectrographe d'imagerie, une caméra en niveaux de gris et un objectif (figure 18), tous ces composants doivent être optimisés pour la gamme de longueurs d'onde des caméras.




Figure 18 : les composants clés d'une caméra hyper-spectrale à balayage linéaire.

5.1.1. L'objectif :

Lors de l'enregistrement d'une image normale en noir et blanc, nous aurons besoin que l'objectif et la caméra. L'objectif projette la cible sur le capteur de la caméra où l'image est enregistrée pour la comparer avec notre illustration, les résultats est un feuillet noir et blanc (figure 19).



Figure 19 : Projection de l'objectif sur la cible et le capteur de la caméra et l'enregistrement d'image en résultat d'un feuillet noir et blanc.

5.1.2. Spectrographe :

Une fois que le spectrographe d'imagerie est ajouté nous pouvons enregistrer des données hyper-spectrales. Le spectrographe d'imagerie contient une fente d'entrée, accommodant une unité dispersive et une lentille de mise au point, l'objectif forme une image à la fente d'entrée la fente d'entrée limite l'information entrante, à travers elle l'information ne passe qu'à partir d'une seule ligne, en raison de ce composant, ces caméras sont des caméras de balayage en ligne (figure 20). La fente d'entrée est nécessaire pour mesurer des spectres précis, le plus étroit la fente le plus précis spectres vous obtenez. L'optique culminante direction culmine la lumière de la fente à l'unité dispersive, avec l'unité dispersive la lumière entrante se propage dans les spectres, la lentille de mise au point est nécessaire pour concentrer l'image à la caméra en niveaux de gris.




Figure 20 : spectrographe d'imagerie.

5.1.3. Caméra en niveaux de gris :

La caméra en niveaux de gris est utilisée pour mesurer l'intensité de la lumière dispersée, lorsque on a une image spectrale, chaque ligne dans cette image contient des informations d'intensité d'une longueur d'onde différente, les lignes ensemble fournissent le spectre complet de sorte que chaque colonne contient le spectre d'un emplacement.

Voici comment la technologie peut fournir des réponses à des questions sur « quoi » basé sur le spectre et « où » basé sur l'emplacement unique (figure 20).




Figure 21 : Caméra en niveaux de gris et l'emplacement de chaque information spectrale.

6. Conclusion :

Dans ce chapitre nous avons présenté les images hyper-spectrales ainsi que ses compositions. Dans notre projet nous avons utilisé des images hyper-spectrales obtenue par une caméra de type SWIR (Bobcat 32 de Xenics) de 256 320 pixels de résolution (figure 7).

Chapitre 02 : apprentissage automatique et méthodes de classification

1. Introduction :

Notre capacité d'apprendre et de nous améliorer dans les tâches c'est grâce à l'expérience qui fait partie de l'être humain. Quand nous naissons nous ne savons presque rien et ne pouvons presque rien faire pour nous-mêmes mais bientôt nous apprenons et devenons capables de minerai chaque jour , mais saviez-vous que les ordinateurs peuvent faire de même ? comme la technologie évolue et que la population mondiale augmente, la quantité de données générées qui sont recueillies, triées et analysées peut prendre beaucoup de temps, mais cela commence à changer avec l'utilisation croissante de l'intelligence artificielle dans notre vie quotidienne et l'émergence de ce qu'on appelle l'apprentissage automatique. C'est un domaine de technologie qui permet aux machines d'apprendre des données et de s'améliorer. L'apprentissage automatique existe depuis longtemps dans le passé et les ordinateurs ne pouvaient faire que ce pour quoi nous les avons programmés, mais avec l'apprentissage automatique, ils peuvent se comporter comme des humains et acquérir des connaissances basées sur leurs expériences passées et devenir de plus en plus utiles et pertinents en trois raisons, Il y a d'abord plus de données que jamais, avant que les ordinateurs ne soient plus puissants qu'ils ne l'étaient et troisièmement nous avons de meilleurs algorithmes d'apprentissage automatique.

2. Définition :

L'apprentissage automatique ou machine Learning est un domaine scientifique plus particulièrement une sous-catégorie de l'intelligence artificielle. Elle consiste à laisser des algorithmes découvrir des motifs " patterns ", et a récurrents les ensembles de données. Ces données peuvent être des chiffres, des mots, des images, des statistiques...etc. Tout ce qui peut être stocké numériquement peut servir de données pour le Machine Learning. En décelant les patterns dans ces données, les algorithmes apprennent et améliorent leurs performances dans l'exécution d'une tâche spécifique.

Pour résumer, les algorithmes de Machine Learning apprennent de manière autonome à effectuer une tâche ou à réaliser des prédictions à partir de données et améliorent leurs performances au fil du temps. Une fois entraîné, l'algorithme pourra retrouver les patterns dans de nouvelles données [10].

