

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITE ABDELHAMID IBN BADIS - MOSTAGANEM



Faculté des Sciences Exactes et d'Informatique

Département de Mathématiques et informatique

Filière : Informatique

MEMOIRE DE FIN D'ETUDE

Pour l'Obtention du Diplôme de Master en Informatique

Option : **Ingénierie des Systèmes d'Information**

THEME

GESTION INTELLIGENTE DES DECHETS

PAR LES TECHNIQUES D'APPRENTISSAGE MACHINE

Présenté par : AYAD Fatma
 DAOUD Leila

Devant le jury composé de :

Président : Mr SEHABA K
Examineur : Mme KENNICHE A
Encadreur : Mr BESNASSI Miloud

Année Universitaire 2021-2022

Remerciement

Nous tenons tout d'abord à remercier notre Encadrant : Mr BESNASSI Miloud pour son précieux conseil et son aide durant toute la période du travail et aussi pour l'orientation, la patience qui ont constitué un apport considérable sans lequel ce travail n'aurait pas pu être mené au bon port.

Nos vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté à notre travail en acceptant d'examiner notre mémoire Et de l'enrichir par leurs propositions.

Nous tenons aussi à exprimer nos remerciements, d'une façon particulière à M' Ghezzar, M' Mecherouk , M' Kadem, M^{me} S.Mokhtari et le personnel du département Informatique surtout M^{elle} Fatiha ,M^{me} Fatima et M^{elle} Fatima pour leurs encouragement et accueil Nous remercions toutes celles et ceux qui de près ou de loin, nous ont prêté main forte pour la réalisation et la finalisation de ce projet.

Dédicace

Je dédie ce modeste travail accompagné d'un profond amour: à la mémoire de mon père.

À celui qui m'a aidé à devenir ce que je suis aujourd'hui .Que Dieu, le tout puissant, l'ait en sa sainte miséricorde !

À ma mère qui est toujours présente par ses encouragements et ses prières pour moi.

À mes chères et adorables sœurs ; Naouel ,Amina et Sabiha qui ont toujours été là pour moi, je vous souhaite une vie pleine de bonheur et de succès.

À mes chers petits frères ; Lokman Hakim et Kacem .

À la prunelle de mes yeux; Mohamed Habib et Ayoub, je t'aime énormément.

À mes amies: Amina , Fatiha , Sabah , souad et hizia . En souvenir de notre sincère et profonde amitié et des moments agréables que nous avons passés ensemble.

Une dédicace particulière à toutes les personnes qui ont participé, pour leur aide documentaliste et que j'ai omis de citer.

AYAD Fatma

Dédicace

Je dédie ce travail

À la mémoire de mon père.

À ma mère

À toute ma famille

À mes amis et mes collègues du SPSPD et SAL

DAOUD Leila

Résumé

Dans le monde entier, les taux de production de déchets augmentent. Les villes du monde ont généré des milliards de tonnes de déchets.

A première vue la gestion des déchets solides urbains semble assez simple et beaucoup pensent avoir trouvé la solution en se débarrassant des déchets dans les décharges. Avec l'évolution démographique et l'urbanisation forcée, les quantités de déchets urbains ne cessent de croître, et les problèmes d'évacuation, de traitement et en général de gestion se compliquent davantage. Le traitement des déchets reste problématique et se traduit par la multiplication des dépôts sauvages qui font l'objet soit d'une mise en décharge non contrôlée soit d'une incinération à l'air libre. Pour résoudre ce problème, nous utilisons une approche de recherche qui consiste à concevoir et implémenter un système de classification automatique d'images dont une perspective de gestion des déchets de manière automatique.

Mots-clés:

Traitement d'image, apprentissage, tri des déchets, classification...

Abstract

Around the world, waste generation rates are increasing. The world's cities have generated billions of tons of waste.

At first glance, urban solid waste management seems simple enough and many people think they have found the solution by disposing of waste in landfills. With demographic change and forced urbanization, the amount of urban waste is increasing, and the problems of disposal, treatment and general management are becoming more complicated. The treatment of waste remains problematic and results in the multiplication of uncontrolled dumping, which is either dumped in uncontrolled landfills or incinerated in the open air. To solve this problem, we use a research approach that consists of designing and implementing an automatic image classification system with an automatic waste management perspective.

Keywords:

Image processing, learning, waste sorting, classification...

Liste des figures

Figure N°	Titre de la figure	Page
Figure 2.1	Convergence d'un modèle-Apprentissage supervisé	14
Figure 2.2	Convergence d'un modèle-Apprentissage non supervisé	14
Figure 2.3	Neurone biologique /Neurone artificiel	15
Figure 2.4	Architecture de base d'un réseau de neurones artificiel	15
Figure 2.5	Structure de base d'un ANN	16
Figure 2.6	Structure de base d'un MLP	16
Figure 2.7	Modèle du perceptron multi couches	17
Figure 2.8	Structure de base d'un LBP	18
Figure 2.9	Réseau bayésien à 5 variables	19
Figure 2.10	Relation entre l'IA , machine learning et Deep Learning	20
Figure 2.11	Réseaux de neurones convolutionnels	21
Figure 2.12	Schéma du parcours de la fenêtre de filtre sur l'image	22
Figure 2.13	Dimension d'u filtre	23
Figure 2.14	Feature map après filtre de convolution	23
Figure 2.15	Stride	23
Figure 2.16	Principe de pooling avec un filtre 2*2 et un pas de 2	25
Figure 2.17	Couche fully connected	26
Figure 2.18	Architecture AlexNet	30
Figure 2.19	Architecture VGGNet	30
Figure 2.20	Structure VGG16	31

Figure 2.21	Architecture VGG16	31
Figure 2.22	Structure VGG19	32
Figure 2.23	Architecture VGG19	32
Figure 2.24	Architecture ResNet 50	33
Figure 2.25	Classes de data set Trashnet	35
Figure 3.1	Echantillon de donnes de TrashNet	40
Figure 3.2	Matrice de confusion	42
Figure 3.3	Courbe ROC	42
Figure 3.4	Architecture premier modèle CNN	51
Figure 3.5	Images mal classées	59

Liste des tableaux

Tableau N°	Titre du tableau	Page
Tableau 2.1	Max pooling vs average pooling	25
Tableau 2.2	Fonctions d'activation	27
Tableau 3 .1	Les différentes catégories du TrashNet	39
Tableau 3 .2	Métrique d'évaluation	41
Tableau 3.3	Résultats du modèle 1 avec MLP	44
Tableau 3.4	Résultats du modèle 2 avec MLP	46
Tableau 3.5	Résultats du modèle 3 avec MLP	48
Tableau 3.6	Résultats obtenus	50
Tableau 3.7	Résultats avec CNN	53
Tableau 3.8	Résultats obtenus	56
Tableau 3.9	Résultats avec VGG 16	58
Tableau 3.10	Résultats VGG 16	59
Tableau 3.11	Résultats avec VGG 19	60
Tableau 3.12	Résultats VGG 19	61
Tableau 3.13	Résultats comparative	62

Liste des abréviations

Abréviation	Expression Complète	Page
PME	Petit ou moyenne entreprise	4
OM	Les ordures ménagères	7
IA	Intelligence artificiel	13
ANNs	Réseaux de neurones artificiels	14
MLP	Multi-layer perception	15
LBP	Local binary pattern	18
CNNs	Réseaux de neurones convolutifs	20
CONV	Couche convolutionnelle	21
FC	La couche Fully Connected	21
ReLU	Rectified liner unit layer	21
POOL	Pooling	21
TMSE	Total mean squared error	28
CEL	Cross entropy loss	28
ILSVRC	ImageNet large scale visual recognition challenge	29
SVM	Support vector machine	29
VGG	Visual geometry group	30
GPU	Graphics processing units	31
ResNet	Residual neural network	33
RFID	Radio Fréquence Identification	33
OWL	Ontology web language	34
SIFT	scale-invariant feature transform	34

Table des matières

Introduction Générale.....	1
Chapitre 1 La Gestion des Déchets Solides	3
1.1 Introduction.....	3
1.2 Définition des déchets	3
1.3 La classification des déchets	3
1.3.1 Distinction en fonction de l'activité à l'origine du déchet.....	4
1.3.2 Distinction en fonction de la nature du déchet.....	4
1.3.3 Distinction en fonction du mode de traitement des déchets.....	5
1.4 Système de gestion des déchets.....	6
1.4.1 La prévention.....	6
1.4.2 Le réemploi, la réutilisation, la régénération et le recyclage	7
1.4.3 Le tri.....	7
1.4.4 La collecte	7
1.4.5 Le transit et le transport des déchets.....	8
1.4.6 Le traitement	8
1.4.7 Acteurs	9
1.5 Stratégie de la gestion des déchets.....	9
1.5.1 Choix des stratégies de la gestion des déchets	9
1.6 Objectifs de la gestion des déchets	10
1.7 Impacts des déchets solides sur la santé et l'environnement	10
1.7.1 Impacts sur la santé humaine.....	10
1.7.2 Impacts sur l'environnement	11
1.8 Conclusion	12
Chapitre 2 Apprentissage et Classification	13
2.1 Introduction.....	13
2.2 Machine Learning.....	13
2.2.1 Apprentissage supervisé.....	13
2.2.2 Apprentissage non supervisé	14
2.3 Réseaux de neurones artificiels (ANNs).....	14
2.4 Perceptrons multicouches MLP	16
2.4.1 LOCAL BINARY PATTERNS	18

2.5 Réseaux bayésiens	18
2.6 Deep Learning	19
2.7 Réseaux de neurones convolutifs (CNNs)	20
2.7.1 Fonctionnement d'un CNN	21
2.7.1.1 Couche convolutive CONV	21
2.7.1.2 Couche de pooling	24
2.7.1.3 La couche Fully Connected FC	26
2.7.1.4 Fonction d'activation	27
2.7.2 L'entraînement d'un CNN	28
2.7.3 Fonction de perte (Loss Function)	28
2.7.4 Les architectures CNN.....	29
2.7.4.1 AlexNet	29
2.7.4.2 VGGNet	30
2.7.4.3 VGG16	30
2.7.4.4 VGG19	32
2.7.4.5 ResNet50	34
2.8 L'apprentissage automatique & classification des déchets.....	33
2.9 Conclusion.....	36
Chapitre 3 Résultats expérimentaux et évaluation	37
3.1 Introduction.....	37
3.2 Ressources matérielles et logicielles utilisées	37
3.3 Base de données	39
3.4 Indicateurs de performance en classification	40
3.4.1 Métrique d'évaluation	40
3.4.2 Matrice de confusion	41
3.4.3 ROC	42
3.5 Architecture proposés	42
3.5.1 Préparation et chargement de la base de données	43
3.6 Résultats et discussion	43
3.6.1 Réseaux de neurones MLP	43
3.6.2 Réseaux de neurones Convolutionnel CNN	51
3.6.3 VGG16	57

3.6.4 VGG19	60
3.7 Résultats comparative	62
3.8 Conclusion	63
Conclusion Générale	64
Bibliographie.....	65

Introduction Générale

A. Contexte de travail

Aujourd'hui, la question des déchets urbains se pose avec acuité dans un contexte général de croissances urbaine et démographique, mais aussi en raison de l'évolution rapide des modes de production et de consommation qui génèrent davantage de restes. Dans des situations de pauvreté ou d'accentuation des inégalités, de plus en plus d'individus récupèrent des déchets qui deviennent des ressources indispensables à leur survie. En effet, dans de nombreuses villes latino-américaines, africaines ou asiatiques et ce depuis longtemps, les chiffonniers, cartoneros, catadores, recicladores, pepenadores, scavengers, streetpickers ou wastepickers fouillent les dépotoirs ou les poubelles à la recherche de matières qu'ils peuvent revendre ou recycler.

Ces pratiques de récupération, de tri, de réutilisation et de recyclage contribuent au traitement d'une partie des déchets urbains : elles fournissent parfois un réel service aux citoyens, mais assurent également des emplois et revenus à des populations se situant aux marges du marché du travail et, souvent, aux marges de la société. D'autres, percevant les bénéfices qui peuvent être tirés des rebuts, deviennent de véritables « entrepreneurs » des déchets *via* le recyclage et le commerce.[12]

Si, par le passé, la récupération et le recyclage étaient l'apanage de populations marginales à la recherche de ressources pour assurer leurs revenus, le potentiel économique du déchet, longtemps sous-estimé ou négligé, est ainsi devenu aujourd'hui un enjeu crucial pour de nombreux acteurs privés et publics. Ce potentiel est encore renforcé par le contexte mondial de raréfaction des ressources énergétiques et minérales, mais également par la demande croissante en matières premières et secondaires.

Dans ce contexte général, le domaine de la gestion des déchets a profondément évolué : au cours des dernières décennies, les politiques publiques sont ainsi passées d'une obligation d'évacuation à une logique de valorisation (recyclage des matières, production d'énergie, etc.). Dans le même ordre d'idées, un principe de réduction a été adopté et mis en œuvre par les gouvernements. Son application prévoit, d'une part, une diminution de leur production et, d'autre part, une diminution du volume à traiter dans les exutoires (décharges, incinérateurs, etc.). En amont et en aval de la chaîne de prise en charge du déchet, la valorisation des matières via la collecte sélective et la récupération s'est imposée comme une troisième

dimension de ces politiques. Celle-ci se présente comme un objectif, mais également comme une nouvelle valeur et un cadre d'action pour les politiques des déchets. [12]

B. Problématique

La gestion efficace de nos déchets est l'un des grands défis de notre époque. Les nouvelles technologies numériques peuvent faciliter les processus des collectivités, résidents et entreprises. L'éventail des innovations va des conteneurs à déchets intelligents aux technologies de tri autonomes. Des technologies de traitement des données et de communication, ainsi que des bras robotisés qui saisissent les objets et les placent dans les conteneurs appropriés.

Devant la vivacité du problème et l'importance de son enjeu social et environnemental, nous visons une méthodologie de recherche qui consiste à concevoir et implémenter une architecture de classification automatique d'images. Le but de notre projet est de classer les images des déchets en fonction de leurs nature (Papier, Métal, Plastique etc). Nous utilisons des algorithmes de classification supervisé en introduisant quelque réseaux neurones pour analyser les caractéristiques extraites à partir des images de déchets et identifier leurs natures.

C. Organisation du mémoire

Dans notre travail nous avons fait un état de l'art qui se compose de trois chapitres, dans le **premier chapitre** nous avons abordé quelque définition sur les déchets et leur classification selon leur nature, origine et mode de traitement ainsi la gestion des déchets et son impact sur la santé et l'environnement. Le **deuxième chapitre** est consacré aux différentes méthodes de classification d'images tel que : MLP ,CNN, VGG16 , VGG19 , AlexNet, ResNet50 .

Le **troisième chapitre** fournit l'évaluation expérimentale ainsi que l'analyse des résultats.

Et enfin, nous terminerons ce mémoire par une conclusion générale

Chapitre 1

La Gestion des Déchets Solides

1.1 Introduction

Les déchets sont l'un des meilleurs indicateurs de vitalité socio-économique et de mode de vie. La croissance de la production et du développement est toujours plus rapide, et la quantité de déchets ménagers a connu une croissance rapide au cours des dernières décennies en raison de l'accélération de l'urbanisation au siècle dernier. Une société de gaspillage est née. La protection de l'environnement devient de plus en plus une préoccupation collective. Le problème des déchets se produit tous les jours et touche chaque être humain. En tant que consommateur, producteur, éboueur et trieur, citoyen ou régisseur des déchets recyclables, chacun peut et doit être acteur d'une meilleure gestion des déchets. [7]

1.2 Définition des déchets

Le mot « déchet » provient de « déchoir » (diminution de valeur d'une matière ou d'un objet). Il est apparu au 15^{ème} siècle. La difficulté commence dès sa définition. Le mot « déchet » appartient à plusieurs terminologies concernant les activités de l'homme : économie, droit, technique. [2]

Un déchet, c'est ce qui est jeté. Mais ce qui est jeté par certains, ici, peut-être réutilisé par d'autres, un déchet est défini aussi comme toute substance ou tout objet dont le détenteur se défait ou dont il a l'intention ou l'obligation de se défaire. [38]

Au sens de la loi Algérienne, un déchet est défini comme : Tout résidu d'un processus de production, de transformation, ou d'utilisation, et plus généralement toute substance, ou produit et tous bien meuble dont le propriétaire ou le détenteur se défait, projette de se défaire, ou dont il a l'obligation de se défaire ou de l'éliminer.[22]

1.3 La classification des déchets :

Les déchets peuvent être solides, liquides ou gazeux. Ils peuvent être dangereux ou non dangereux. Ils peuvent aussi être classés selon leur provenance ou leur composition et leurs propriétés physiques et chimiques. On peut classer les déchets selon plusieurs critères : en fonction de l'activité à l'origine du déchet, en fonction de la nature du déchet, en fonction du mode d'élimination du déchet.[2]

1.3.1 Distinction en fonction de l'activité à l'origine du déchet

- Les déchets ménagers et assimilés

Les déchets ménagers et assimilés sont les déchets produits par les ménages, les commerçants, les artisans, et même les entreprises et industries quand ils ne présentent pas de caractère dangereux ou polluant : papiers, cartons, bois, verre, textiles, emballages. Ces déchets sont collectés par la commune si, eu égard à leurs caractéristiques et aux quantités produites, ils peuvent être éliminés sans sujétions techniques particulières et sans risques pour les personnes ou l'environnement. [18]

- Les déchets industriels

Les déchets industriels non dangereux ou "banals". Ce sont les déchets des entreprises non dangereux qui sont aussi appelés "déchets assimilés aux déchets ménagers". Les déchets industriels dangereux ou "spéciaux". Ce sont les déchets des entreprises qui, en raison de leurs propriétés dangereuses, ils ne peuvent pas être déposés dans des installations de stockage recevant d'autres catégories de déchets. [18]

- Les déchets agricoles

Sont les déchets issus de l'activité agricole. Il s'agit essentiellement de déchets organiques comme les déjections des animaux, les déchets de culture, etc. [18]

- Les déchets d'activité de soins de santé

Ce sont les déchets issus des hôpitaux et les autres établissements de soins, les laboratoires et les centres de recherches, les morgues et les centres d'autopsie, les banques de sang et les services de collecte de sang. [18]

1.3.2 Distinction en fonction de la nature du déchet

- Les déchets dangereux

Les déchets sont considérés comme dangereux s'ils présentent une ou plusieurs des propriétés suivantes : explosif, comburant, inflammable, irritant, nocif, toxique, cancérigène, corrosif, infectieux, toxique pour la reproduction, mutagène, écotoxique. [18]

- Les déchets toxiques en quantités dispersées

Sont des déchets dangereux produits en petites quantités par les ménages, les commerçants ou les PME (garages, coiffeurs, laboratoires photo, imprimeries, laboratoires de

recherche...). Il peut s'agir de déchets banals souillés (chiffons, cartons,...), piles, résidus de peinture, etc. [18]

- Les déchets non dangereux

Les déchets non dangereux sont les déchets qui ne présentent aucune des caractéristiques relatives à la "dangerosité" mentionnées ci-dessus (toxique, explosif, corrosif, ...). Ce sont les déchets "banals" des entreprises, commerçants et artisans (papiers, cartons, bois, textiles...) et les déchets ménagers. [18]

- Les déchets inertes

Sont des solides minéraux qui ne subissent aucune transformation physique, chimique ou biologique importante : pavés, gravats, carrelage. Ils proviennent des chantiers du bâtiment et des travaux publics, mais aussi des mines et des carrières. [18]

- Les déchets ultimes

Est ultime un déchet, résultant ou non du traitement d'un déchet, qui n'est plus susceptible d'être traité dans les conditions techniques et économiques du moment, notamment par extraction de la part valorisable ou par réduction de son caractère polluant ou dangereux. [18]

1.3.3 Distinction en fonction du mode de traitement des déchets

- Les déchets biodégradables ou composables

Comme les résidus verts, boues d'épuration des eaux, restes alimentaires... Ces déchets sont au moins pour partie détruits naturellement, plus ou moins rapidement, en général par les bactéries, champignons et autres micro-organismes et/ou par des réactions chimiques laissant des produits de dégradation identiques ou proches de ceux qu'on peut trouver dans la nature, parfois néanmoins contaminés par certains résidus. [18]

- Les déchets recyclables

Comme le verre, métaux, matières plastiques. Ces déchets peuvent être réutilisés tels quels dans d'autres domaines ou recyclés. [18]

- Les déchets ultimes

Les déchets qui ne sont plus susceptibles d'être traités dans les conditions techniques et économiques du moment. Eux seuls devraient être mis en décharge. [18]

- Les déchets spéciaux et déchets industriels spéciaux

Dont font partie les déchets toxiques, les déchets radioactifs et déchets nucléaires qui doivent faire l'objet d'un traitement tout à fait particulier en raison de leur nocivité particulière liée à la radioactivité. [18]

1.4 Système de gestion des déchets

La gestion des déchets est l'ensemble des opérations et moyens mis en œuvre pour limiter, valoriser ou éliminer les déchets. Opérations de prévention, de réduction à la source, opérations de tri, de pré collecte, de collecte et de transport, opérations de réutilisation, de recyclage et devalorisation, opérations de traitement, jusqu'au stockage des résidus, y compris la surveillance de ces opérations et celle des sites d'élimination de ces déchets. [7]

1.4.1 La prévention

La prévention des déchets consiste à prévenir ou réduire la production et la nocivité des déchets. La prévention inclut toutes les étapes du cycle de vie d'un produit avant qu'il soit considéré comme un déchet. La prévention quantitative concerne la diminution de la masse et du volume des déchets, la prévention qualitative concerne la nocivité des déchets. Trois stades sont à considérer : [7]

• La réduction à la source ou « Eco-conception »

Cette étape concerne les industriels. C'est l'étape de prévention la plus en amont dans le cycle de vie du produit. Les industriels doivent réduire dès la conception, la fabrication et jusqu'à la distribution la quantité des matières utilisées. Une prévention qualitative doit également permettre de réduire la toxicité des futurs déchets par un choix judicieux des matières employées. Il faut donc favoriser la conception d'objets durables, réparables, recyclables et réutilisables. [7]

• La responsabilité élargie du consommateur ou « Eco-consommation »

A ce niveau, le consommateur fait des choix et agit au moment de l'achat (choix du moindre emballage), de l'utilisation et de la gestion des biens qu'il consomme. [7]

• Une seconde vie pour nos vieux objets

Il est parfois possible de réutiliser ou de réemployer certains objets, évitant qu'ils ne deviennent des déchets. [7]

1.4.2 Le réemploi, la réutilisation, la régénération et le recyclage

- **Le réemploi** : on emploie un déchet pour un usage analogue à son premier emploi. C'est par exemple le réemploi de bouteilles consignées. C'est, en quelque sorte, prolonger la durée de vie du produit avant qu'il ne devienne un déchet.
- **La réutilisation** : on emploie un déchet pour un usage différent de son premier emploi.
- **La régénération** : par un procédé physique ou chimique, on redonne au déchet des caractéristiques qui lui permettent de remplacer une matière première neuve.
- **Le recyclage** : on obtient à partir des déchets, des matières premières entrant dans la fabrication de nouveaux produits. [7]

1.4.3 Le tri

Opération de séparation des différents flux de déchets par les producteurs. Le tri sélectif consiste à récupérer séparément les déchets selon leur nature. On parle aussi de tri des déchets ou de collecte sélective. Il est possible de faire le tri à la source de création de déchet ou de collecter les déchets ensemble et d'effectuer le tri ensuite dans un centre de tri. Le tri sélectif nécessite la participation de chacun, du citoyen à la collectivité locale. Le tri contribue ainsi à la préservation des ressources naturelles, évite le gaspillage et réduit les coûts de traitement en limitant les quantités à incinérer. Le tri sélectif est un pas vers une écologie plus saine. [7]

Pour mettre en œuvre efficacement ces différents modes de traitement, il est indispensable de mettre en place en amont un tri des déchets pour orienter chaque déchet (ou fraction de déchet) vers la solution optimale. Le meilleur tri étant situé à la source du déchet. L'idéal est bien sûr d'éviter la production de déchets. [7]

1.4.4 La collecte

La collecte désigne l'ensemble des opérations qui consistent à regrouper les déchets, depuis leurs sources de production puis à les transporter jusqu'aux centres de traitement. [2]

- **La pré-collecte** : regroupe toutes les opérations nécessaires à l'évacuation des OM depuis le logement jusqu'au lieu de prise en charge par le service de collecte. [2]
- **La collecte par apport volontaire** : des conteneurs spécifiques sont installés en différents points de la ville pour récupérer les produits recyclables. Les habitants apportent leurs déchets recyclables jusqu'au conteneur. De la même façon, les déchèteries reçoivent des déchets qui ne sont pas acceptés par la collecte normale. [2]

• **La collecte séparative en porte à porte** : La commune fournit à ses habitants plusieurs poubelles, qui ont des couvercles de couleurs différentes selon ce qu'elles doivent contenir. Les habitants placent leurs déchets dans les différentes poubelles. Il peut y avoir par exemple une poubelle pour les matières organiques, une poubelle pour les emballages et une dernière poubelle pour les déchets non recyclables. Dans certaines communes, ce sont des sacs transparents (qui permettent ainsi de vérifier le contenu du sac) qui sont fournis aux habitants pour le tri des emballages. La collecte séparative en porte à porte permet de collecter de plus grands volumes qu'avec l'apport volontaire, mais son inconvénient est que le tri est souvent mal fait. [2]

• **La collecte mixte** : la collecte est partagée entre apport volontaire et collecte séparative en porte à porte. Par exemple, les emballages et déchets non recyclables sont récupérés en porte à porte et le verre et le papier peuvent être apportés dans des conteneurs en ville. La collecte mixte est le plus souvent la solution retenue. [2]

• **La collecte par point de regroupement** : est particulièrement développée en milieu rural dispersé ou groupé. Ce sont les usagers qui déplacent leurs déchets ou récipients afin de les grouper avec ceux des habitants voisins. Ce système permet de diminuer le nombre de points et le temps de collecte et donc le coût supporté par la collectivité. [2]

• **La collecte sélective** : vise la collecte de certains flux de déchets préalablement séparés par les producteurs, en vue d'une valorisation ou d'un traitement spécifique. [2]

1.4.5 Le transit et le transport des déchets

La station de transit ou centre de transfert reçoit les flux de déchets ménagers et permet leur stockage dans une fosse, des conteneurs ou sur une aire. Les déchets, éventuellement compactés sont ensuite acheminés, par un mode de transport vers une installation de traitement ou de stockage. L'emploi d'une station de transit n'est justifié que dans le cas où le traitement des déchets n'est pas réalisé dans l'aire géographique de la collecte.[7]

1.4.6 Le traitement

Ensemble de procédés visant à transformer les déchets pour notamment en réduire dans des conditions contrôlées leur potentiel polluant initial, la quantité ou le volume, et assurer leur recyclage ou leur valorisation. (Incinération, compostage,...). [18]

1.4.7 Acteurs

De nombreux acteurs interviennent dans la gestion des déchets à différents niveaux. Cinq acteurs se répartissent la tâche de la gestion des déchets :

- Le secteur public représenté par les autorités locales (commune)
- Le secteur privé formé de petites et de grandes entreprises
- Le secteur informel composé soit par des particuliers rassemblés en association de quartier, soit par des petites entreprises non officielles, s'occupant de la pré-collecte en porte à porte. Ce secteur est une caractéristique de la gestion des déchets dans les pays en voie de développement.
- La population, premier producteur, bénéficie souvent d'un service de collecte.
- Les associations, très nombreuses dans les pays en voie de développement, doivent leur essor aux défaillances des communes ou autres autorités compétentes dans le domaine de l'environnement. Elles fondent leurs actions sur les liens sociaux entretenus avec la population. Avec une organisation structurelle assez précaire, elles offrent un service apprécié par une population mobilisée dans tous les programmes d'amélioration du cadre de vie. [18]

1.5 Stratégie de la gestion des déchets

1.5.1 Choix des stratégies de la gestion des déchets

Face à la nécessité de résoudre le problème de la gestion d'un déchet, les choix stratégiques sont :

- **Arrêt de la production ou de la diffusion du produit à l'origine de déchet**

Cette stratégie est imposée par les impacts écologiques ou toxiques liés à l'usage de certains produits (Amiante, etc.). [18]

- **Optimisation des procédés et innovations technologiques**

Technologies propres, sobres et économes. Le développement des biotechnologies s'inscrit dans cette évolution des outils de production moins générateurs des déchets dangereux. [18]

• Valorisation des déchets

La majeure partie des déchets sont potentiellement valorisables en fonction de leur nature chimique, de leurs propriétés mécaniques, physico-chimiques ou thermiques (valorisation du verre, papier, plastique). [18]

• Rejet éco-compatible dans le milieu naturel

Dans certains cas, le retour des déchets en milieu naturel est sans impact écologique, écotoxique ou toxique. C'est le cas en général des déchets inertes. [18]

• Stockage dans le milieu naturel

Il s'agit de l'enfouissement des déchets. C'est la mise en décharge dans un contexte réglementé qui doit garantir l'innocuité du système vis-à-vis du milieu environnant. [18]

1.6 Objectifs de la gestion des déchets

Les objectifs de la gestion des déchets sont :

- Prévenir ou réduire la production et la nocivité des déchets, de la fabrication à la distribution des produits.
- Organiser le transport des déchets et de le limiter en distance et en volume.
- Valoriser les déchets par réemploi, recyclage ou toute autre action visant à obtenir des matériaux réutilisables ou de l'énergie.
- Planifier la gestion des déchets pour qu'ils soient transportés et éliminés conformément à ces objectifs.
- Assurer l'information du public sur les effets pour l'environnement et la santé publique des opérations de production et d'élimination des déchets, et sur les mesures destinées à prévenir ou compenser les effets préjudiciables de ces opérations. [2]

1.7 Impacts des déchets solides sur la santé et l'environnement

1.7.1 Impacts sur la santé humaine

La manipulation inappropriée des déchets peut avoir un impact sur la santé humaine par exemple, la décomposition des déchets organiques attire les rongeurs, les insectes et les animaux errants, qui vont être l'origine des maladies telles que la typhoïde et le choléra.

Une mauvaise gestion des déchets solides et des décharges à ciel ouvert peut entraîner une pollution de l'environnement et peuvent être aussi particulièrement graves pour les

personnes qui entrent en contact direct avec ces déchets ou qui vivent à proximité de décharges. [30]

1.7.2 Impacts sur l'environnement

Le contrôle inadéquat de lixiviats¹, l'eau qui s'infiltré par percolation à travers les déchets et transporte les produits chimiques, sur les sites d'élimination peut entraîner une contamination des sols et des plans d'eau, ce qui affecte les écosystèmes locaux. Ils constituent également une menace pour les animaux errants et la faune sauvage, car ces animaux sont susceptibles de manger les déchets contenant des résidus alimentaires ou des restes de nourriture. [30]

La combustion ouverte des déchets produit des émissions de carbone noir, un composant de matière particulaire qui a un impact significatif sur la qualité de l'air au niveau régional et le climat mondial. Les sites d'élimination des déchets libèrent du méthane qui contribue à la formation

Les déchets industriels peuvent avoir des conséquences très néfastes pour l'environnement s'ils sont mal gérés. Leurs impacts sur l'air, l'eau et le sol ne sont pas négligeables. [30]

- **L'impact sur la pollution de l'air** : (pollution atmosphérique). Les Décharges contiennent une large variété de déchets leur mélange (surtout entre déchets organiques et de l'eau) provoque l'apparition des gaz à effet de serre tel que le méthane. [30]

- **L'impact sur la pollution du sol** : Elle est une préoccupation mineure par rapport à celle de l'eau et de l'air, et pourtant c'est un problème majeur. Aujourd'hui on estime que 70% des déchets sont enfouis, notamment les déchets nucléaires. Cela provoque l'érosion et la contamination des sols. [30]

- **L'impact sur la pollution de l'eau** : Chaque année plus de six millions de tonnes de déchets différents sont rejetés dans les océans. La contamination des espèces aquatiques qui s'ensuit peut devenir dangereuse pour les réseaux trophiques. Les déchets biodégradables réagissent avec la pluie, provoquant ensuite des pluies acides qui polluent les rivières et les océans. Les rejets de déchets industriels dans des fleuves, rivières ou mers constituent évidemment

¹ Lixiviats : Les eaux de pluie et la fermentation naturelle des déchets produisent un liquide appelée "lixiviats"

une source plus directe de pollution de l'eau. Les industriels laissent ainsi les solvants, les produits chimiques et, en règle générale, les résidus industrie.[30]

1.8 Conclusion

Dans ce chapitre, nous avons fourni une brève introduction au contexte théorique de la gestion de déchet, et à la fin du chapitre nous avons présenté les impacts des déchets solides sur la santé et l'environnement.

Dans le chapitre suivant, nous donnerons plus de détail sur de l'apprentissage automatique en expliquant les concepts fondamentaux associés à l'apprentissage profond pour la détection d'objets.

Chapitre 2

Apprentissage et Classification

2.1 Introduction

Ce chapitre fournit une brève introduction au contexte théorique de l'apprentissage automatique et explique les concepts fondamentaux associés à l'apprentissage profond pour la détection d'objets utilisant des architectures de réseaux de neurones convolutifs.

Depuis quelques années, un nouveau lexique lié à l'émergence de l'intelligence artificielle dans notre société inonde les articles scientifiques, et il est parfois difficile de comprendre de quoi il s'agit. Lorsqu'on parle d'intelligence artificielle, on fait très souvent l'allusion aux technologies associées comme le Machine learning ou le Deep learning. Deux termes extrêmement utilisés avec des applications toujours plus nombreuses, mais pas toujours bien définis. Pour commencer, revenons sur ces définitions essentielles :

2.2 Machine Learning

Le Machine Learning ou bien « apprentissage automatique » est un sous ensemble de l'IA qui concerne la création d'algorithmes qui permettent d'apprendre à partir de données précédemment collectées. Le terme machine Learning a été introduit en 1959 par Arthur Samuel qui en donne la définition suivante « L'apprentissage automatique est la discipline donnant aux ordinateurs la capacité d'apprendre sans qu'ils soient explicitement programmés.[23]

En voici une autre définition plus technique : « Étant donné une tâche T et une mesure de performance P, on dit qu'un programme informatique apprend à partir d'une expérience E si les résultats obtenus sur T, mesurés par P, s'améliorent avec l'expérience E. » [6]

En général, l'apprentissage peut être de deux types : **supervisé** et **non-supervisé**.