3. Principe de fonctionnement :

Le développement de modèles d'apprentissage automatique repose sur quatre étapes principales.

a) La première étape consiste à sélectionner et à préparer l'ensemble de données d'entraînement. Ces données sont utilisées pour alimenter des modèles d'apprentissage automatique afin d'apprendre à résoudre des problèmes conçus. Nous pouvons étiqueter les données et indiquer au modèle les caractéristiques que nous souhaitons identifier. Ils peuvent être non étiquetés et le

modèle doit reconnaître et extraire les caractéristiques récurrentes de lui-même. Dans les deux cas, nos données doivent être soigneusement préparées, organisées et nettoyées. Ne pas le faire peut fausser la formation des modèles d'apprentissage automatique. Les résultats de ses prédictions futures sont directement affectés.

b) La deuxième étape consiste à choisir l'algorithme à exécuter sur l'ensemble de données d'apprentissage. Le type d'algorithme que nous utilisons dépend du type et de la quantité de données d'entraînement et du type de problème que nous résolvons.

c) La troisième étape est la formation à l'algorithme. Il s'agit d'un processus itératif. La variable passe par l'algorithme et le résultat est comparé à ce qu'il devrait produire. Ensuite ajuster les "pondérations" et les écarts pour améliorer la précision des résultats. Réexécutons ensuite la variable jusqu'à ce que l'algorithme renvoie le résultat correct dans la plupart des cas. Un algorithme entraîné de cette manière est un modèle d'apprentissage automatique.

d) La quatrième et dernière étape est l'utilisation et l'amélioration du modèle. Appliquons ce modèle aux nouvelles données. Son origine dépend du problème à résoudre. Par exemple, un modèle d'apprentissage automatique est appliqué à la détection de spam par courriel ou comme notre cas la détection de plastique. L'efficacité et la précision peuvent également s'améliorer avec le temps [10].

4. Les modèles d'apprentissages automatique :

Les modèles d'apprentissage automatique peuvent être classés en deux types supervisés ou non supervisés :

4.1 Apprentissage supervisé :

Il s'agit d'une série de fonctions qui mappe une entrée à une sortie, basée sur une série d'exemples, paires d'entrées-sorties, qui se définit par l'utilisation d'ensembles de données étiquetées. Ces ensembles de données sont conçus pour former les algorithmes afin qu'ils classent les données ou prédisent les résultats avec précision [11], par exemple, si nous avons un ensemble de données de deux variables, l'une étant l'âge, qui est l'entrée et l'autre étant la taille de la chaussure comme sortie, nous pourrions mettre en œuvre un modèle d'apprentissage supervisé pour prédire la taille de la chaussure d'une personne en fonction de son âge, avec un apprentissage supervisé on se consiste de deux sous-catégories, régression et classification :

4.1.1 Régression

Dans le modèle de relation, nous trouvons une valeur cible basée sur des prédictors indépendants qui signifie que nous pouvons l'utiliser pour trouver la relation entre une variable dépendante et une variable indépendante dans les modèles de régression.

4.1.1.1 Régression linéaire : Il s'agit simplement de trouver une ligne qui correspond aux données et ses extensions comprennent une régression linéaire multiple qui trouve un plan de meilleur ajustement et une régression polynomiale qui trouve une courbe pour le meilleur ajustement.




Figure 2.1 : Graph présente la régression linéaire

4.1.1.2 Arbre de décision : elle Permet d'établir prédictions basées sur un ensemble de règles de décisions en se basant sur des données classifiées. Par exemple, il est possible de prédire le temps en se basant sur des données telle que l'humidité et le vent.




Figure 2.2 : Graph présente l'arbre de décision.

4.1.1.3 forêt aléatoire : il s'agit de techniques d'apprentissage assemblées qui s'appuient sur des arbres de décision et impliquent la création de multiples arbres de décision à l'aide d'ensembles de données Bootstrap de données originales et la sélection aléatoire d'un sous-ensemble de variables à chaque étape de l'arbre de décision que le modèle sélectionne ensuite le mode de toutes les prédictions de chaque arbre de décision et en s'appuyant sur le modèle des vents majoritaires, il réduit le risque d'erreur de chaque arbre.



Figure 2.3 : Graph présente la forêt aléatoire.

4.1.1.4 Réseau neuronal : est un modèle multicouche très connu, inspiré par les esprits humains comme les neurones dans notre cerveau le cercle représente un nœud, le cercle bleu représente une couche d'entrée le cercle noir représente une couche cachée, et le cercle vert représente la couche de sortie chaque nœud dans la couche cachée représente une fonction que l'entrée passe par finalement menant à la sortie dans les cercles verts.