2.2.1 Apprentissage supervisé

L'apprentissage supervisé est une variété de machine Learning qui utilise un ensemble de données d'apprentissage étiquetées afin de créer des modèles d'intelligence artificielle. Le but de cette méthode est le fait que l'algorithme soit capable « d'apprendre » en comparant sa sortie réelle avec les sorties « enseignées » pour trouver des erreurs et modifier le modèle en

conséquence. Donc l'apprentissage supervisé utilise des modèles pour déterminer les valeurs d'étiquettes pour un ensemble de données non étiquetées. [6]

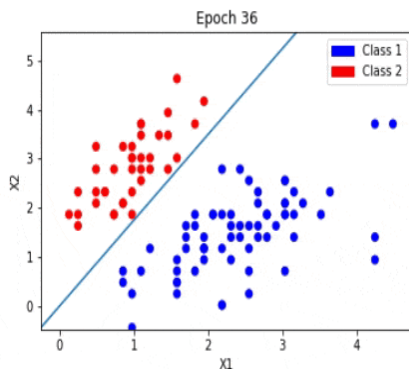


Figure 2.1– Convergence d'un modèle - Apprentissage supervisé [6]

2.2.2 Apprentissage non supervisé

Dans le cas de l'apprentissage non supervisé, on utilise un ensemble de données d'entrées non étiquetées, afin de laisser l'algorithme d'apprentissage trouver tout seul les points communs parmi cet ensemble de données, ce qui va rendre la machine intelligente capable de découvrir automatiquement les représentations nécessaires pour classer des données brutes.[6]




Figure 2.2– Convergence d'un modèle - Apprentissage non supervisé [6]

2.3 Réseaux de neurones artificiels (ANNs) :

Les réseaux neurones artificiels sont des méthodes d'apprentissage supervisé et non supervisé qui tentent d'imiter la pensée humaine par la modélisation simplifiée des systèmes neuronaux du cerveau de l'homme. L'intention n'est pas de modéliser le mécanisme exact du fonctionnement biologique des cellules neurales dans le cerveau ni de créer un clone biologique. Au lieu de cela, la biologie n'est que la source d'inspiration. [4]

Ce concept fut introduit pour la première fois en 1943 par McCulloch qui a proposé la première définition de neurone formel [31]. Puis, en 1957, Rosenblatt réalisa le premier réseau avec une couche d'entrée et de sortie afin de simuler le fonctionnement rétinien dans la reconnaissance de forme [15]. Depuis cette époque et au travers des puissances computationnelles qui ne cessent d'augmenter, il a été développé un nombre non négligeable de différents types de réseaux neurones artificiels tel que : McCulloch and Pit, Perceptron, ADaptive LInear Neuron (ADALINE), Multi-Layer Perceptron (MLP), Many ADaptive LInear Neuron (MADALINE) et Back Propagation Network. [50]

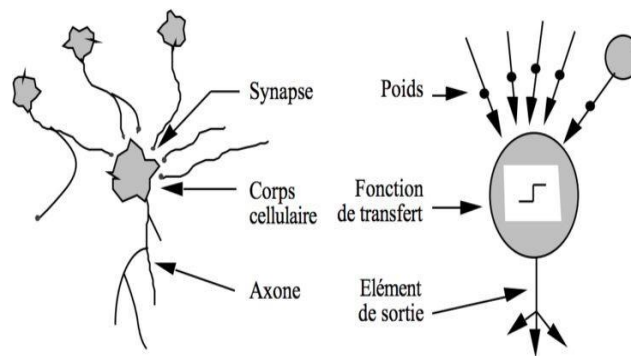


Figure 2.3 - Neurone biologique / Neurone artificiel [13]

En général un réseau de neurones est constitué d'un ensemble de couches successives dont chacune prend ses entrées sur les sorties de la précédente c.-à-d. que cet ensemble est entièrement connectée. Chaque couche est un ensemble de neurones n'ayant pas de connexion entre eux et qui reçoivent des informations numériques en provenance de neurones voisins. L'ensemble de couches est composé d'une couche d'entrée qui lit les valeurs d'entrées, une couche de sortie qui fournit les résultats du système et entre ces deux se cache une à plusieurs couches dites cachées qui participent au transfert. Comme le montre la figure 2.4 suivante.

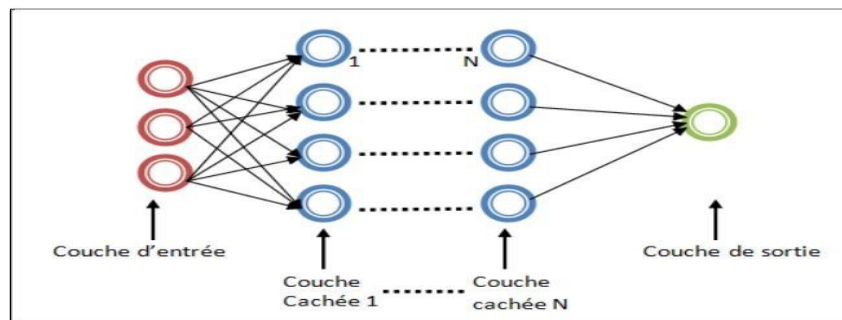


Figure 2.4 -Architecture de base d'un réseau de neurones artificiel [26]

Les réseaux de neurones artificiels sont excellents pour modéliser des données non linéaires avec un grand nombre de fonctionnalités d'entrée. Lorsqu'ils sont utilisés correctement, les ANN peuvent résoudre des problèmes qui sont trop difficiles à résoudre avec un algorithme simple. Cependant, les réseaux de neurones sont coûteux en calcul, il est difficile de comprendre comment un réseau de neurones artificiels a atteint une solution. La structure de base d'un ANN est illustrée à la figure 2.5:

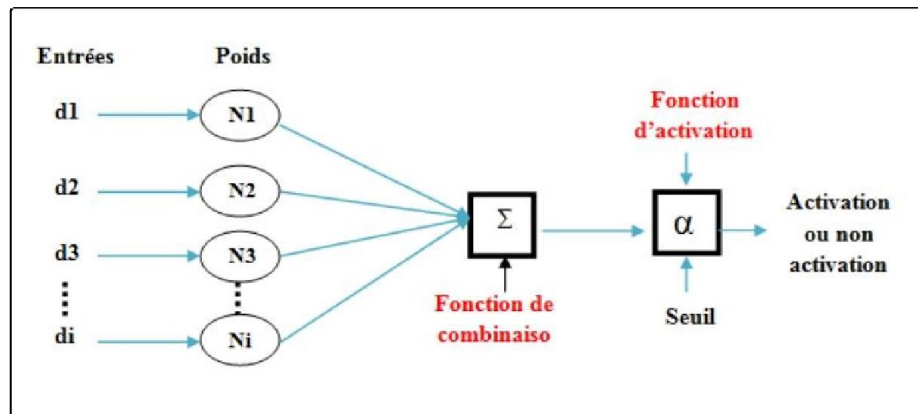


Figure 2.5—structure de base d'un ANN[26]

2.4 Perceptrons multicouches MLP

La version la plus standard d'une architecture de réseaux de neurones artificiels est le perceptron multicouche (MLP), qui correspond à un empilement de couches de neurones, aussi appelés perceptrons. Le perceptron a été introduit en 1957 par Franck Rosenblatt. Il s'agit d'un neurone artificiel inspiré par la théorie cognitive de Friedrich Hayek et celle de Donald Hebb. [35]




Figure 2.6 -Structure d'un MLP. [35]

Un neurone possède des entrées, qui sont des variables à valeur réelles, notées x_1, \dots, x_n , et une sortie, notée y . Chaque entrée est associée à un poids, noté w_i . Le calcul

effectué par un neurone consiste à multiplier la valeur de chaque entrée x_i par son poids w_i et d'en faire la somme. Le résultat de cette somme est additionné à une constante b (appelé le biais). Ce résultat constitue lui-même l'entrée d'une fonction non linéaire f , appelée fonction d'activation (Équation 2.1). [20]

Le résultat de ce calcul constitue la sortie \hat{y} du neurone :

$$y = f\left(\sum_{i=0}^n w_i x_i + b\right) \quad (2.1)$$

La somme pondérée des entrées par les poids w_i associés aux entrées est appelée potentiel, noté p . [20]

$$p = \sum w_i x_i \quad (2.2)$$

Les MLP sont généralement organisés en trois couches, la couche d'entrée, la couche cachée et la couche de sortie. L'utilité de plusieurs couches cachées n'a pas été démontrée. La figure 2.5 illustre la structure d'un MLP. Lorsque tous les neurones d'une couche sont connectés aux neurones de la couche suivante, on parle alors des couches complètement connectées. [35]




Figure 2.7 - Modèle du Perceptron Multi-Couches. [35]

Les perceptrons multicouches « Multi Layer Perceptron » ont montré leur efficacité comme technique d'apprentissage pour la classification des données. Ils sont en effet capables d'approximer des fonctions non-linéaires complexes afin de traiter des données de grande dimension. Dans le cadre de la classification d'images, deux approches sont possibles :

- Extraire des caractéristiques directement des données. Classiquement, ces caractéristiques sont extraites par un algorithme choisi par l'utilisateur. Les vecteurs de caractéristiques obtenus sont ensuite présentés en entrée d'un réseau de neurones.

- Présenter l'image en entrée d'un réseau de neurones. L'image nécessite cependant d'être vectorisée, c'est à dire mise sous forme d'un vecteur dont la dimension est égale au nombre de pixels de l'image. [35]

2.4.1 Motifs binaires locaux (Local Binary Pattern)

La technique du modèle Local Binary Patterns (LBP) est proposée par Ojala, Pietikäinen, & Harwood (1996). LBP fait partie des descripteurs utilisés pour extraire les caractéristiques locales. Il est devenu l'un des descripteurs d'analyse de texture les plus importants, efficace et robuste contre les variations de luminance. [21]

La description de la texture se fait par un modèle d'histogramme basé sur la représentation binaire calculée sur l'image complète ou bien une région d'une image. Le principe du descripteur LBP est d'étudier la relation entre le pixel central, et ces pixels voisins ce qui permet de construire une description binaire autour du pixel central. Les approches basées sur LBP peuvent être utilisées dans différentes applications de vision par ordinateur où elles ont montré de meilleures performances dans la classification des textures. Dans les dernières tendances, ces modèles locaux sont de plus en plus adaptés à la reconnaissance faciale.

Le concept du LBP est le suivant : un code binaire décrivant la texture locale d'une région est calculé par seuillage d'un voisinage avec le niveau de gris du pixel central. Tous les voisins prendront alors une valeur 1 si leur valeur est supérieure ou égale au pixel courant et 0 sinon. On va alors multiplier cette matrice composée de 0 et 1 par les poids LBP et sommer tous ses éléments pour obtenir la valeur LBP du pixel courant [21]. On obtiendra donc des pixels dont l'intensité se situe entre 0 et 255 comme dans une image 8 bits ordinaire.




Figure 2.8– Structure LBP [52]

2.5 Réseaux bayésiens

Les réseaux bayésiens, qui doivent leur nom aux travaux de Thomas Bayes au dix-huitième siècle sur « la probabilité des causes », sont le résultat de recherches effectuées dans les années 80. [32]

Un réseau bayésien est un modèle graphique probabiliste simple, couramment utilisé. La structure de ce type de réseau est simple : un graphe dans lequel les nœuds représentent des variables aléatoires, et les arcs reliant ces dernières sont rattachées à des probabilités conditionnelles. Notons que le graphe est acyclique : il ne contient pas de boucle. Les arcs représentent des relations entre variables qui sont soit déterministes, soit probabilistes. Ainsi, l'observation d'une ou plusieurs causes n'entraîne pas systématiquement l'effet ou les effets qui en dépendent, mais modifie seulement la probabilité de les observer.

L'intérêt particulier des réseaux bayésiens est de tenir compte simultanément de connaissances a priori d'experts (dans le graphe) et de l'expérience contenue dans les données. [32]

Un réseau bayésien à 5 variables est illustré à la figure 2.9 :




Figure 2.9 - Réseau bayésien à 5 variables [21]

2.6 Deep Learning

Le Deep Learning, ou apprentissage profond, est un sous-ensemble du Machine Learning, ou apprentissage automatique, basé sur des réseaux neuronaux artificiels. Le processus d'apprentissage est qualifié de profond parce que la structure des réseaux neuronaux artificiels se compose de plusieurs couches d'entrées, de sorties et masquées. Chaque couche contient des unités qui transforment les données d'entrée en informations que la couche suivante peut utiliser une tâche prédictive spécifique. Grâce à cette structure, une machine est capable d'apprendre au travers de son propre traitement de données. [47]




Figure 2.10-Relation entre l'IA, Machine Learning et DeepLearning [51]

2.7 Réseaux de neurones convolutifs (CNNs)

Les CNN désignent une sous-catégorie de réseaux de neurones et sont à ce jour un des modèles de classification d'images réputés être les plus performant. Leur mode de fonctionnement est à première vue simple : l'utilisateur fournit en entrée une image sous la forme d'une matrice de pixels. Celle-ci dispose de 3 dimensions :

- Deux dimensions pour une image en niveaux de gris.
- Une troisième dimension, de profondeur 3 pour représenter les couleurs fondamentales (Rouge, Vert, Bleu). [51]

Contrairement à un modèle MLP (Multi Layers Perceptron) qui ne contient qu'une partie classification, l'architecture du Convolutional Neural Network dispose en amont d'une partie convolutive et comporte par conséquent deux parties bien distinctes :

- Une partie convolutive : Son objectif final est d'extraire des caractéristiques propres à chaque image en les compressant de façon à réduire leur taille initiale. En résumé, l'image fournie en entrée passe à travers une succession de filtres, créant par la même occasion de nouvelles images appelées cartes de convolutions. Enfin, les cartes de convolutions obtenues sont concaténées dans un vecteur de caractéristiques appelé code CNN. [51]
- Une partie classification : Le code CNN obtenu en sortie de la partie convolutive est fourni en entrée dans une deuxième partie, constituée de couches entièrement connectées. Le rôle de cette partie est de combiner les caractéristiques du code CNN afin de classer l'image. [51]

Le premier bloc fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un extracteur de features. Pour cela, il effectue du template matching en appliquant des opérations de filtrage par convolution. La première couche filtre l'image avec

plusieurs noyaux de convolution, et renvoie des "feature maps", qui sont ensuite normalisées (avec une fonction d'activation) et/ou redimensionnées. [50]

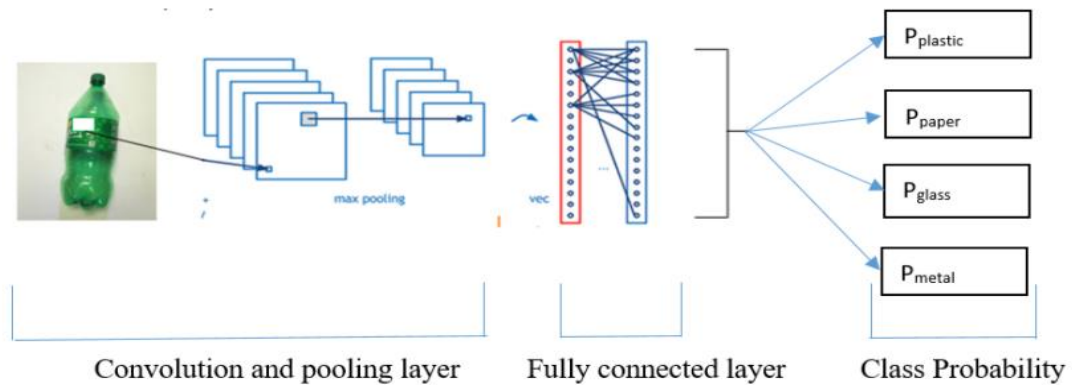


Figure 2.11- Les réseaux de neurones convolutionnels [42]

2.7.1 Fonctionnement d'un CNN

Un CNN typique est construit par la répétition de trois types de couches de base, c'est à dire les couches convolutionnelles (convolutional layers), les couches de mise en commun (pooling layers) et les couches entièrement connectées (fully connected layers). Un réseau neuronal profond empile un grand nombre de ces couches pour effectuer des tâches liées à la reconnaissance et à la détection de formes.[49]

Une architecture CNN est formée par un empilement de couches de traitement indépendantes :

- La couche de convolution (CONV) qui traite les données d'un champ récepteur.
- La couche de pooling (POOL), qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous-échantillonnage).
- La couche de correction (ReLU), souvent appelée par abus 'ReLU' en référence à la fonction d'activation (Unité de rectification linéaire).
- La couche "entièrement connectée" (FC), qui est une couche de type perceptron.
- La couche de perte (LOSS).

2.7.1.1 Couche de convolution

Cette couche est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche. Son but est de repérer la présence d'un ensemble de features dans les images reçues en entrée. Pour cela, on réalise un filtrage par convolution :

le principe est de faire "glisser" une fenêtre représentant la feature sur l'image, et de calculer le produit de convolution entre la feature et chaque portion de l'image balayée. Une feature est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte. [51]

La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images. [51]

On obtient pour chaque paire (image, filtre) une carte d'activation, ou feature map, qui nous indique où se situent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature. [8]




Figure 12- schéma du parcours de la fenêtre de filtre sur l'image [51]

❖ **Choix des features**

Contrairement aux méthodes traditionnelles, les features ne sont pas pré-définies selon un formalisme particulier, mais apprises par le réseau lors de la phase d'entraînement. Les noyaux des filtres désignent les poids de la couche de convolution. Ils sont initialisés puis mis à jour par rétropropagation du gradient. [51]

C'est là toute la force des réseaux de neurones convolutifs : ceux-ci sont capables de déterminer tout seul les éléments discriminants d'une image, en s'adaptant au problème posé. [51]

La couche Conv possède quatre hyperparamètres :

- Le nombre de filtres K
- La taille F des filtres : chaque filtre est de dimensions $F \times F \times D$ pixels.
- Le pas S avec lequel on fait glisser la fenêtre correspondant au filtre sur l'image.
- Le zero-padding P

❖ **Paramètre du filtre**

La couche convolutionnelle contient des filtres pour lesquels il est important de savoir comment ajuster ses paramètres.

1) Dimension d'un filtre

Un filtre de taille $F \times F$ appliqué à une entrée contenant C canaux est un volume de taille $F \times F \times C$ qui effectue des convolutions sur une entrée de taille $I \times I \times C$ et qui produit un feature map de sortie (aussi appelé activation map) de taille $O \times O \times 1$.




Figure 2.13- Dimension d'un filtre [3]

Remarque : appliquer K filtres de taille $F \times F$ engendre un feature map de sortie de taille $O \times O \times K$.

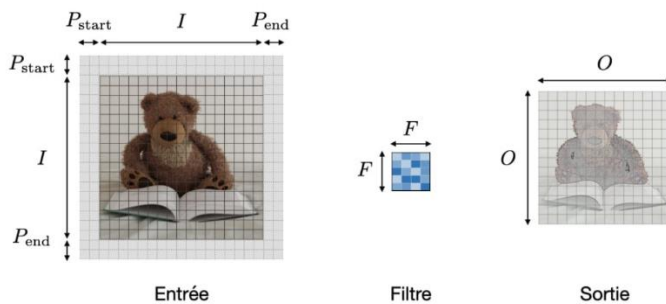


Figure 2.14- Feature map après filtre de convolution. [3]

2) Stride

Dans le contexte d'une opération de convolution ou de pooling, la stride S est un paramètre qui dénote le nombre de pixels par lesquels la fenêtre se déplace après chaque opération. [3]



Figure 2.15- Stride [3]

3) Zero padding

Le zero-padding est une technique consistant à ajouter P zeros à chaque côté des frontières de l'entrée. Cette valeur peut être spécifiée soit manuellement ou automatiquement. [3] On ajoute à l'image en entrée de la couche un contour noir d'épaisseur P pixels. Sans ce contour, les dimensions en sortie sont plus petites. Ainsi, plus on empile de couches de convolution avec P=0, plus l'image en entrée du réseau rétrécit. On perd donc beaucoup d'informations rapidement, ce qui rend la tâche d'extraction de features difficile. [51]

Pour chaque image de taille $W \times H \times D$ en entrée, la couche de convolution renvoie une matrice de dimensions $WC \times HC \times DC$, [29]

$$WC = \frac{w-F+2P}{s} + 1 \quad \text{où} \quad (2.3)$$

$$HC = \frac{H-F+2P}{s} + 1 \quad \text{et} \quad (2.4)$$

$$DC=K. \quad (2.5)$$

2.7.1.2 Couche de Pooling (POOL)

La couche de pooling (POOL) est une opération de sous-échantillonnage typiquement appliquée après une couche conv. En particulier, les types de pooling les plus populaires sont le max et l'average pooling, où les valeurs maximales et moyennes sont prises, respectivement. [3] La couche de pooling se place entre les couches convolutives. Elle permet d'appliquer à chacune des cartes de caractéristiques une réduction de leur taille tout en préservant les caractéristiques les plus importantes (en ne gardant que les valeurs maximales par exemple). Elle permet ainsi de réduire le nombre de paramètres du réseau et donc les calculs nécessaires. Elle permet aussi de rendre le réseau moins sensible à la position des caractéristiques. [8]




Figure 2.16- Le principe de Pooling avec un filtre 2*2 et un pas de 2 [3]

Tableau 2.1 – Max-pooling vs average pooling

Type	Max pooling	Average pooling
But	Chaque opération de pooling sélectionne la valeur maximale de la surface	Chaque opération de pooling sélectionne la valeur moyenne de la surface
Illustration		
Commentaires	<ul style="list-style-type: none"> • Garde les caractéristiques détectées • Plus communément utilisé 	<ul style="list-style-type: none"> • Sous-échantillonne la <i>feature map</i> • Utilisé dans Le Net

La couche de pooling présente seulement deux hyper paramètres :

- La taille F des cellules : l'image est découpée en cellules carrées de taille F×F pixels
- Le pas S : les cellules sont séparées les unes des autres de SS pixels

Pour chaque image de taille W×H×D en entrée, la couche de pooling renvoie une matrice de dimensions WP×HP×DP , où [40]

$$Wp = \frac{w-F}{s} + 1 \quad ; \quad (2.6)$$

$$Hp = \frac{H-F}{s} + 1 \quad \text{et} \quad (2.7)$$

$$DP=D \quad (2.8)$$

2.7.1.3 Couche complètement connecté - Fully Connected (FC)

Elle constitue toujours la dernière couche d'un réseau de neurones convolutif ou non. Elle reçoit un vecteur en entrée contenant les pixels aplatis de toutes les images filtrées, corrigées et réduites par le Pooling et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée. La dernière couche Fully-connected permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille N , où N est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe. [3]




Figure 2.17- Couche fully connected [3]

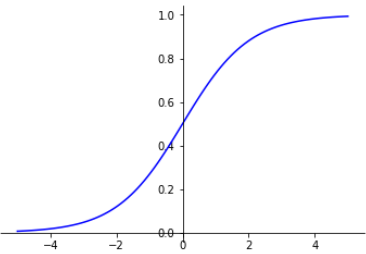
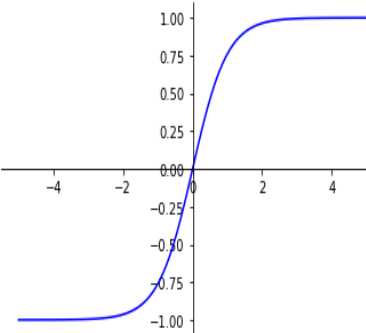
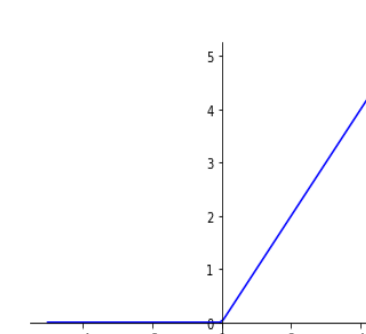
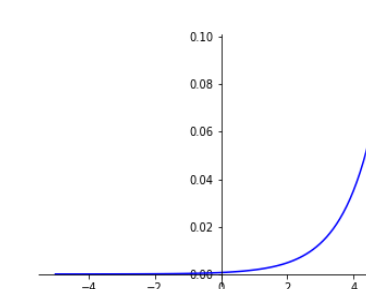
2.7.1.4 Fonctions d'activation

Dans les réseaux de neurones profonds, les fonctions d'activations sont des fonctions non-linéaires puisque l'application récurrente d'une même fonction linéaire n'aurait aucun effet. Ceci permet de séparer les données non-linéairement séparables et donc d'effectuer des classifications plus poussées qu'en apprentissage automatique classique. Autre point très important, les données traitées par les neurones peuvent atteindre des valeurs étonnamment grandes. [8]

L'utilisation d'une fonction linéaire, ne modifié pas la sortie, les valeurs des données transmises de neurones en neurones peuvent devenir de plus en plus grandes et rendant les calculs beaucoup plus complexes. Afin d'y remédier, les fonctions d'activation non linéaires réduisent la valeur de sortie d'un neurone le plus souvent sous forme d'une simple probabilité. [8]

Il existe plusieurs fonctions d'activation, le choix de cette dernière dépend de la fonction du modèle qu'on souhaite modéliser.

Tableau 2.2 – Fonctions d'activation [54]

Fonctions	Equation	Graphe	
<p>Fonction sigmoïde</p>	$\sigma(x) = \frac{1}{1 + e^{-x}}$ <p>pour $x \in \mathbb{R}$.</p>		<p>La fonction Sigmoïde donne une valeur entre 0 et 1, une probabilité. Elle est donc très utilisée pour les classification binaire ,lorsqu'un modèle doit déterminer seulement deux labels.</p>
<p>Fonction Tangente Hyperbolique</p>	$\tanh(x) = \frac{2}{1 + e^{-2x}}$		<p>Tanh permet d'avoir des valeurs entre -1 et 1.</p> <p>L'avantage de tanh est que les entrées négatives seront bien répertoriées comme négatives là où, avec sigmoïde, les entrées négatives peuvent être confondus avec les valeurs proche de nulles.</p>
<p>Rectified Linear Unit (ReLU)</p>	$\text{ReLU}(x) = \max(x, 0)$		<ul style="list-style-type: none"> - Permet d'effectuer un filtre sur nos données. -Laisse passer les valeurs positives ($x > 0$) dans les couches suivantes - Elle est utilisée presque partout mais surtout pas dans la couche final, elle est utilisée dans les couches intermédiaires.
<p>Fonction softmax</p>	$\sigma(X_{n,k}) = \frac{e^{(X_{n,k})}}{\sum_{j=1}^k e^{(X_{n,j})}}$		<p>L softmax est une non-linéarité utilisée pour la dernière couche d'un réseau neuronal profond créé pour une tâche de classification à k classes car elle permet de sortir k probabilités de prédiction dont la somme totale est égale à 1.</p>

2.7.2 L'entraînement d'un CNN

L'entraînement d'un CNN pour une tâche de traitement d'image signifie le calcul d'une perte en comparant les prédictions de sortie avec les sorties ciblées. Pendant l'entraînement, le passage en arrière est calculé. Le passage en arrière peut simplement être décrit comme la sensibilité de la perte par rapport aux changements des paramètres du réseau. L'objectif principal de l'entraînement d'un CNN est de minimiser la fonction de perte dans l'ensemble de données d'entraînement en modifiant les paramètres entraînaables du réseau, tels que les poids et les biais, à l'aide de passage en arrière. [48]

2.7.3 Fonction de perte (Loss Function)

Les fonctions de perte sont les fonctions différentiables utilisées pour guider le processus d'apprentissage d'un réseau neuronal. Pour s'entraîner un CNN pour une tâche de détection d'objets, les réseaux sont généralement optimisés pour les éléments de classification et de régression. Mathématiquement, la fonction de perte mappe la sortie du réseau y et la sortie ciblée \hat{y} sur une valeur réelle représentant la pénalité pour l'inexactitude des prédictions. Les fonctions de perte les plus utilisées pour les problèmes de classification sont l'erreur quadratique moyenne totale (perte TMSE ou L2), entropie croisée (CEL) et la perte Softmax. Pour un problème de régression, les fonctions de perte peuvent varier d'un réseau à l'autre.[54]

▪ Erreur quadratique moyenne (TMSE)

L'erreur quadratique moyenne totale (TMSE) pour la sortie réseau y et la sortie cible \hat{y} est définie comme suit

$$\text{TMSE} = \frac{1}{n \cdot l} \sum_{i=1}^n \|y_i - \hat{y}_i\|^2, \quad (2.9)$$

Où n et l représentent respectivement le nombre d'échantillons d'apprentissage et le nombre de neurones de sortie. Le terme $\|y_i - \hat{y}_i\|$ est la distance euclidienne entre y et \hat{y} . [54]

▪ La perte d'entropie croisée (CEL)

La perte d'entropie croisée pour la sortie réseau y et la sortie cible \hat{y} est définie comme suit .[54] :

$$\text{CEL} = -\frac{1}{N} \sum_{i=1}^N [\hat{y} \log y_i + (1 - \hat{y}) \log(1 - y_i)], \quad (2.10)$$

2.7.4 Les architectures CNN

Les performances des réseaux de neurones profonds dans la détection d'objets reposent sur une grande quantité de données d'apprentissage ainsi que sur la puissance de calcul. La collecte et l'annotation d'un ensemble de données (Dataset) de taille suffisante est un processus mouvementé et qui prend du temps. Par conséquent, la plupart des recherches sur la détection d'objets sont effectuées sur des ensembles de données accessibles au public. Il existe plusieurs ensembles de données de ce type. Nous discutons brièvement de quelques architectures CNN les plus courantes et récentes.

2.7.4.1 AlexNet

On ne peut pas parler de Deep Learning sans mentionner AlexNet. C'est en effet le pionnier des réseaux de neurones dédié à la classification des images. Développé par Alex Krizhevsky, Ilya Sutskever et Geoffrey Hinton, il est le premier réseau de neurones à remporter en 2012 le Challenge ILSVRC de la classification des images. Aujourd'hui, et depuis lors, les algorithmes évalués reposent presque tous sur des réseaux de neurones. AlexNet a eu un impact énorme sur le domaine et la plupart des réseaux de neurones étaient plus ou moins basés sur son architecture. [27]

AlexNet est composé de 5 couches convolutionnelles, suivies de deux couches entièrement connectées (permettant d'effectuer la classification à proprement parler), puis d'une couche finale softmax (permettant d'attribuer aux objets détectés les probabilités d'appartenance aux différentes classes). [27]

L'idée de ce réseau dédié à la classification d'images couleur de 227x227 pixels est la suivante : chaque couche convolutionnelle apprend une représentation plus détaillée des images que la précédente ; la première couche est capable de reconnaître des formes très simples, la dernière des formes complexes telles que des visages. L'enchaînement des couches de convolutions permet de réduire drastiquement l'information à analyser en passant progressivement d'un vecteur de 227x227x3 coordonnées à un vecteur signature de 4096 coordonnées. Les deux couches entièrement connectées et le softmax jouent le rôle d'un classifieur classique de type Random Forests ou SVM (Support Vector Machine). [27]




Figure 2.18 - Architecture AlexNet . [27]

2.7.4.2 VGGNet

VGGNet a été proposé en 2014 par Simonyan et al. L'équipe de Visual Geometry Group (VGG) ont inventés le VGG-16 qui a 13 couches convolutionnelles (CONV) et 3 couches Fully Connected (FC). Ils ont remplacés le filtre 11×11 AlexNet et le filtre 7×7 ZF Net par un filtre 3×3 dans leur modèle. Il se compose de 138 millions de paramètres et occupe environ 500 Mo d'espace de stockage. Compétition ILSVRC. [24]

2.7.4.3 VGG 16

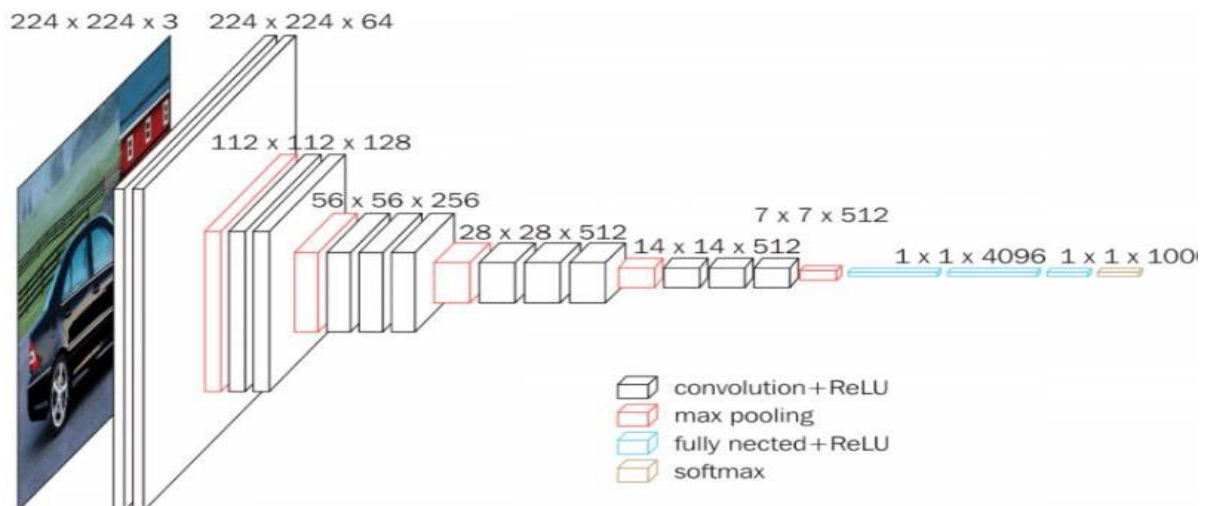


Figure 2.19 -Architectur VGGNet .[24]

Le modèle VGG, ou VGGNet, qui prend en charge 16 couches est également appelé VGG16, qui est un modèle de réseau neuronal convolutionnel proposé par A. Zisserman et K. Simonyan de l'Université d'Oxford. Le modèle VGG16 atteint près de 92,7 % de précision

dans le top 5 des tests dans ImageNet. ImageNet est une base de données composé de plus de 14 millions d'images appartenant à près de 1000 classes. [24]

De plus, c'était l'un des modèles les plus populaires soumis à ILSVRC-2014 . Il remplace les grands filtres de la taille d'un noyau par plusieurs filtres de la taille d'un noyau 3×3 les uns après les autres, apportant ainsi des améliorations significatives par rapport à AlexNet. Le modèle VGG16 a été formé à l'aide de GPU Nvidia Titan Black pendant plusieurs semaines. [24]




Figure 2.20 - Structure VGG 16. [24]

Comme mentionné ci-dessus, le VGGNet-16 prend en charge 16 couches et peut classifier les images en 1000 catégories d'objets, y compris le clavier, les animaux, le crayon, la souris, etc. De plus, le modèle a une taille d'entrée d'image de 224 par 224. [24]




Figure 2. 21 -Architectur VGG16. [24]

2.7.4.4 VGG 19

VGG19 est une variante du modèle VGG qui se compose en bref de 19 couches (16 couches de convolution, 3 couches entièrement connectées, 5 couches MaxPool et 1 couche SoftMax). . VGG19 a 19,6 milliards de FLOP . [24]

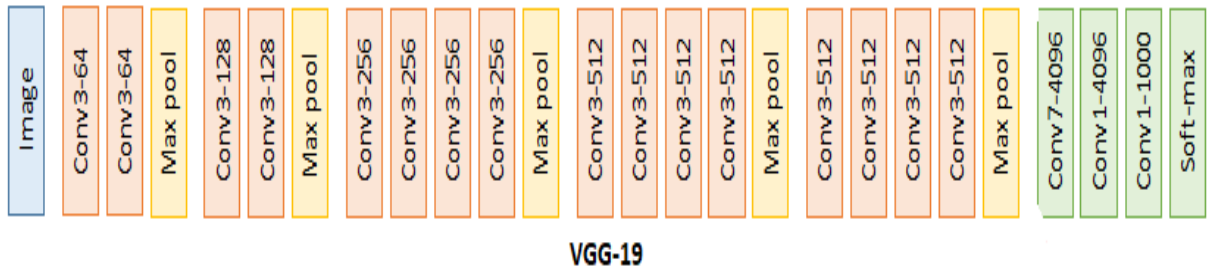


Figure 2.22- Structure VGG -19 [24]