Figure 2.4 : Graph présente la régression linéaire

4.1.2 Classifications :

Dans la classification, la production est distincte de certains des types les plus courants de modèles de classification, notamment :

4.1.2.1 Régression logistique : c'est l'semblable à la régression linéaire, mais qui est utilisée pour modéliser la probabilité d'un nombre fini de résultats généralement deux, les valeurs de sortie ne peuvent être comprises qu'entre 0 ou 1.




Figure 2.5 : Graph présente la régression logistique

4.1.2.2 Machine vectorielle de support : est une technique de classification supervisée qui a pour objectif de trouver une voie hyper dans l'espace n-dimensionnel qui peut classer distinctement les points de données.




Figure 2.6 : Graph présente la machine vectorielle de support.

4.1.2.3 Naïve Bayes: c'est un classificateur qui agit comme un modèle probabiliste d'apprentissage automatique utilisé pour les tâches de classification le nœud du classificateur est basé sur le théorème de Bayes.




Figure 2.7 : Graph présente la Naïve Bayes.

4.2 Apprentissage non supervisé :

Contrairement à l'apprentissage supervisé, l'apprentissage non supervisé est utilisé pour tirer des inférences et trouver des modèles cachés à partir de données d'entrée sans référence au résultat étiqueté données sans nécessiter d'intervention humaine [11]. Les deux principales méthodes utilisées dans l'apprentissage non supervisé comprennent le regroupement et la réduction de la dimensionnalité :

4.2.1 Le regroupement: comprend le regroupement des points de données qu'il est fréquemment utilisé pour la détection de la fraude par segmentation de la clientèle et la classification des documents. Le regroupement hiérarchique signifie le regroupement de formes et le regroupement basé sur la densité, tandis que chaque technique utilise des méthodes différentes pour trouver des grappes.




Figure 2.8 : Graph présente le regroupement

4.2.2 Réduction de la dimensionalité : Il s'agit d'un processus de réduction des dimensions de votre ensemble de fonctionnalités Auto States simplement analyse ou PCA évidemment il y a une tonne de complexité si nous plongeons dans un modèle particulier.

4.2.2.1 Les arbres de décision les forêts aléatoires et les réseaux neuronaux : Ces modèles suivent la même logique que précédemment expliquée la seule différence c'est que la sortie est discrète plutôt que continue.

5. Méthodes de classification :

5.1 Redondance minimale pertinence maximale :

Avec l'avènement des problèmes à grande échelle, la sélection des caractéristiques est devenue une étape de prétraitement fondamentale pour réduire la dimensionnalité des entrées. Le sélecteur minimum-redondance-maximum-pertinence (mRMR) est considéré comme l'une des méthodes les plus pertinentes pour la réduction de la dimensionalité en raison de sa grande précision. Il s'agit d'une sélection de caractéristiques, visant à identifier un sous-ensemble de caractéristique parmi un ensemble éventuellement important de fonctionnalités qui sont pertinentes pour prédire une réponse, est une étape de prétraitement importante dans l'apprentissage automatique [12].

La technique d'imagerie hyper-spectrale a montré la capacité de discerner la matière plastique, mais sa grande quantité d'information qui est principalement corrélée et redondante limite la précision de la classification et la vitesse de traitement. Avec la méthode de sélection des caractéristiques (algorithme de redondance minimale pertinence maximale), nous pouvons sélectionner les longueurs d'onde optimales à partir du spectre visible au proche infrarouge des données d'imagerie hyper-spectrale pour la classification des matières plastiques. Un ensemble de données spectrales contenant deux échantillons PE et PET a été prélevé à partir d'images de réflectance hyper-spectrale. Chaque polymère plastique présente des bandes d'absorption étroites spécifiques dans l'onde courte Spectre infra-rouge (InfraRed (SWIR)) et les principaux pics d'absorption sont situés à des longueurs d'onde de 1130 nm, 1170 nm, 1420 nm et 1660 nm pour la PET et 1040 nm, 1210 nm, 1420 nm et 1540 nm pour le PE. L'ensemble de données a été prétraité en supprimant le bruit, et le nombre de longueurs d'onde a été réduit à le range de 900-1700 nm[1], en supprimant ceux dont les longueurs d'onde optimales ont été sélectionnées à partir de l'ensemble de données prétraité par une

approche qui consiste à classer les caractéristiques à l'aide de l'algorithme « redondance minimale pertinence maximale » et à fournir uniquement les caractéristiques les mieux classées pour la sélection des caractéristiques suivantes. La généralité des longueurs d'onde sélectionnées a été évaluée en comparant les performances de classification à l'aide de l'analyse linéaire discriminante (LDA). Au total, 12 longueurs d'onde (selon nos choix) ont été choisies comme caractéristiques optimales pour la classification des matières étrangères [1]. Cette étude a exploré une nouvelle méthode d'imagerie hyper-spectrale pour la sélection des longueurs d'onde optimales et les longueurs d'onde sélectionnées peuvent être utilisées avec différents classificateurs pour les matières étrangères de plastique classification.