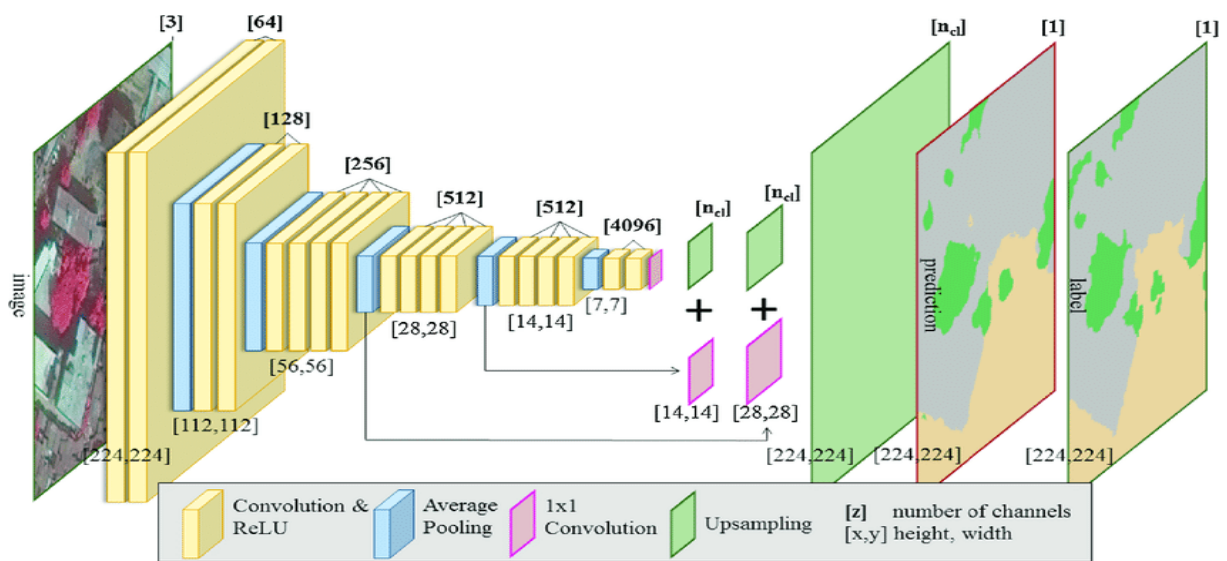


Figure 2.23 - Architecture VGG 19. [24]

L'architecture adapter par VGG19 est [24] :

- Une taille fixe de (224 * 224) image RVB a été donnée en entrée à ce réseau, ce qui signifie que la matrice était de forme (224,224,3).
- Le seul prétraitement effectué consiste à soustraire la valeur RVB moyenne de chaque pixel, calculée sur l'ensemble de l'apprentissage.
- Utiliser des noyaux de taille (3 * 3) avec une taille de pas de 1 pixel, cela leur a permis de couvrir toute la notion d'image.
- Un rembourrage spatial a été utilisé pour préserver la résolution spatiale de l'image.
- Max pooling a été effectué sur une fenêtre de 2 * 2 pixels avec stride 2.

- Cela a été suivi par Unité linéaire rectifiée (ReLU) pour introduire la non-linéarité afin de mieux classer le modèle et d'améliorer le temps de calcul, car les modèles précédents utilisaient des fonctions tanh ou sigmoïdes, ce qui s'est avéré bien meilleur que ceux-là.
- Implémenté trois couches entièrement connectées dont les deux premières étaient de taille 4096 et après cela une couche avec 1000 canaux pour la classification ILSVRC à 1000 voies et la couche finale est une fonction softmax.

2.7.4.5 ResNet-50

ResNet (Residual Neural Network) est une architecture de réseau profond avec 152 couches [10]. Ceci a été développé par Microsoft en 2015. Il a remporté l'ILSVRC 2015 avec un taux d'erreur de 3,6%, ce qui est considéré comme meilleur que la précision au niveau humain. Les couches résiduelles dans ResNet calculent les changements dans l'entrée. Ceci est ensuite ajouté à l'entrée pour produire la sortie. ResNet-50 est l'un des premiers à adopter la normalisation des batches. Le ResNet est constitué de deux blocs CONV et Identité. [19]

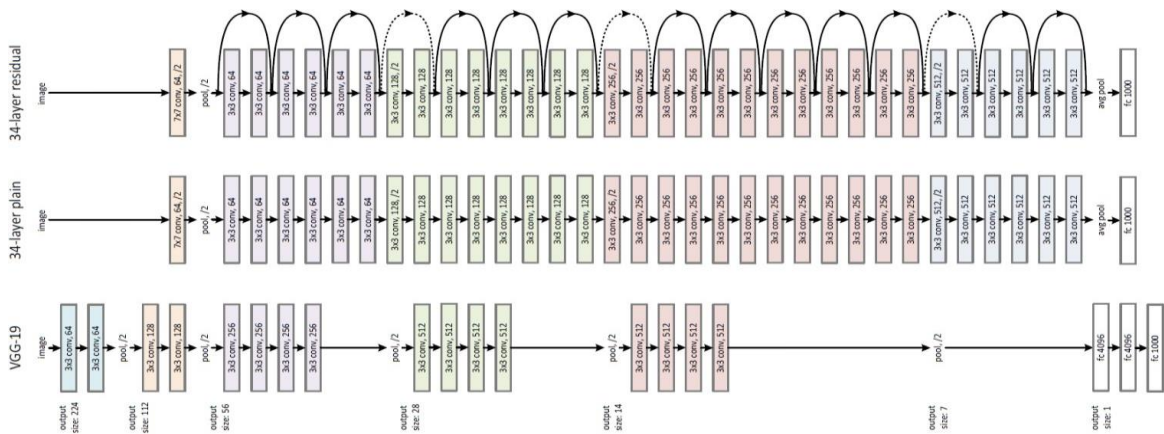


Figure 2.24 - Architecture ResNet-50 [19].

2.8 L'apprentissage automatique & la classification des déchets

Avant de parler des différents travaux d'apprentissage automatique dans la catégorisation des images de déchets, nous prendrons un aperçu des techniques traditionnelles, puis nous plongerons dans les technologies intelligentes.

2.8.1 Les approches traditionnelles

- Dans [16] ont proposé une méthode pour améliorer la qualité de la collecte sélective en suivant le flux de déchets d'une ville, où chaque déchet est détecté à partir d'informations stockées sur une étiquette RFID (associée aux déchets) et lors de l'étape de traitement des

déchets étiquettes RFID sont lus pour fournir des informations pertinentes.

- Dans [5] a été proposé d'estimer le volume des déchets ménagers sur la base d'une analyse d'image du contenu du couvercle du conteneur ouvert à partir d'étiquettes RFID, telles que l'étiquette serait utilisée pour associer chaque bac à l'adresse de la maison qui en est propriétaire.
- Dans [1], les auteurs ont discuté des applications de la technologie RFID dans l'autogestion des produits, en mettant l'accent sur la gestion des déchets solides municipaux et ses implications environnementales, également en identifiant chaque bac à partir d'une étiquette RFID.
- Dans [10], les auteurs ont proposé un capteur RFID (pour stocker le poids de la poubelle et identifier le propriétaire de chaque poubelle) qui mesure dans chaque opération de collecte, le poids de la poubelle jetée dans le camion poubelle.
- Sinha et al. [40] ont développé une méthode capable de sélectionner le meilleur conteneur de recyclage compte tenu des déchets jetés par l'utilisateur. Ils ont présenté un modèle utilisant l'Ontology Web Language (OWL) pour trier les déchets intelligents pour un meilleur recyclage des matériaux. Ils utilisent l'ontologie OWL pour représenter des informations sur la quantité de matériaux recyclables précieux contenus dans chaque déchet.

2.8.2 Les approches intelligentes

De nombreux modèles différents ont été développés pour la classification des images, comme RNN, SVM, ANN, etc., mais Convolutional Neural Network, qui est un algorithme d'apprentissage automatique, a vraiment mieux performé qu'eux tous.

- En 2016, Yang et Thung [42] ont publié un ensemble de données **Trashnet** (figure 2.25) composé de six classes : verre, papier, carton, plastique, métal et poubelle en utilisant l'algorithme SVM de machine Learning, avec une transformation de caractéristique invariante d'échelle (SIFT¹) et un réseau de neurones convolutifs (CNN). Leurs approches ont atteint un taux de précision de 63% et 22% pour le SVM formé et le CNN, respectivement.



FIGURE 2.25- Les 6 classes de data set TrashNet [42]

- En 2018 Aral et al. [36] ont utilisé les modèles d'apprentissage par transfert provenant de plusieurs modèles CNN bien connus pour la classification d'images, notamment Densenet, pour classer les déchets dans l'ensemble de données Trashnet. Dans leurs expériences, les auteurs ont utilisé 70% de l'ensemble de données Trashnet pour la formation, 13% pour la validation et 17% pour les tests. De plus, le lot et la taille d'entrée ont été sélectionnés respectivement à 8 et 224×224 . Selon les résultats expérimentaux, un modèle d'apprentissage par transfert de DenseNet a archivé la meilleure précision qui donne 95%.
- Ensuite en 2018, Bircanoglu et al. [9] ont développé un modèle de réseau neuronal convolutionnel, pour la classification des déchets. Bien que le modèle n'ait atteint que 81% en termes de précision pour l'ensemble de données Trashnet avec 70% d'images pour la formation, 13% pour la validation et 17% pour les tests, il a réduit la complexité du temps en réduisant le nombre de paramètres de sept millions à trois millions.
- En 2018 Kennedy et al. [43] ont utilisé VGG-19 pour classer les déchets et ont atteint une précision de 88,42% après 150 epoch. Ils ont supprimé les couches de classification FC et ajouté une couche cachée dense.
- En 2019 [44] les auteurs ont évalué l'utilisation de plusieurs modèles CNN, notamment ResNet pour la classification automatique des déchets. Dans cette étude, les auteurs ont utilisé 80% de l'ensemble de données Trashnet pour la formation, 10% pour la validation et les 10% restants pour les tests. Les meilleurs résultats de performance ont été obtenus en utilisant une architecture basée sur ResNet avec 88,66% en termes de précision moyenne pour l'ensemble de données Trashnet.

- En 2022 Neelesh Karthikeyan [33] utilise des architecture pré trainé de réseau de neurone CNN qui existe dans la bibliothèque keras. Avec VGG 16 et VGG19 atteint que 81% enternes de précision pour l'ensemble de données Trashnet avec 80% d'images pour la formation, 10% pour la validation et 10% pour les tests. Les meilleurs résultats de performance ont été obtenus avec NASNetMobile avec 97% en termes de précision moyenne pour l'ensemble de données Trashnet.

2.9 Conclusion

Ce chapitre a été consacré à la présentation des notions de bases de Machine Learning et ses type d'apprentissage, Deep Learning , et ceci dans le but d'introduire les réseaux de neurones convolutionnels .

En passant par l'explication de concepts plus général des réseaux de neurones Artificiel ANNs en particulier les perceptrons multicouches, Nous nous sommes intéressés en suite aux réseaux de neurones convolutionnels (définition, structure et fonctionnement) et nous avons cité quelque architecture.

Aussi dans le dernier point nous avons établi un état de l'art sur les différentes approches techniques de classification des déchets

Le chapitre qui suit, on va présenter notre contribution ainsi que nos modèles et algorithmes utilisés dans notre architecture.

Chapitre 3

Résultats expérimentaux et évaluation

3.1 Introduction

Au cours de ce chapitre, nous allons présenter les architectures proposées pour la classification d'images dans un système de gestion de déchets. Les solutions proposées seront évaluées via des métriques d'évaluation afin de déterminer leurs degrés d'efficacité et fiabilité.

Nous montrons ainsi les expériences et les résultats des tests réalisés afin d'estimer la qualité de nos modèles et leurs performances comparées aux autres modèles qui existent, après nous discutons les résultats obtenus.

3.2 Ressources matérielles et logicielles utilisées

Nous avons utilisé le matériel et les logicielles suivants :

3.2.1 Ressources matérielles

La configuration du matériel utilisé dans notre implémentation est :

- ✓ PC : HP I7-9700 CPU @3.00GHz
- ✓ RAM : 8 GO
- ✓ Disque dur : 1 TO
- ✓ Système d'exploitation : Windows 10 Professionnel 64 bits

3.2.2 Ressources logicielles et Environnement de développement

a) Python

Python est un langage de programmation open source de haut niveau interprété pour la programmation à usage général développé pour une utilisation avec une large gamme de systèmes d'exploitation. Créé par Guido van Rossum, et publié pour la première fois en 1991. Il est qualifié de langage de programmation le plus puissant en raison de sa nature dynamique et diversifiée. Python est facile à utiliser avec une syntaxe super simple pour les apprenants débutants.[57]

b) Google Colaboratory

Colaboratory, souvent raccourci en "Colab", est un produit de Google Research. Il permet à n'importe qui d'écrire et d'exécuter le code Python de son choix par le biais du navigateur. C'est un environnement particulièrement adapté au machine learning, à l'analyse de données et à l'éducation. En termes plus techniques, Colab est un service hébergé de notebooks Jupyter qui ne nécessite aucune configuration. [59]

c) Bibliothèques Python

Il existe un grand nombre de librairies et de framework dans le domaine de l'apprentissage machine et l'imagerie par ordinateur, nous allons décrire quelques-unes qui nous avons utilisé dans notre travail.

- **TensorFlow** : TensorFlow est une bibliothèque open source, permettant d'exécuter des applications de machine learning et de deep learning. Cet outil dédié à l'apprentissage automatique a été développé par Google, et est fortement utilisé dans le domaine de l'intelligence artificielle (IA). Ainsi, des professionnels comme des novices peuvent créer des modèles de machine learning ou de deep learning pour optimiser les capacités de leur matériel. [60].
- **Keras** : Keras est **une API de réseau de neurones écrite en langage Python**. Il s'agit d'une bibliothèque Open Source, exécutée par-dessus des frameworks tels que Theano et TensorFlow.. Le but de cette bibliothèque est de permettre la constitution rapide de réseaux neuronaux. Dans ce cadre, Keras ne fonctionne pas comme un framework propre mais comme une interface de programmation applicative (API) pour l'accès et la programmation de différents frameworks d'apprentissage automatique. [61]
- **Scikit-learn** : est une bibliothèque libre Python destinée à l'apprentissage automatique. Elle est développée par de nombreux contributeurs notamment dans le monde académique par des instituts français d'enseignement supérieur et de recherche comme Inria3. Elle propose dans son framework de nombreuses bibliothèques d'algorithmes à implémenter clé en main, à disposition des data scientists. Elle comprend notamment des fonctions pour estimer des forêts aléatoires, des régressions logistiques, des algorithmes de classification, et les machines à vecteurs de support. Elle est conçue pour s'harmoniser avec d'autres bibliothèques libres Python, notamment NumPy et SciPy. [62]

• **NumPy** : est une extension du langage de programmation Python, destinée à manipuler des matrices ou tableaux multidimensionnels ainsi que des fonctions mathématiques opérant sur ces tableaux. Plus précisément, cette bibliothèque logicielle libre et open source fournit de multiples fonctions permettant notamment de créer directement un tableau depuis un fichier ou au contraire de sauvegarder un tableau dans un fichier, et manipuler des vecteurs, matrices et polynômes. [62]

• **Matplotlib** : Pour pouvoir afficher et visualiser les résultats statistiques sous forme de courbes, histogrammes, points et autre, en 2D, ou en 3D.

• **Train-Test Split** : Permet de décomposer de manière aléatoire un ensemble de données. Une partie servira à l'entraînement du modèle de Machine Learning, l'autre partie permettra de le tester pour la validation. [55]

3.3 Base de données

Nous avons utilisé dans notre projet le dataset « TrashNet » crée par Yang et Thung en 2016. Les photos ont été prises en plaçant l'objet sur un tableau blanc et en utilisant la lumière du soleil et / ou l'éclairage de la pièce. Les images ont été redimensionnées à 512 x 384. La taille de la base de données d'origine dépasse environ 3,5 Go. Elle contient six catégories : verre, papier, carton, plastique, métal et déchets, elle comprend au total 2527 photos : [42]

Tableau 3.1. Les différentes catégories du TrashNet

Catégorie	Nombre d'image
Verres	501
Papiers	594
Cartons	403
Plastique	482
Métal	410
Poubelle	137
Total	2527

Un échantillon de mélange de différentes catégories de cette dataset est présenté dans la figure suivante :



Figure 3.1 – Echantillon de données de TrashNet [42]

3.4 Indicateurs de performance en classification

L'étape d'évaluation s'avère être une étape importante dans la démarche de choix du modèle, d'où la nécessité d'avoir un outil de précision qui nous permet de mener cette étape en bonne et due forme.

3.4.1 Métrique d'évaluation

Pour pouvoir valider le modèle proposé, certaines métriques doivent être évaluées à base de la matrice de confusion. Des mesures sont utilisées comme l'Accuracy (Taux de reconnaissance), Précision, Sensibilité (Taux de rappel, Recall en anglais), et Fscore, Spécificité, Fitness, Les attributs sélectionnés.

Ces mesures sont basées sur le nombre de vrais positifs (TP), de faux positifs (FP), de vrais négatifs (TN) et de faux négatifs (FN) et sont définies comme suit :

- **TP:** Le classifieur arrive à classer l'attribut comme vrais positifs
- **TN:** le classifieur arrive à classer l'attribut comme vrais négatifs .

- **FP**: le classifieur identifie l'attribut comme étant positif sachant que l'étiquetage réel indique qu'il est négatif.

- **FN** : le classifieur identifie l'attribut comme étant négatif sachant que l'étiquetage réel indique qu'il est positif.

Tableau 3.2- Métrique d'évaluation

Mesure	Formule
Accuracy	$Accuracy = \frac{TP + TN}{TP + FP + FN + TN}$
Recall (Sensibilité)	$Recall = \frac{TP}{(TP + FN)}$
Précision	$Precision = \frac{TP}{(TP + FP)}$
F-score (F-Measure)	$F - Score = 2 * \frac{précision * rappel}{précision + rappel}$

3.4.2 Matrice de confusion

La performance d'un algorithme de Machine Learning est directement liée à sa capacité à prédire un résultat. Lorsque l'on cherche à comparer les résultats d'un algorithme à la réalité, on utilise une matrice de confusion.

La matrice de confusion est un outil utile pour évaluer les performances d'un classificateur dans la reconnaissance et la prédiction des images de différentes classes. La matrice de confusion est un outil utile pour analyser dans quelle mesure votre classificateur peut reconnaître les images de différentes classes. C'est une table de taille (n x n), où n est le nombre de classes. Chaque colonne de la matrice représente les classifications prévues et chaque ligne représente les classifications définies réelles.[55]

	Classe prédite	
Classe Réelle	<i>True Positive</i>	<i>False Negative</i>
	<i>False Positive</i>	<i>True Negative</i>

Figure 3.2- Matrice de confusion [55]

3.4.3 Courbe ROC (Received Operating Characteristic)

Dans le cas d'un classifieur binaire, il est possible de visualiser les performances du classifieur sur ce que l'on appelle une courbe ROC. La courbe ROC est une représentation du taux de vrais positifs en fonction du taux de faux positifs. Son intérêt est de s'affranchir de la taille des données de test dans le cas où les données sont déséquilibrées.

Cette représentation met en avant un nouvel indicateur qui est l'aire sous la courbe. Plus elle se rapproche de 1, plus le classifieur est performant. [56]




Figure 3.3- Courbe ROC

3.5 Architecture proposé

Dans cette partie, nous allons évaluer les performances des modèles proposés tels que MLP, CNN, VGG 16 et aussi VGG 19.

En raison de la complexité de l'entraînement de notre code, il n'est pas très utile de le faire fonctionner localement. Nous avons exécuté nos modèles dans Google Colab pro version payante.

Comme il a été mentionné précédemment, nous avons utilisé l'ensemble de données Trashnet. Dans ce qui suit, nous présenterons les résultats obtenus dans plusieurs perspectives.

3.5.1 Préparation et chargement de la Base de données :

Pour L'ensemble de nos modèles nous avons répartis la base Trashnet en deux partie Training et Test par la technique Train-Test Split comme suit :

- Train :70% , Test :30% - Train :50% , Test :50% - Train :30% , Test :70%

La technique Train-Test Split :

```
from sklearn.model_selection import train_test_split
x_train, x_test, y_train, y_test = train_test_split(X_img,YY, test_size= taux/100, random_state=27)
```

3.6 Résultats et discussion

Afin de montrer les résultats obtenus pour les cinq modèles, on illustre dans ce qui suit les résultats en termes de précision et d'erreur ainsi que matrice de confusion pour chacun de ces modèles.

3.6.1 Réseaux de neurones (Perspective multi couches – MLP -)

Nous avons créé trois modèles avec MLP. Dans le premier modèle nous avons utilisé l'image en entrée avec la taille réelle, pour le deuxième modèle nous avons adapté la taille 28×28 et dans le dernier modèle nous avons appliqué le descripteur LBP.

Vue le nombre des tests effectuer sur ce modèle nous avons divisé Trashnet en premier temps :Train 70%,Test :30% ensuite Train 50%,Test :50%

Dans nos expérimentations, nous proposons de tester nos modèles en jouant sur le nombre de couches cachés 10 ,70 et 150.

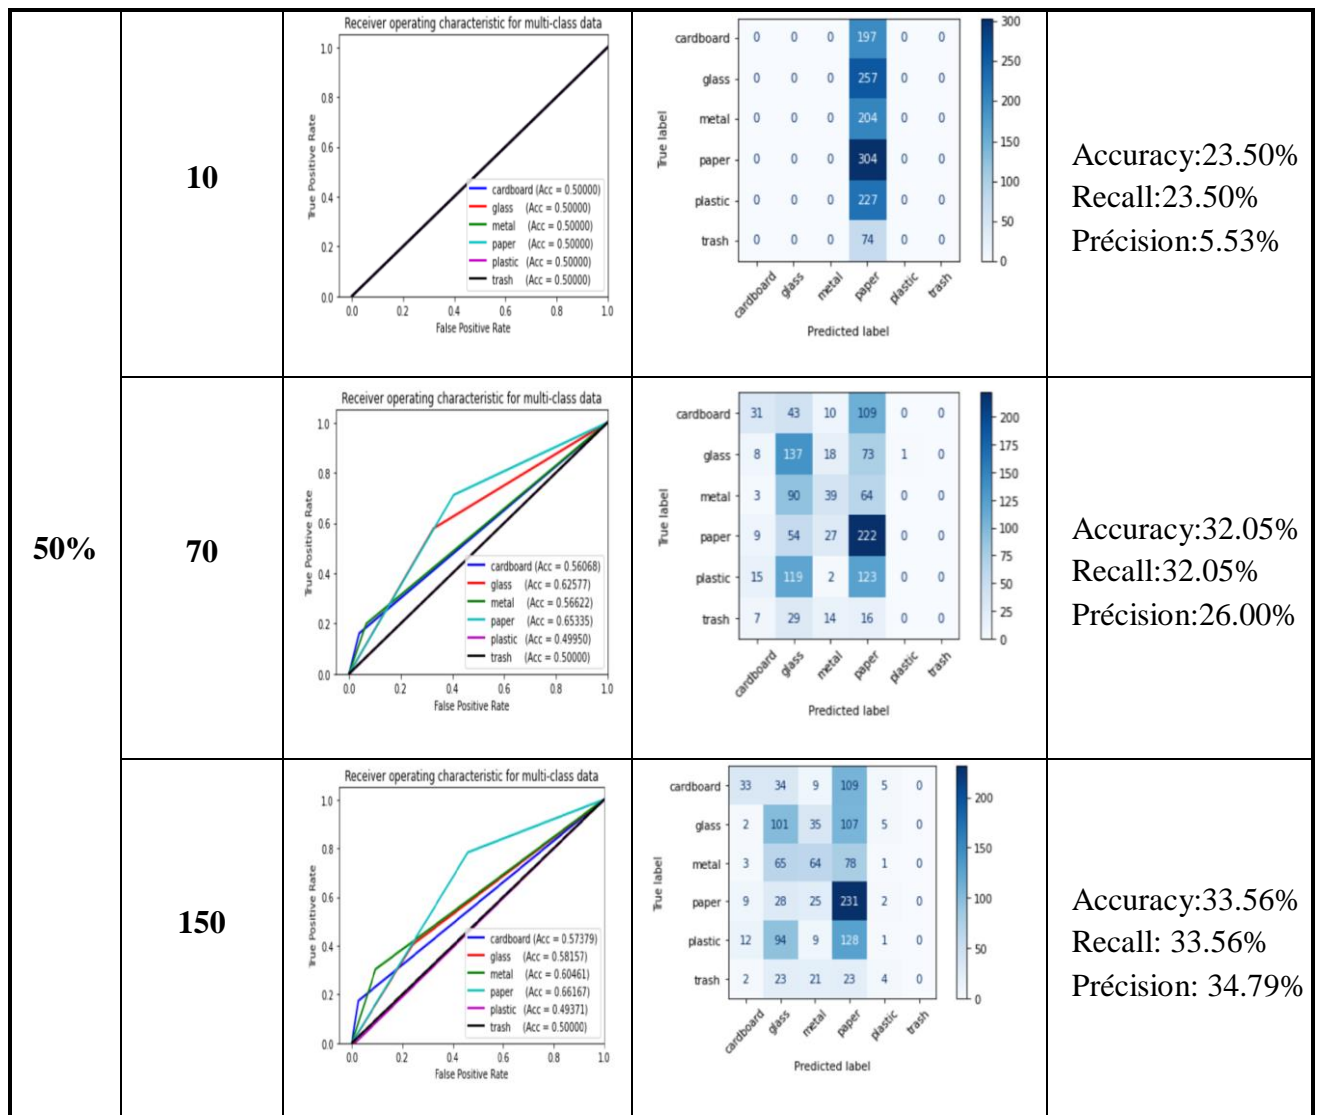
Concernant le Nombre d'itération, il a été fixé à 200 (epochs=200), avec un batch_size de 32.

Le tableau ci-dessous montrent les résultats obtenus.

- **Modèle 01 : Taille Réelle (512 x 384)**

Tableau 3.3- Résultat du Modèle 01 avec MLP

Taux Train	Nombre de couche	ROC	Matrice de confusion	Résultats																																										
70%	10	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.50000) glass (Acc = 0.50286) metal (Acc = 0.50000) paper (Acc = 0.51472) plastic (Acc = 0.50000) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>0</td><td>0</td><td>0</td><td>113</td><td>0</td><td>0</td></tr> <tr><td>glass</td><td>0</td><td>0</td><td>0</td><td>162</td><td>0</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>0</td><td>0</td><td>129</td><td>0</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>0</td><td>0</td><td>176</td><td>0</td><td>0</td></tr> <tr><td>plastic</td><td>0</td><td>0</td><td>0</td><td>144</td><td>0</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>0</td><td>0</td><td>34</td><td>0</td><td>0</td></tr> </table>	cardboard	0	0	0	113	0	0	glass	0	0	0	162	0	0	metal	0	0	0	129	0	0	paper	0	0	0	176	0	0	plastic	0	0	0	144	0	0	trash	0	0	0	34	0	0	<p>Accuracy:23.68%</p> <p>Recall:23.68%</p> <p>Précision:7.73%</p>
	cardboard	0	0	0	113	0	0																																							
	glass	0	0	0	162	0	0																																							
metal	0	0	0	129	0	0																																								
paper	0	0	0	176	0	0																																								
plastic	0	0	0	144	0	0																																								
trash	0	0	0	34	0	0																																								
70	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.53638) glass (Acc = 0.61760) metal (Acc = 0.56577) paper (Acc = 0.68766) plastic (Acc = 0.54230) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>10</td><td>25</td><td>6</td><td>75</td><td>8</td><td>0</td></tr> <tr><td>glass</td><td>2</td><td>72</td><td>15</td><td>41</td><td>13</td><td>0</td></tr> <tr><td>metal</td><td>1</td><td>50</td><td>25</td><td>40</td><td>4</td><td>0</td></tr> <tr><td>paper</td><td>1</td><td>24</td><td>12</td><td>147</td><td>5</td><td>0</td></tr> <tr><td>plastic</td><td>0</td><td>53</td><td>2</td><td>65</td><td>20</td><td>0</td></tr> <tr><td>trash</td><td>1</td><td>13</td><td>14</td><td>8</td><td>6</td><td>0</td></tr> </table>	cardboard	10	25	6	75	8	0	glass	2	72	15	41	13	0	metal	1	50	25	40	4	0	paper	1	24	12	147	5	0	plastic	0	53	2	65	20	0	trash	1	13	14	8	6	0	<p>Accuracy:29.77%</p> <p>Recall:29.77%</p> <p>Précision:28.81%</p>	
cardboard	10	25	6	75	8	0																																								
glass	2	72	15	41	13	0																																								
metal	1	50	25	40	4	0																																								
paper	1	24	12	147	5	0																																								
plastic	0	53	2	65	20	0																																								
trash	1	13	14	8	6	0																																								
150	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.57919) glass (Acc = 0.57788) metal (Acc = 0.61082) paper (Acc = 0.70410) plastic (Acc = 0.51057) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>7</td><td>17</td><td>11</td><td>97</td><td>15</td><td>0</td></tr> <tr><td>glass</td><td>0</td><td>47</td><td>31</td><td>38</td><td>30</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>29</td><td>36</td><td>28</td><td>8</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>11</td><td>26</td><td>128</td><td>15</td><td>0</td></tr> <tr><td>plastic</td><td>3</td><td>38</td><td>9</td><td>65</td><td>29</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>9</td><td>13</td><td>9</td><td>9</td><td>0</td></tr> </table>	cardboard	7	17	11	97	15	0	glass	0	47	31	38	30	0	metal	0	29	36	28	8	0	paper	0	11	26	128	15	0	plastic	3	38	9	65	29	0	trash	0	9	13	9	9	0	<p>Accuracy:35.62%</p> <p>Recall: 35.62%</p> <p>Précision: 36.39%</p>	
cardboard	7	17	11	97	15	0																																								
glass	0	47	31	38	30	0																																								
metal	0	29	36	28	8	0																																								
paper	0	11	26	128	15	0																																								
plastic	3	38	9	65	29	0																																								
trash	0	9	13	9	9	0																																								

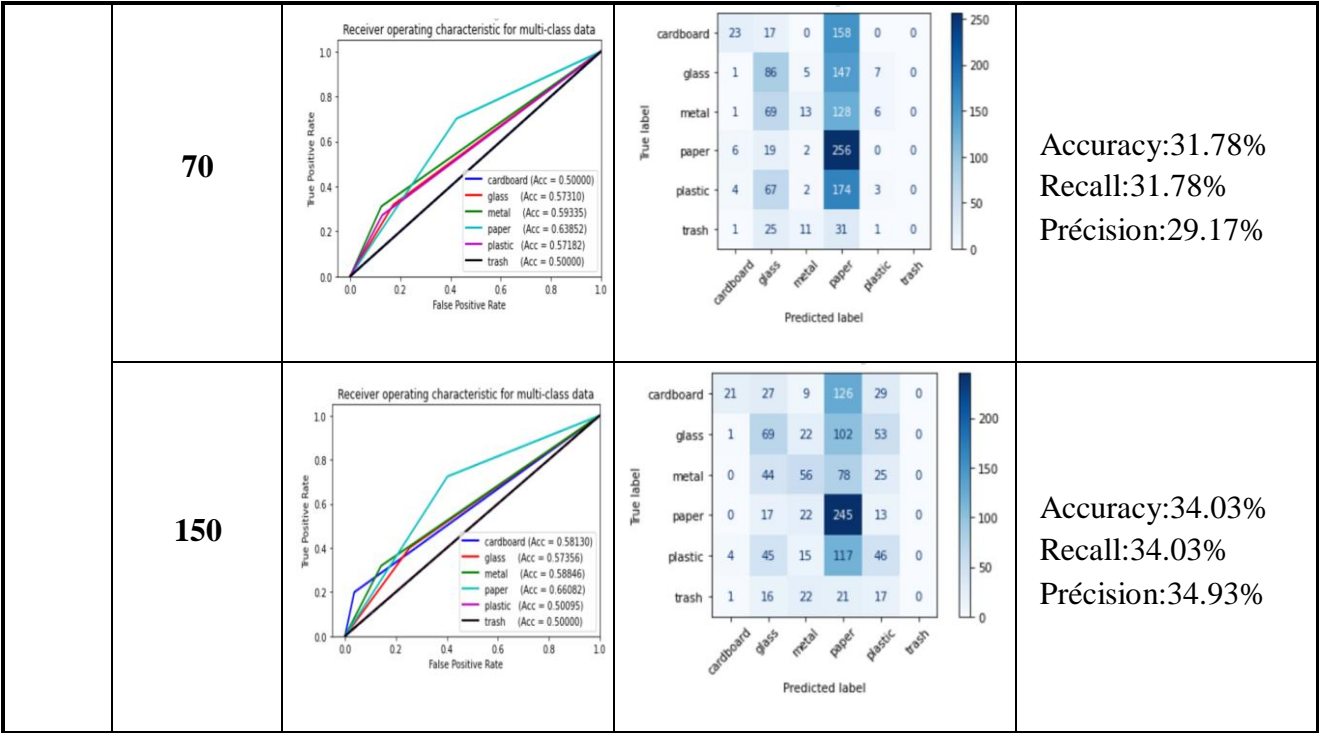


Après plusieurs exécutions Nous avons remarqué que le meilleur taux Accuracy et précision atteint par ce modèle est de 35.62% et 36.39% respectivement pour un taux Train =70% et nombre couches =150 , et d'après la matrice de confusion nous concluons que tant que le nombre de couches est faible le modèle a du mal à reconnaître les classes sauf la classe Paper qui a été bien reconnue .