5.2 Analyse linéaire discriminante (LDA) :

L'analyse discriminante « Lineare Discriminant Analysis » utilise les observations de formation pour déterminer l'emplacement d'une limite entre les classes de réponse, l'emplacement de la limite est déterminé en traitant les observations de chaque classe comme des échantillons à partir d'une distribution dimensionnelle normale. Théoriquement nous pourrions adapter un N-distribution normale dimensionnelle aux observations dans chaque classe. Cela implique de calculer le vecteur moyen « μ » pour déterminer le centre et la matrice de covariance « Σ » pour la forme de la distribution de chaque classe respectivement. Après avoir ajusté les distributions on peut tracer une limite entre les classes en déterminant l'ensemble de points où les probabilités sont des observations égales. D'un côté de la limite serait classé comme une classe observations (jeune) et de l'autre côté comme une autre classe (vert). Nous pouvons faire tout cela théoriquement résultant en une équation pour la limite qui dépend des paramètres de la distribution ajustée « $f(x)$ », cela signifie que nous n'avons pas vraiment besoin de passer par tout le processus pour effectuer une analyse discriminante nous avons juste besoin de calculer les moyens et les covariances et d'appliquer la formule pour la limite [13].




Figure 2.9 : L'utilisation de l'analyse discriminante sur les observations pour déterminer l'emplacement d'une limite entre les classes de réponse.

Pour le cas de nos distributions ils ont toutes la même forme (figure 3), alors les mêmes matrices de covariance, donc les formules simplifient grandement, les limites s'avèrent linéaires et les

coefficients de ces limites linéaires sont facilement calculés à partir des moyennes de classe individuelle et la matrice de covariance partagés par les observations, ce qui rend l'analyse discriminante linéaire rapide et facile à effectuer. Mais en utilisant le Matlab on ne doit rien calculer, car LDA est déjà implémenté en Matlab il se fait juste d'exécutée instructions directement.




Figure 2.10 : l'analyse discriminante linéaire.

5.3 L'algorithme des K plus proches voisins (K-Nearest Neighbors « K-NN » :

C'est une approche de la classification des données qui estime la probabilité qu'un point de données soit membre d'un groupe ou de l'autre selon le groupe dans lequel se trouvent les points de données les plus proches. Le voisin k le plus proche est un exemple d'algorithme "paresseux", ce qui signifie qu'il ne construit pas un modèle en utilisant l'ensemble de formation jusqu'à ce qu'une requête de l'ensemble de données soit effectuée.

Un voisin k-le plus proche est un algorithme de classification des données qui tente de déterminer dans quel groupe se trouve un point de données en examinant les points de données qui l'entourent, en regardant un point sur une grille, essayant de déterminer si un point est dans le groupe A ou B, regarde les états des points qui sont près de lui. La fourchette est déterminée arbitrairement, mais il s'agit de prendre un échantillon des données. Si la majorité des points se trouvent dans le groupe A, il est probable que le point de données en question sera A plutôt que B, et vice versa.

L'algorithme "K-NN" ne génère pas de modèle de l'ensemble de données au préalable. Les seuls calculs qu'il fait sont quand il est demandé de sonder les voisins du point de données. Cela rend K-NN très facile à mettre en œuvre pour l'exploration de données [14].




Figure 2.11: K plus proches voisins (K-Nearest Neighbors « K-NN »).

6. Conclusion :

Dans ce chapitre nous avons présenté le principe d'apprentissage automatique avec ses différents modèles et méthode de classification. Dans notre projet nous avons utilisé l'apprentissage non supervisé sur deux modèles LDA et K-NN avec le même Le sélecteur minimum-redondance-maximum-pertinence et les résultats sont présentés dans le chapitre 03.

Chapitre 03 :

Résultats et simulation

1. Introduction :

Ce chapitre présente des résultats obtenus en trois parties. La première partie présente les déchets de plastique prisés par le drone pour seulement deux polymères (PE et PET), la deuxième partie présente des échantillons préparés à l'intérieur d'un laboratoire, la troisième partie des échantillons préparés à l'extérieur. Les résultats obtenus dans chaque partie se décomposent en deux phases, phase d'apprentissage et phase de classification.