• **Modèle 02: Taille (28 x 28)**

Tableau3.4 - Résultat du Modèle 02 avec MLP

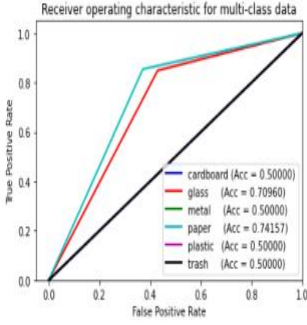
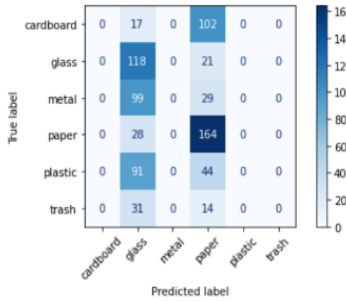
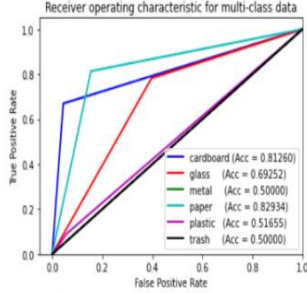
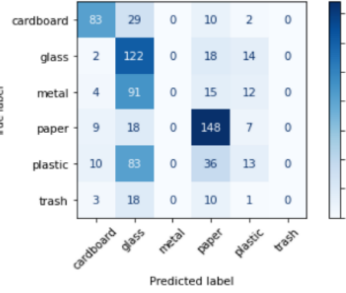
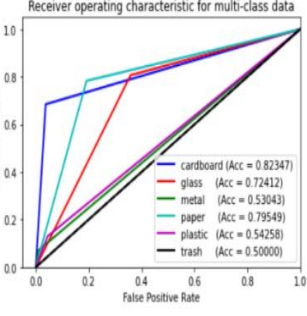
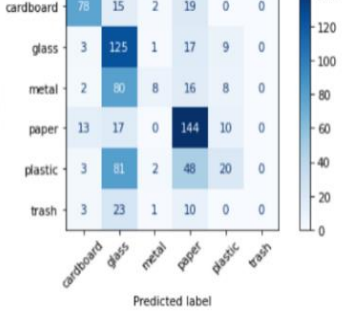
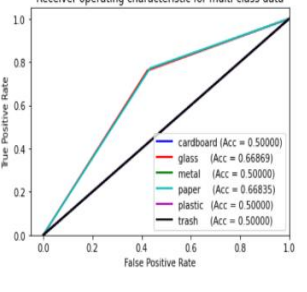
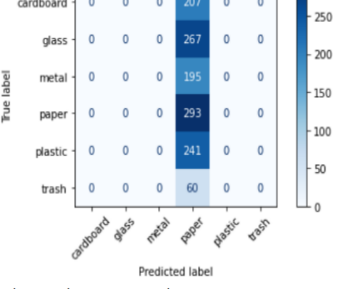
Taux	Nombre de couche	ROC	Matrice de confusion	Résultats																																										
70%	10	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.50000) glass (Acc = 0.51084) metal (Acc = 0.50000) paper (Acc = 0.52086) plastic (Acc = 0.50000) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>0</td><td>3</td><td>0</td><td>115</td><td>0</td><td>0</td></tr> <tr><td>glass</td><td>0</td><td>8</td><td>0</td><td>139</td><td>0</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>3</td><td>0</td><td>129</td><td>0</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>1</td><td>0</td><td>184</td><td>0</td><td>0</td></tr> <tr><td>plastic</td><td>0</td><td>1</td><td>0</td><td>129</td><td>0</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>12</td><td>0</td><td>34</td><td>0</td><td>0</td></tr> </table>	cardboard	0	3	0	115	0	0	glass	0	8	0	139	0	0	metal	0	3	0	129	0	0	paper	0	1	0	184	0	0	plastic	0	1	0	129	0	0	trash	0	12	0	34	0	0	<p>Accuracy:24.22%</p> <p>Recall:24.22%</p> <p>Précision:8.52%</p>
	cardboard	0	3	0	115	0	0																																							
	glass	0	8	0	139	0	0																																							
metal	0	3	0	129	0	0																																								
paper	0	1	0	184	0	0																																								
plastic	0	1	0	129	0	0																																								
trash	0	12	0	34	0	0																																								
70	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.54833) glass (Acc = 0.57778) metal (Acc = 0.55310) paper (Acc = 0.66798) plastic (Acc = 0.50893) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>11</td><td>20</td><td>2</td><td>71</td><td>3</td><td>0</td></tr> <tr><td>glass</td><td>2</td><td>72</td><td>12</td><td>59</td><td>6</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>56</td><td>22</td><td>54</td><td>6</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>23</td><td>10</td><td>127</td><td>2</td><td>0</td></tr> <tr><td>plastic</td><td>2</td><td>76</td><td>2</td><td>73</td><td>8</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>20</td><td>7</td><td>10</td><td>2</td><td>0</td></tr> </table>	cardboard	11	20	2	71	3	0	glass	2	72	12	59	6	0	metal	0	56	22	54	6	0	paper	0	23	10	127	2	0	plastic	2	76	2	73	8	0	trash	0	20	7	10	2	0	<p>Accuracy:31.29%</p> <p>Recall:31.29%</p> <p>Précision:29.87%</p>	
cardboard	11	20	2	71	3	0																																								
glass	2	72	12	59	6	0																																								
metal	0	56	22	54	6	0																																								
paper	0	23	10	127	2	0																																								
plastic	2	76	2	73	8	0																																								
trash	0	20	7	10	2	0																																								
150	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.58611) glass (Acc = 0.57824) metal (Acc = 0.54767) paper (Acc = 0.62289) plastic (Acc = 0.50000) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>11</td><td>18</td><td>8</td><td>79</td><td>12</td><td>0</td></tr> <tr><td>glass</td><td>1</td><td>49</td><td>33</td><td>36</td><td>35</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>36</td><td>44</td><td>27</td><td>13</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>12</td><td>21</td><td>131</td><td>6</td><td>0</td></tr> <tr><td>plastic</td><td>0</td><td>39</td><td>8</td><td>61</td><td>23</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>13</td><td>20</td><td>13</td><td>9</td><td>0</td></tr> </table>	cardboard	11	18	8	79	12	0	glass	1	49	33	36	35	0	metal	0	36	44	27	13	0	paper	0	12	21	131	6	0	plastic	0	39	8	61	23	0	trash	0	13	20	13	9	0	<p>Accuracy:33.34%</p> <p>Recall:33.34%</p> <p>Précision:29.48%</p>	
cardboard	11	18	8	79	12	0																																								
glass	1	49	33	36	35	0																																								
metal	0	36	44	27	13	0																																								
paper	0	12	21	131	6	0																																								
plastic	0	39	8	61	23	0																																								
trash	0	13	20	13	9	0																																								
50	10	<p>Receiver operating characteristic for multi-class data</p> <p>Legend: cardboard (Acc = 0.50000) glass (Acc = 0.54523) metal (Acc = 0.50000) paper (Acc = 0.55493) plastic (Acc = 0.50000) trash (Acc = 0.50000)</p>	<table border="1"> <tr><td>cardboard</td><td>0</td><td>0</td><td>0</td><td>209</td><td>0</td><td>0</td></tr> <tr><td>glass</td><td>0</td><td>0</td><td>0</td><td>263</td><td>0</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>0</td><td>0</td><td>199</td><td>0</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>0</td><td>0</td><td>285</td><td>0</td><td>0</td></tr> <tr><td>plastic</td><td>0</td><td>0</td><td>0</td><td>235</td><td>0</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>0</td><td>0</td><td>72</td><td>0</td><td>0</td></tr> </table>	cardboard	0	0	0	209	0	0	glass	0	0	0	263	0	0	metal	0	0	0	199	0	0	paper	0	0	0	285	0	0	plastic	0	0	0	235	0	0	trash	0	0	0	72	0	0	<p>Accuracy:24.96%</p> <p>Recall:24.96%</p> <p>Précision:9.09%</p>
cardboard	0	0	0	209	0	0																																								
glass	0	0	0	263	0	0																																								
metal	0	0	0	199	0	0																																								
paper	0	0	0	285	0	0																																								
plastic	0	0	0	235	0	0																																								
trash	0	0	0	72	0	0																																								

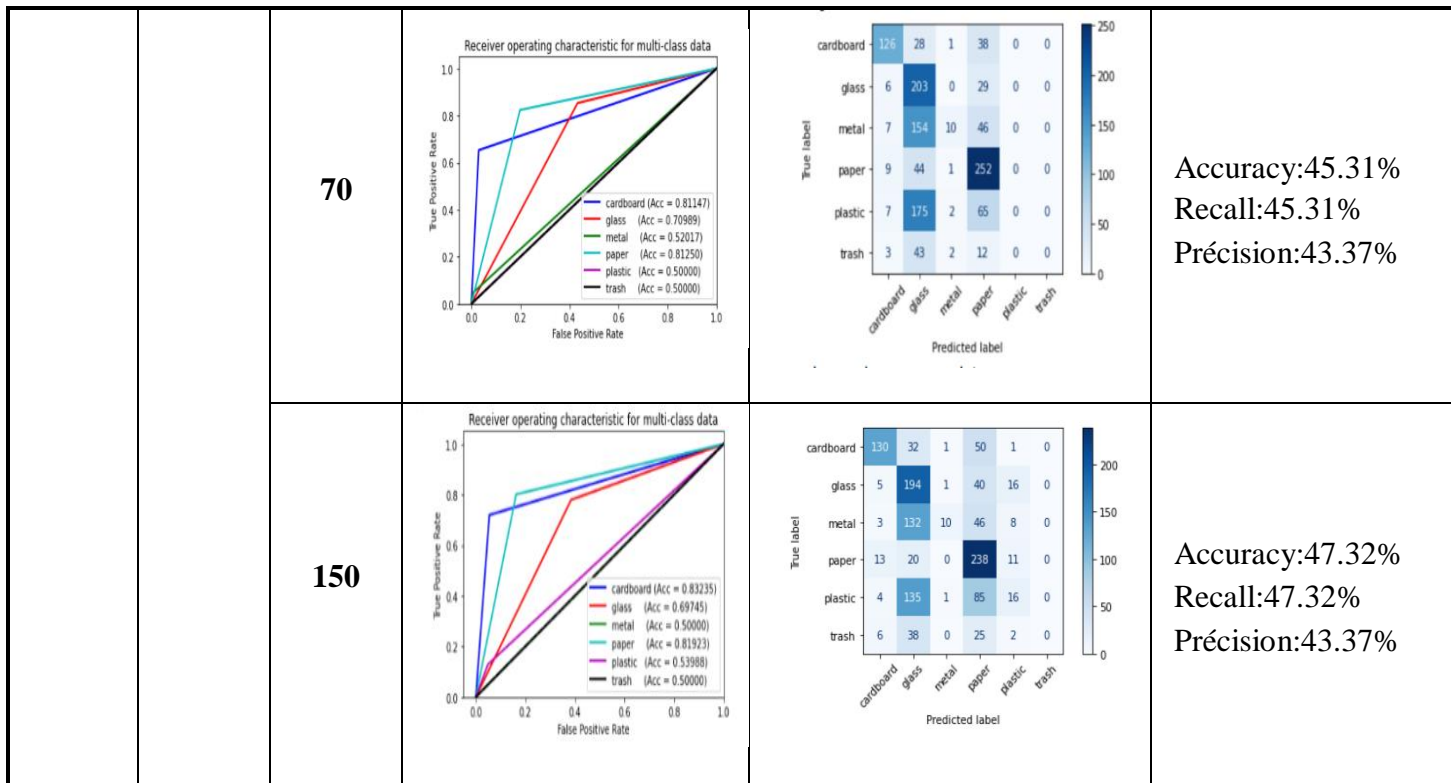


De même pour ce modèle le meilleur taux Accuracy = 34.03% et précision = 34.93% pour un taux Train = 50% et nombre couches = 150, et d'après la matrice de confusion nous concluons aussi que tant que le nombre de couches est faible le modèle a du mal à reconnaître les classes sauf la classe Paper qui a été reconnue.

• **Modèle 03: MLP en appliquant LPB**

Tableau3.5 - Résultat du Modèle 03 avec MLP

Taille d'image	Taux	Nombre de couche	ROC	Matrice de confusion	Résultats
LBP	70%	10			<p>Accuracy:29.96%</p> <p>Recall:29.96%</p> <p>Précision:10.95%</p>
		70			<p>Accuracy:40.85%</p> <p>Recall:40.85%</p> <p>Précision:29.92%</p>
		150			<p>Accuracy:47.46%</p> <p>Recall:47.46%</p> <p>Précision:43.36%</p>
		50	10		



Pour ce modèle le meilleur taux Accuracy =47.46% et précision=43.36% pour un taux Train =70% et nombre couches =150, et d'après la matrice de confusion nous remarquons que le modèle à donner un meilleur classement pour Paper, Glass et cardboard .

Nous récapitulons nos résultats obtenus dans le tableau 3.6 suivant

Tableau 3.6 – Les résultats obtenus

Modèle	Taux	Nombre de couche	Accuracy	Recall	Précision
Modèle1 Taille Réelle	50	10	23.50%	23.50%	5.53%
		70	32.05%	32.05%	26.00%
		150	33.56%	33/56%	34.79%
	70	10	23.68%	23.68%	7.73%
		70	29.77%	29.77%	28.81%
		150	35.62%	35.62%	36.39%
Modèle2 Taille (28 x 28)	50	10	24.96%	24.96%	9.09%
		70	31.78%	31.78%	29.17%
		150	34.03%	34.03%	34.93%
	70	10	24.22%	24.22%	8.52%
		70	31.29%	31.29%	29.87%
		150	33.34%	33.34%	29.48%
Modèle3 (LBP)	50	10	27.82%	27.82%	9.62%
		70	45.31%	45.31%	43.37%
		150	47.32%	47.32%	43.37%
	70	10	29.96%	29.96%	10.95%
		70	40.85%	40.85%	29.92%
		150	47.46%	47.46%	43.36%

Après l'analyse des résultats obtenus en utilisant les trois modèles MLP. Nous constatons que le meilleur taux (47.46%) de reconnaissance moyen est obtenu par le modèle 3

(descripteur LBP) avec Train =70% et le nombre de couche cachées = 150. Le mauvais taux (23.50%) est obtenu par le modèle 1 avec Train =50 % et le nombre de couche cachées = 10.

Nous concluons que lorsque la base d'apprentissage (Train) est suffisante et le nombre de couches cachées augmente, le taux accuracy dans les trois modèles augmente également.

Nous constatons aussi que le descripteur LBP a performé notre MLP pour une meilleure classification des images des déchets.

3.6.2 réseau de neurones Convolutionnel « CNN »

Nous utilisons un modèle CNN-2D, composé de 3 couches de convolution et 3 couches de maxpooling et 2 couches de sortie. Avec Filtre de 3 x 3

```
(756, 64, 64, 3)
Model: "sequential_32"
```

Layer (type)	Output Shape	Param #
conv2d_42 (Conv2D)	(None, 64, 64, 32)	896
max_pooling2d_42 (MaxPooling2D)	(None, 32, 32, 32)	0
conv2d_43 (Conv2D)	(None, 32, 32, 64)	18496
max_pooling2d_43 (MaxPooling2D)	(None, 16, 16, 64)	0
conv2d_44 (Conv2D)	(None, 16, 16, 32)	18464
max_pooling2d_44 (MaxPooling2D)	(None, 8, 8, 32)	0
flatten_23 (Flatten)	(None, 2048)	0
dense_46 (Dense)	(None, 64)	131136
dropout_23 (Dropout)	(None, 64)	0
dense_47 (Dense)	(None, 6)	390
=====		
Total params: 169,382		
Trainable params: 169,382		
Non-trainable params: 0		

Figure 3.4 - Architecture première modèle CNN

- 1^{er} couche de convolution « CONV » : c'est là que CNN apprend, donc nous aurons certainement des matrices de poids

Le nombre de paramètre = (Largeur du filtre * Hauteur du filtre * Nombre de filtres dans la couche précédente + 1) * Nombre de filtres.

$$\mathbf{Param} = ((3*3*3) + 1) * 32 = 896$$

- 2^{eme} couche POOL: nombre de paramètres = 0. On applique Maxpooling pour réduire la taille de l'information ainsi la quantité de paramètres et de calcul.
- 3^{eme} couche de convolution « CONV » : **Param = ((3*3*32) + 1) * 64 = 18496**
- 4^{eme} et 6^{eme} sont des couches de maxpooling avec le nombre de paramètre = 0
- 5^{eme} couche est la dernière couche de convolution, leur paramètre calculé comme suit :

$$\mathbf{Param} = ((3*3*64) + 1) * 32 = 18464$$

- 8^{eme} couche est une couche de sorti, cela a certainement des paramètres apprenables, en est fait, par rapport aux autres couches, cette catégorie de couches au plus grand nombre de paramètres, car, chaque neurone est connecté à tous les autres neurones, Alors, c'est le produit du nombre de neurones dans la couche actuelle **c** et du nombre de neurones sur la couche **p** précédente sans oublier le biais. Ainsi, le nombre de paramètres

Le nombre de paramètre = ((couche actuelle c * couche précédente p) + 1 * c)

$$\mathbf{Param} = ((64*2048) + 1*64) = 131136$$

- 9^{eme} couche est la deuxième couche de sortie **Param = ((6*64) + 1*6) = 390**

Totale paramètre = Σ Param.

$$\mathbf{Total\ param} = \Sigma (896 + 18496 + 18464 + 131136 + 390) = 169382$$

Nous avons créé le jeu d'essai suivant la taille d'image afin de tester la performance de notre modèle CNN.

- Taille d'image = 28×28
- Taille d'image = 64×64
- Taille d'image = 224×224. .

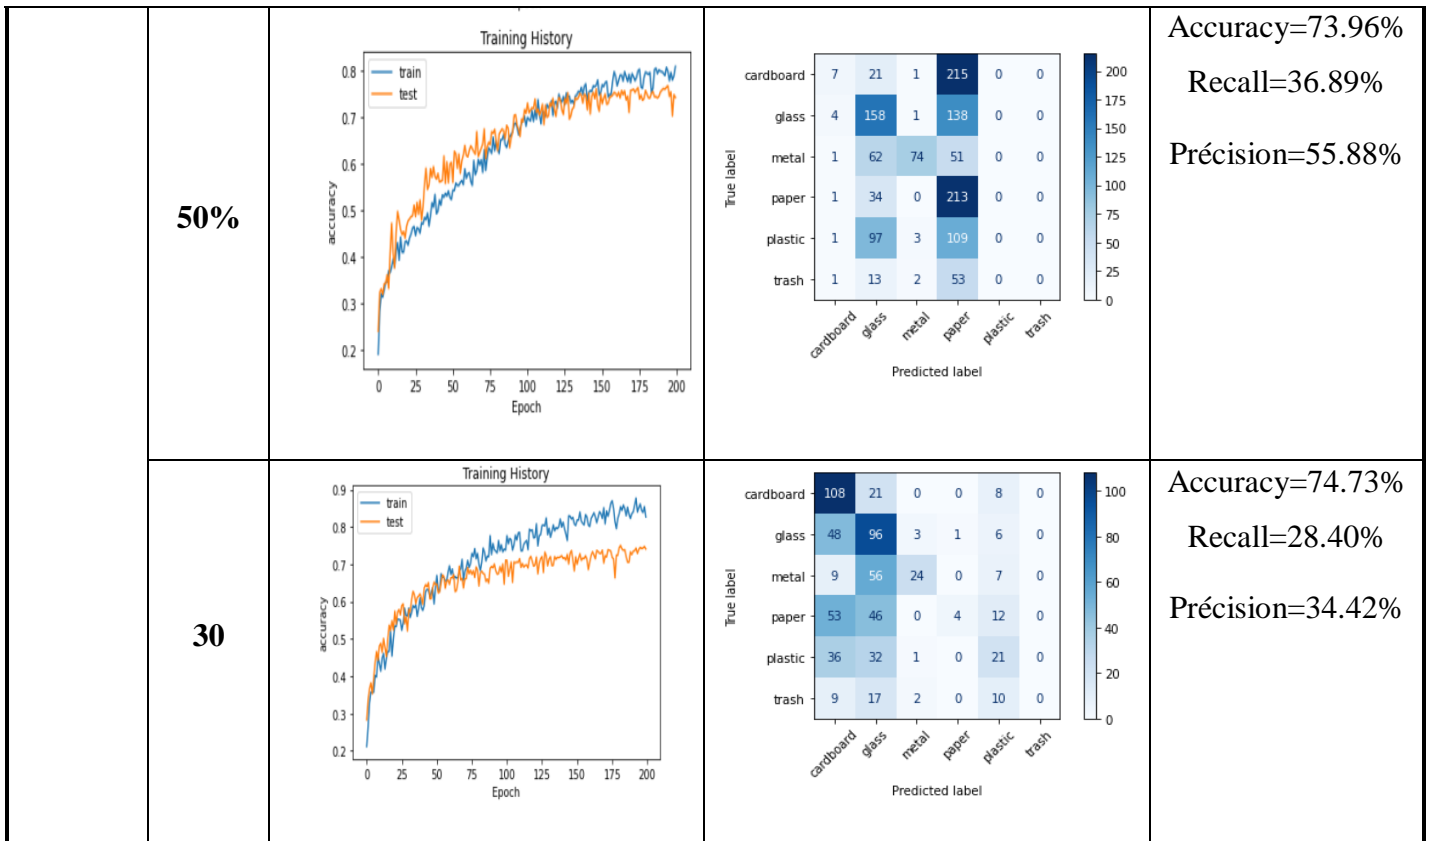
Et comme nous l'avons mentionné auparavant notre base est divisé en deux partie Train et Test.