2. Partie 1 : Préparation des données, apprentissage et classification

2.1 Phase d'apprentissage :

Dans cette phase on va sélectionner un nombre de pixels à partir d'une image normale. Cette opération nous permet de différencier les matériaux désirés et non désirés pour identifier les déchets recherchés. Les différentes étapes de cette phase sont résumées dans ce qui suit :

2.1.1 Etape 1 : Choisir différents pixels pour différents cas (ex., ombré ou non, et différents matériaux, plastiques, non plastiques) et affecter une étiquette pour chaque catégorie, "a" pour un PET, "b" pour un PE et de "c" pour le reste des pixels (considérer comme non plastique). Les résultats obtenus dans cette étape sont enregistrés dans des vecteurs contenant les coordonnées des points et sont étiquetés.




Figure 3.1 : phase d'apprentissage.

2.1.2 Etape 2 : rassemble les images de différentes couches dans un cube (matrice de 3 dimensions) ou x et y représentent les coordonnées spatiale et z représente la longueur d'onde. Puis éliminer les bandes qui n'emporte aucune information utile comme indiqué dans la figure ci-dessous.




Figure 3.2 : un cube contient les images de différentes couches en trois dimensions




Figure 3.3 : (a) spectre de deux polymère PE et PET avec l'élimination des bandes non utile. (b) les différentes classes de la détection (rouge plastique, noir non plastique).

2.2 Phase de classification :

La classification en générale c'est une décision pour affecter un pixel a une catégorie définis dans la première phase, dans le premier cas on se concentre sur deux classes plastique ou non plastique. Dans notre projet nous avons utilisé les deux algorithmes présentés dans le chapitre 02 qui sont le LDA et KNN pour faire la classification et la détection.

Pour la réalisation de la télédétection des déchets, nous avons appliqué les étapes expliquées précédemment en deux cas. Dans le premier cas nous avons utilisé les images hyper-spectrales prennent à l'intérieur (indoor) avec les conditions artificielle (lumière, humidité) alors que dans le deuxième cas nous avons utilisé les images hyper-spectrales prennent à l'extérieur (outdoor) avec les conditions naturelles.

Dans le but de vérifier l'efficacité des étapes de télédétection expliqués précédemment faire une classification utilisant l'algorithme LDA sur un ensemble de matériaux (plastique non plastique est y compris l'herbe). Figure 3.4 montre l'emplacement des objets pour la phase de classification. Les objets sont distribués d'une façon aléatoire sur l'herbe, puis nous avons utilisée Drone avec la caméra hyper-spectrale pour balayer linéairement tous les objets qui se trouve dans le champ et la direction du vol du Drone. Figure 3.3.(a) montre une image d'une seule couche qui correspond à une seule longueur d'onde.

Au début nous avons utilisé l'algorithme LDA pour détecter uniquement un seul type de plastique. Figure 5.a montre le résultat de la détection de plastique du type PE alors que la figure 5.b Montre la détection du plastique de type PET.




Figure 3.4 : emplacement des objets pour la phase de classification



(a)



(b)

Figure 3.5 : (a) indetification de polymère PE. (b) indetification de polymère PE.

3. Partie 2 : Télédiction à l'intérieur de laboratoire (enivrement artificiel) :

Les paramètre de deux algorithmes utilisé son montrés dans le tableau suivant :

<u>L'algorithmme</u>	Type de polymère	Nombre des échantillons pour l'apprentissage	Nombre des échantillons pour la classification
<u>LDA</u>	Blanc	331	1219308
	PC	331	1219308
	PS	331	1219308
	PE	331	1219308
	PET	331	1219308
	PLA	331	1219308
	MaterBi	331	1219308
	PP	331	1219308
	ABS	331	1219308
	PVC	331	1219308
	TOUS	331	1219308
<u>KNN</u>	Blanc	331	1219308
	PC	331	1219308
	PS	331	1219308
	PE	331	1219308
	PET	331	1219308
	PLA	331	1219308
	MaterBi	331	1219308
	PP	331	1219308
	ABS	331	1219308
	PVC	331	1219308
	TOUS	331	1219308

Les résultats de cette partie est divisé en deux catégories. La première catégorie présente les résultats obtenus avec la normalisation des spectre et l'élimination des bandes non utiles, alors que la deuxième montre les résultats sans la normalisation et l'élimination des bandes.

3.1 Catégorie 1 : avec normalisation et l'élimination de bande

Les différents étapes de cette phase sont résumé dans ce de suite :

3.1.1. Etape 1 : On commence par construire un cube contenant tous les cubes de chaque polymère de plastique, ensuite refaire la procédure précédente en sélectionnant un nombre de pixels à partir d'une image normale. Cette opération nous permet de différencier les matériaux désirés pour chaque polymère.

3.1.2. Etape 2 : Choisir différents pixels pour chaque polymère et affecter une étiquette pour chaque catégorie, "a, b, c, d, e et f " pour la blanche référence, "g" pour un PC, "h" pour PS, "i" pour PE, "g" pour PET, "k" pour **PLA**, "l" pour **MaterBi**, "m" pour **PP**, "n" pour ABS, "o" pour PS, "p" pour PVC.




Figure 3.6 : phase d'apprentissage(indoor).

3.1.3. Etape 3 : normalisé le cube et le spectre de la matrice et éliminer les bandes qui n'emporte aucune information utile.

Figure 3.7.(a).(b). Montre les spectres (en nanomètre 'nm') avant et après la normalisation de tous les échantillons utiliser dans la phase d'apprentissage.




Figure 3.7 : Les spectres des échantillons (a) spectres non normalisés (b) spectres normalisés.

Les figures de 3.8 à 3.17 Montre les spectres normaliser de chaque polymère détecté.




Figure 3.8 : Spectres d'échantillons PC.




Figure 3.9 : Spectre d'échantillons PS.




Figure 3.10 : Spectres d'échantillons PE.




Figure 3.11 : Spectre d'échantillons PET.




Figure 3.12 : Spectres d'échantillons PLA.




Figure 3.13 : Spectre d'échantillons MaterBi.




Figure 3.14 : Spectres d'échantillons PP.




Figure 3.15 : Spectre d'échantillons ABS.




Figure 3.16 : Spectres d'échantillons PVC.




Figure 3.17 : Spectre d'échantillons de la blanche référence.

Figure de 3.18 à 3.27. Montre les classes de séparation après la normalisation de tous les échantillons utiliser dans la phase d'apprentissage.




Figure 3.18 : Séparation de tous les échantillons.




Figure 3.19 : Séparation d'échantillon PC.




Figure 3.20 : Séparation d'échantillon PS.




Figure 3.21 : Séparation d'échantillon PE.




Figure 3.22 : Séparation d'échantillon PET.




Figure 3.23 : Séparation d'échantillon PLA.




Figure 3.24 : Séparation d'échantillon MaterBi.




Figure 3.25 : Séparation d'échantillon PP.




Figure 3.26 : Séparation d'échantillon ABS.




Figure 3.27 : Séparation d'échantillon PVC.

Figure de 3.28 à 3.38. Montre les résultats après la normalisation de tous les échantillons utiliser dans la phase de classification.




Figure 3.28 : Référence des polymères (indoor).




Figure 3.29 : Résultats de tous les échantillons.




Figure 3.30 : Résultat d'échantillon PC.




Figure 3.31 : Résultat d'échantillon PS.




Figure 3.32 : Résultat d'échantillons PE




Figure 3.33 : Résultats d'échantillons PET.




Figure 3.34 : Résultat d'échantillon PLA.




Figure 3.35 : Résultats d'échantillons MaterBi.




Figure 3.36 : Résultat d'échantillon PP.




Figure 3.37 : Résultats d'échantillons ABS.




Figure 3.38 : Résultat d'échantillon PVC.

3.2 Catégorie 2 : Sans la normalisation et l'élimination des bandes

Figure de 3.39 à 3.48. Montre les spectres (en nanomètre 'nm') sans la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.




Figure 3.39 : Spectres de tous les échantillons.




Figure 3.40 : Spectre d'échantillons PC.




Figure 3.41 : Spectres d'échantillons PS.




Figure 3.42 : Spectre d'échantillons PE.




Figure 3.43 : Spectres d'échantillons PET.




Figure 3.44 : Spectre d'échantillons PLA.




Figure 3.45 : Spectres d'échantillons MaterBi.




Figure 3.46 : Spectre d'échantillons PP.




Figure 3.47 : Spectres d'échantillons ABS.




Figure 3.48 : Spectre d'échantillons PVC.




Figure 3.49 : Spectres d'échantillons de la référence blanche.

Figure de 3.49 à 3.58. Montre les classes de séparation après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.




Figure 3.49 : Séparation de tous les échantillons.




Figure 3.50 : Séparation d'échantillon PC.




Figure 3.51 : Séparation d'échantillon PS.




Figure 3.52 : Séparation d'échantillon PE.




Figure 3.53 : séparation d'échantillon PET.




Figure 3.54 : Séparation d'échantillon PLA.




Figure 3.55 : Séparation d'échantillon MaterBi.




Figure 3.56 : Séparation d'échantillon PP.




Figure 3.57 : Séparation d'échantillon ABS.




Figure 3.58 : Séparation d'échantillon PVC.

Figure de 3.59 à 3.68. Montre les résultats après la normalisation de tous les échantillons utilisés dans la phase de classification.



Figure 3.59 : Résultats de tous les échantillons.




Figure 3.60 : Résultat d'échantillon PC.




Figure 3.61 : Résultats d'échantillons PS.




Figure 3.62 : Résultat d'échantillon PE.




Figure 3.63 : Résultats d'échantillons PET.




Figure 3.64: Résultat d'échantillon PLA.




Figure 3.65 : Résultats d'échantillons MaterBi.




Figure 3.66 : résultat d'échantillon PP.




Figure 3.67 : Résultats d'échantillons ABS.




Figure 3.68 : Résultat d'échantillon PVC.

Figure de 3.69 à 3.78. Montre les résultats de K-NN de tous les échantillons utilisés dans la phase de classification avec K=5.




Figure 3.69 : Résultats de tous les échantillons.




Figure 3.70 : Résultat d'échantillon PC.



Figure 3.71 : Résultats d'échantillons PS.



Figure 3.72 : Résultat d'échantillon PE.




Figure 3.73 : Résultats d'échantillons PET.




Figure 3.74 : Résultat d'échantillon PLA.




Figure 3.75 : Résultats d'échantillons MaterBi.




Figure 3.76 : résultat d'échantillon PP.



Figure 3.77 : Résultats d'échantillons ABS.




Figure 3.78 : Résultat d'échantillon PVC.

4. Partie 3 : Echantillons prise à l'extérieur de laboratoire :

Refaire les mêmes étapes précédentes sur les échantillons prise à l'intérieur de laboratoire mais seulement avec une affectation déferente pour l'étiquette de chaque catégorie, "a, b, c, d, et e " pour la blanche référence, "f" pour un **PLA**, "g" pour **MaterBi**, "h" pour **ABS**, "i" pour **PE**, "g" pour **PET**, "k" pour **PP**, "l" pour **PC**, "m" pour **PS**, "n" pour **ABS**, "o" pour **PVC**.

4.1 Catégorie 1 : normalisation et l'élimination des bandes




Figure 3.79 : Phase d'apprentissage (outdoor).

Figure de 3.80.(a).(b). Montre les spectre (en nanomètre 'nm') avant et après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.




Figure 3.80 : Les spectres des échantillons (a) spectres non normalisés (b) spectres normalisés.

Les figures 3.81 – 3.90. Montre les spectres normaliser de chaque polymère détecté.




Figure 3.81 : Spectres d'échantillons PLA.




Figure 3.82 : Spectre d'échantillons MaterBi.




Figure 3.83 : Spectres d'échantillons ABS.




Figure 3.84 : Spectre d'échantillons PE.




Figure 3.85 : Spectres d'échantillons PET.




Figure 3.86 : Spectre d'échantillons PP.




Figure 3.87 : Spectres d'échantillons PC.




Figure 3.88 : Spectre d'échantillons PS.




Figure 3.89 : Spectres d'échantillons PVC.




Figure 3.90 : Spectre d'échantillons de référence blanche.

Figure de 3.91 à 3.100. Montre les classes de séparation après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.




Figure 3.91 : séparation de tous les échantillons.




Figure 3.92 : Séparation d'échantillon PLA.




Figure 3.93 : séparation d'échantillon MaterBi.




Figure 3.94 : Séparation d'échantillon ABS.




Figure 3.95 : séparation d'échantillon PE.




Figure 3.96 : Séparation d'échantillon PET.




Figure 3.97 : Séparation d'échantillon PP.




Figure 3.98 : Séparation d'échantillon PC.




Figure 3.99 : Séparation d'échantillon PS.




Figure 3.100 : Séparation d'échantillon PVC.

Figure de 3.101 à 3.110. Montre les résultats après la normalisation de tous les échantillons utilisés dans la phase de classification.



Figure 3.101 : Résultats de tous les échantillons.



Figure 3.102 : Résultat d'échantillon PLA.



Figure 3.103 : Resultats d'échantillon MaterBi.



Figure 3.104 : Résultat d'échantillon ABS.



Figure 3.105 : Résultats d'échantillon PE.



Figure 3.106 : Résultat d'échantillon PET.




Figure 3.107 : Résultats d'échantillon PP.



Figure 3.108 : Résultat d'échantillon PC.




Figure 3.109 : Résultats d'échantillon PS.




Figure 3.110 : résultat d'échantillon PVC.

4.1 Catégorie 2 : Sans normalisation et l'élimination de bande

Les figures 3.111 à 3.121. Montre les spectres (en nanomètre 'nm') normaliser de chaque polymère détecté.




Figure 3.111 : Spectres de tous les échantillons. blanche.




Figure 3.112 : Spectre d'échantillon de la référence blanche.




Figure 3.113 : Spectres d'échantillons PLA.




Figure 3.114 : Spectre d'échantillons MaterBi.




Figure 3.115 : Spectres d'échantillons ABS.




Figure 3.116 : Spectre d'échantillons PE.




Figure 3.117 : Spectres d'échantillons PET.




Figure 3.118 : Spectre d'échantillons PP.




Figure 3.119 : Spectres d'échantillons PC.




Figure 3.120 : Spectre d'échantillons PS.




Figure 3.121 : Spectres d'échantillons PVC.

Figure de 3.122 à 3.131. Montre les classes de séparation après la normalisation de tous les échantillons utilisés dans la phase d'apprentissage.




Figure 3.122 : séparation de tous les échantillons.




Figure 3.123 : Séparation d'échantillon PLA.




Figure 3.124 : Séparation d'échantillon MaterBi.




Figure 3.125 : Séparation d'échantillon ABS.




Figure 3.126 : Séparation d'échantillon PE.




Figure 3.127 : Séparation d'échantillon PET.




Figure 3.128 : Séparation d'échantillon PP.




Figure 3.129 : Séparation d'échantillon PC.




Figure 3.130 : Séparation d'échantillon PS.




Figure 3.131 : Séparation d'échantillon PVC.

Figure de 3.132 à 3.141. Montre les résultats après la normalisation de tous les échantillons utilisés dans la phase de classification.



Figure 3.132 : Résultats de tous les échantillons.




Figure 3.133 : Résultat d'échantillon PLA.



Figure 3.134 : Résultats d'échantillon MaterBi.




Figure 3.135 : Résultat d'échantillon PLA.



Figure 3.136 : Résultats d'échantillon PE.




Figure 3.137 : Résultat d'échantillon PET.




Figure 3.138 : Résultats d'échantillon PP.



Figure 3.139 : Résultat d'échantillon PLA.




Figure 3.140 : Résultats d'échantillon PS.




Figure 3.141 : Résultat d'échantillon PVC.

5. Conclusion :

Dans ce chapitre nous avons montrés les resultats de la télédiction de différents polymères en utilisant les deux algorithmes de classification LDA et KNN. Les resultats obtenus a nous permet de prendre des décisions sur la présence ou l'absence du plastique dans les environnements qui nous avant prendre en considération par le balayage de Drone.

Conclusion générale

En conclusion ce travail illustre le potentiel de l'imagerie hyper-spectrale par l'UAV pour la détection du plastique et sa précision, le prétraitement des données et l'exploration d'outils d'apprentissage automatique. Nous avons réussi d'utiliser les images hyper-spectrales et les algorithmes de classification pour réaliser un système de télédétection des déchets en plastique. Après l'application de deux algorithmes LDA et KNN avec deux conditions de travail artificielle et naturelle nous avons trouvé que la qualité des résultats du KNN est meilleure que celle de LDA cependant Le LDA est plus rapide en termes de temps d'exécution ce qui nous permet de dire que l'algorithme LDA est le meilleur si on parle d'une utilisation en temps réel.

Référence

- [1] High-Resolution Aerial Detection of Marine Plastic Litter by Hyperspectral Sensing par Marco Balsi, Monica Moroni, Valter Chiarabini and Giovanni Tan. Le 14/03/2022.
- [2] <https://www.geochemicalperspectivesletters.org/article1829/>. Le 16/03/2022.
- [3] <https://pubmed.ncbi.nlm.nih.gov/28815367/>. Le 22/03/2022.
- [4] <https://www.science.org/doi/10.1126/sciadv.1700782>. Le 23/03/2022.
- [5] <https://ourworldindata.org/plastic-pollution>. Le 25/03/2022.
- [6] <https://svs.gsfc.nasa.gov/11920>. Le 01/04/2022.
- [7] <http://www.ccrs.nrcan.qc.ca/>. Le 04/04/2022.
- [8] <https://www.geographie.ens.fr/IMG/file/kergomard/Teledetection/CTeledetection.pdf>. Le 05/04/2022.
- [9] https://fr.wikipedia.org/wiki/Imagerie_hyperspectrale#M%C3%A9thodes_d'acquisition_d'une_image_hyperspectrale. Le 11/04/2022.
- [10] <https://datascientest.com/machine-learning-tout-savoir>. Le 15/04/2022.
- [11] <https://mobiskill.fr/blog/conseils-emploi-tech/apprentissage-supervise-vs-apprentissage-non-supervise/>. Le 27/04/2022.
- [12] <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-016-1423-9>. Le 16/05/2022
- [13] <https://towardsdatascience.com/linear-discriminant-analysis-explained-f88be6c1e00b>. Le 17/05/2022
- [14] <https://www.techopedia.com/definition/32066/k-nearest-neighbor-k-nn>. Le 14/03/2022 Le 28/05/2022