Le tableau 3.7 ci-dessous montre les résultats obtenus.

Tableau3.7 - Résultat avec CNN

Taille d'image	Taux Train	ROC		Résultats																																										
Taille 28 × 28	70%		<table border="1"> <tr><td>cardboard</td><td>12</td><td>83</td><td>34</td><td>191</td><td>7</td><td>5</td></tr> <tr><td>glass</td><td>0</td><td>322</td><td>49</td><td>20</td><td>3</td><td>6</td></tr> <tr><td>metal</td><td>0</td><td>33</td><td>187</td><td>32</td><td>7</td><td>1</td></tr> <tr><td>paper</td><td>1</td><td>136</td><td>23</td><td>169</td><td>13</td><td>7</td></tr> <tr><td>plastic</td><td>1</td><td>79</td><td>31</td><td>110</td><td>47</td><td>14</td></tr> <tr><td>trash</td><td>1</td><td>52</td><td>12</td><td>2</td><td>4</td><td>20</td></tr> </table>	cardboard	12	83	34	191	7	5	glass	0	322	49	20	3	6	metal	0	33	187	32	7	1	paper	1	136	23	169	13	7	plastic	1	79	31	110	47	14	trash	1	52	12	2	4	20	<p>Accuracy=76.94%</p> <p>Recall=37.22%</p> <p>Précision=47.74%</p>
	cardboard	12	83	34	191	7	5																																							
	glass	0	322	49	20	3	6																																							
metal	0	33	187	32	7	1																																								
paper	1	136	23	169	13	7																																								
plastic	1	79	31	110	47	14																																								
trash	1	52	12	2	4	20																																								
50%		<table border="1"> <tr><td>cardboard</td><td>120</td><td>100</td><td>59</td><td>40</td><td>23</td><td>0</td></tr> <tr><td>glass</td><td>1</td><td>313</td><td>70</td><td>10</td><td>12</td><td>0</td></tr> <tr><td>metal</td><td>4</td><td>25</td><td>195</td><td>16</td><td>36</td><td>0</td></tr> <tr><td>paper</td><td>14</td><td>127</td><td>37</td><td>143</td><td>32</td><td>0</td></tr> <tr><td>plastic</td><td>5</td><td>91</td><td>76</td><td>63</td><td>57</td><td>1</td></tr> <tr><td>trash</td><td>0</td><td>55</td><td>17</td><td>17</td><td>3</td><td>2</td></tr> </table>	cardboard	120	100	59	40	23	0	glass	1	313	70	10	12	0	metal	4	25	195	16	36	0	paper	14	127	37	143	32	0	plastic	5	91	76	63	57	1	trash	0	55	17	17	3	2	<p>Accuracy=72.07%</p> <p>Recall=32.53%</p> <p>Précision=39.56%</p>	
cardboard	120	100	59	40	23	0																																								
glass	1	313	70	10	12	0																																								
metal	4	25	195	16	36	0																																								
paper	14	127	37	143	32	0																																								
plastic	5	91	76	63	57	1																																								
trash	0	55	17	17	3	2																																								
30%		<table border="1"> <tr><td>cardboard</td><td>1</td><td>63</td><td>23</td><td>241</td><td>14</td><td>0</td></tr> <tr><td>glass</td><td>1</td><td>154</td><td>83</td><td>109</td><td>59</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>16</td><td>212</td><td>35</td><td>13</td><td>0</td></tr> <tr><td>paper</td><td>0</td><td>104</td><td>18</td><td>210</td><td>21</td><td>0</td></tr> <tr><td>plastic</td><td>3</td><td>59</td><td>31</td><td>143</td><td>57</td><td>0</td></tr> <tr><td>trash</td><td>1</td><td>44</td><td>19</td><td>12</td><td>17</td><td>1</td></tr> </table>	cardboard	1	63	23	241	14	0	glass	1	154	83	109	59	0	metal	0	16	212	35	13	0	paper	0	104	18	210	21	0	plastic	3	59	31	143	57	0	trash	1	44	19	12	17	1	<p>Accuracy=67.27%</p> <p>Recall=26.09%</p> <p>Précision=42.42%</p>	
cardboard	1	63	23	241	14	0																																								
glass	1	154	83	109	59	0																																								
metal	0	16	212	35	13	0																																								
paper	0	104	18	210	21	0																																								
plastic	3	59	31	143	57	0																																								
trash	1	44	19	12	17	1																																								

Taille 64 × 64	70%		<table border="1"> <tr><td>cardboard</td><td>14</td><td>46</td><td>73</td><td>3</td><td>1</td><td>0</td></tr> <tr><td>glass</td><td>2</td><td>126</td><td>18</td><td>3</td><td>3</td><td>2</td></tr> <tr><td>metal</td><td>0</td><td>12</td><td>80</td><td>3</td><td>1</td><td>0</td></tr> <tr><td>paper</td><td>2</td><td>56</td><td>44</td><td>10</td><td>2</td><td>1</td></tr> <tr><td>plastic</td><td>4</td><td>42</td><td>31</td><td>7</td><td>6</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>25</td><td>5</td><td>2</td><td>1</td><td>5</td></tr> </table>	cardboard	14	46	73	3	1	0	glass	2	126	18	3	3	2	metal	0	12	80	3	1	0	paper	2	56	44	10	2	1	plastic	4	42	31	7	6	0	trash	0	25	5	2	1	5	<p>Accuracy=78.26%</p> <p>Recall=41.65%</p> <p>Précision=46.48%</p>
	cardboard	14	46	73	3	1	0																																							
	glass	2	126	18	3	3	2																																							
	metal	0	12	80	3	1	0																																							
paper	2	56	44	10	2	1																																								
plastic	4	42	31	7	6	0																																								
trash	0	25	5	2	1	5																																								
50%		<table border="1"> <tr><td>cardboard</td><td>4</td><td>44</td><td>18</td><td>69</td><td>2</td><td>0</td></tr> <tr><td>glass</td><td>0</td><td>131</td><td>19</td><td>1</td><td>2</td><td>1</td></tr> <tr><td>metal</td><td>0</td><td>11</td><td>69</td><td>9</td><td>7</td><td>0</td></tr> <tr><td>paper</td><td>5</td><td>47</td><td>17</td><td>37</td><td>7</td><td>2</td></tr> <tr><td>plastic</td><td>2</td><td>40</td><td>16</td><td>27</td><td>5</td><td>0</td></tr> <tr><td>trash</td><td>0</td><td>32</td><td>1</td><td>0</td><td>4</td><td>1</td></tr> </table>	cardboard	4	44	18	69	2	0	glass	0	131	19	1	2	1	metal	0	11	69	9	7	0	paper	5	47	17	37	7	2	plastic	2	40	16	27	5	0	trash	0	32	1	0	4	1	<p>Accuracy=73.57%</p> <p>Recall=32.81%</p> <p>Précision=20.29%</p>	
cardboard	4	44	18	69	2	0																																								
glass	0	131	19	1	2	1																																								
metal	0	11	69	9	7	0																																								
paper	5	47	17	37	7	2																																								
plastic	2	40	16	27	5	0																																								
trash	0	32	1	0	4	1																																								
30%		<table border="1"> <tr><td>cardboard</td><td>13</td><td>15</td><td>54</td><td>66</td><td>0</td><td>1</td></tr> <tr><td>glass</td><td>0</td><td>91</td><td>29</td><td>46</td><td>1</td><td>0</td></tr> <tr><td>metal</td><td>0</td><td>16</td><td>79</td><td>6</td><td>0</td><td>0</td></tr> <tr><td>paper</td><td>5</td><td>22</td><td>38</td><td>47</td><td>5</td><td>4</td></tr> <tr><td>plastic</td><td>2</td><td>18</td><td>46</td><td>24</td><td>11</td><td>1</td></tr> <tr><td>trash</td><td>0</td><td>24</td><td>5</td><td>8</td><td>0</td><td>4</td></tr> </table>	cardboard	13	15	54	66	0	1	glass	0	91	29	46	1	0	metal	0	16	79	6	0	0	paper	5	22	38	47	5	4	plastic	2	18	46	24	11	1	trash	0	24	5	8	0	4	<p>Accuracy=72.07%</p> <p>Recall=28.12%</p> <p>Précision=35.52%</p>	
cardboard	13	15	54	66	0	1																																								
glass	0	91	29	46	1	0																																								
metal	0	16	79	6	0	0																																								
paper	5	22	38	47	5	4																																								
plastic	2	18	46	24	11	1																																								
trash	0	24	5	8	0	4																																								
Taille 224 × 224	70%		<table border="1"> <tr><td>cardboard</td><td>101</td><td>8</td><td>0</td><td>22</td><td>56</td><td>16</td></tr> <tr><td>glass</td><td>14</td><td>30</td><td>1</td><td>16</td><td>50</td><td>32</td></tr> <tr><td>metal</td><td>2</td><td>2</td><td>0</td><td>18</td><td>11</td><td>2</td></tr> <tr><td>paper</td><td>15</td><td>1</td><td>0</td><td>47</td><td>12</td><td>30</td></tr> <tr><td>plastic</td><td>10</td><td>12</td><td>0</td><td>34</td><td>58</td><td>36</td></tr> <tr><td>trash</td><td>3</td><td>5</td><td>0</td><td>22</td><td>18</td><td>75</td></tr> </table>	cardboard	101	8	0	22	56	16	glass	14	30	1	16	50	32	metal	2	2	0	18	11	2	paper	15	1	0	47	12	30	plastic	10	12	0	34	58	36	trash	3	5	0	22	18	75	<p>Accuracy=77.87%</p> <p>Recall=35.85%</p> <p>Précision=36.41%</p>
cardboard	101	8	0	22	56	16																																								
glass	14	30	1	16	50	32																																								
metal	2	2	0	18	11	2																																								
paper	15	1	0	47	12	30																																								
plastic	10	12	0	34	58	36																																								
trash	3	5	0	22	18	75																																								



Après 200 époques, nous avons obtenus un meilleur taux Accuracy = 78.26% pour un taux Train =70% et taille d'image =**64 ×64**, et un mauvais taux de Accuracy=67.27% pour Train =30% et taille d'image =**28 ×28**

D'après la matrice de confusion nous concluons que tant que la base d'apprentissage est faible le modèle a du mal à reconnaître les classes.

Nous remarquons aussi que l'accuracy de l'apprentissage et de test augmente avec le nombre d'époque, tandis que l'erreur d'apprentissage (loss) diminue.

Nous pouvons dire que lorsque la précision de l'apprentissage augmente, ceci reflète qu'à chaque époque le modèle apprend plus d'informations. Cependant l'erreur d'apprentissage diminue avec le nombre d'époque.

Nous récapitulons nos résultats obtenus dans le tableau 3.8 suivant

Tableau 3.8 – Les résultats obtenus

Taille d'image	Taux	Accuracy	Recall	Précision
Taille 28 ×28	30	67.27%	26.09%	42.42%
	50	72.07%	32.53%	39.56%
	70	76.94%	37.22%	47.74%
Taille 64 ×64	30	72.07%	28.12%	35.52%
	50	73.54%	32.81%	20.29%
	70	78.26%	41.65%	46.48%
Taille 224 ×224	30	74.73%	28.04%	34.42%
	50	73.96%	36.89%	55.89%
	70	77.87%	35.85%	36.41%

D'après le tableau 3.8 , les résultats enregistrés montre que le taux de reconnaissance qui a été données par CNN égale à 78.26% .ce résultat est plus satisfaisant par rapport au MLP.

3.6.3 VGG16

Grâce à la librairie keras de Tensorflow, il est simple de récupérer le modèle pré-entraîné sur ImageNet et le tester sur notre ensemble de données Trashnet .

L'input de la première couche de convolution est une image RGB de taille 224 x 224. Ils se sont concentrés sur des couches de convolution de filtre 3x3 avec une stride 1 et toujours utilisé le même padding et la même couche maxpool de filtre 2x2 de 2 strides. Au final, il a 2 FC (couches connectées) suivies d'un softmax pour la sortie.

Nous expliquerons plus en détail la structure du réseau VGG-16 ci-dessous :

- La 1^{er}e et la 2^{ème}e couche de convolution sont constituées de 64 filtres de caractéristiques de base « feature kernel filters » de taille 3 x 3. Lorsque l'image d'entrée (image RVB avec une profondeur de 3) est transmise aux première et seconde couches convolutives, les dimensions passent à 224x224x64. Ensuite, la sortie générée est transmise à la couche de pooling maximale « max pooling layer » par un pas (stride) de 2.
- Le 3^{ème}e et 4^{ème}e couche de convolution sont constitués de 124 filtres de caractéristiques de base « feature kernel filters » de taille 3 x 3. Ces deux couches sont suivies par la couche de pooling maximale « max pooling layer » avec un pas (stride) de 2 et le résultat est réduit à 56x56x128.
- Les 5^{ème}e, 6^{ème}e et 7^{ème}e couches sont des couches convolutives avec une taille de filtre de 3x3. Tous les trois utilisent 256 cartes de caractéristiques « feature maps ». Ces couches sont suivies par la couche de pooling maximale « max pooling layer » avec un pas (stride) de 2.
- Les couches 8 à 13 sont des ensembles de couches convolutives constituées de 512 kernel filtres de taille 3x3. Ceux-ci sont suivis par la couche de pool maximale « max pooling layer » en 1 pas (stride).
- Les couches 14^{ème}e et 15^{ème}e sont des couches cachées entièrement connectées de 4096 unités, suivies d'une couche de sortie softmax de 1 000 unités (seizième couche).

Le tableau 3.9 ci-dessous montre les résultats obtenus.

Tableau 3.9 – Résultats du Modèle avec VGG 16

Taille d'image	Taux Train	ROC	Matrice de confusion	Résultats																																										
Taille 224 ×224	70%		<table border="1"> <tr><td>cardboard</td><td>98</td><td>16</td><td>8</td><td>0</td><td>3</td><td>5</td></tr> <tr><td>glass</td><td>12</td><td>149</td><td>10</td><td>4</td><td>16</td><td>6</td></tr> <tr><td>metal</td><td>47</td><td>1</td><td>76</td><td>1</td><td>1</td><td>6</td></tr> <tr><td>paper</td><td>3</td><td>11</td><td>7</td><td>5</td><td>0</td><td>8</td></tr> <tr><td>plastic</td><td>6</td><td>23</td><td>4</td><td>2</td><td>78</td><td>7</td></tr> <tr><td>trash</td><td>54</td><td>7</td><td>51</td><td>0</td><td>3</td><td>31</td></tr> </table>	cardboard	98	16	8	0	3	5	glass	12	149	10	4	16	6	metal	47	1	76	1	1	6	paper	3	11	7	5	0	8	plastic	6	23	4	2	78	7	trash	54	7	51	0	3	31	<p>Accuracy=81.82%</p> <p>Recall=51.93%</p> <p>Précision=65.21%</p>
	cardboard	98	16	8	0	3	5																																							
	glass	12	149	10	4	16	6																																							
metal	47	1	76	1	1	6																																								
paper	3	11	7	5	0	8																																								
plastic	6	23	4	2	78	7																																								
trash	54	7	51	0	3	31																																								
50%		<table border="1"> <tr><td>cardboard</td><td>128</td><td>35</td><td>27</td><td>4</td><td>0</td><td>6</td></tr> <tr><td>glass</td><td>12</td><td>242</td><td>9</td><td>6</td><td>35</td><td>11</td></tr> <tr><td>metal</td><td>59</td><td>11</td><td>159</td><td>2</td><td>0</td><td>6</td></tr> <tr><td>paper</td><td>4</td><td>27</td><td>9</td><td>13</td><td>5</td><td>10</td></tr> <tr><td>plastic</td><td>7</td><td>77</td><td>3</td><td>2</td><td>116</td><td>2</td></tr> <tr><td>trash</td><td>52</td><td>36</td><td>103</td><td>4</td><td>6</td><td>36</td></tr> </table>	cardboard	128	35	27	4	0	6	glass	12	242	9	6	35	11	metal	59	11	159	2	0	6	paper	4	27	9	13	5	10	plastic	7	77	3	2	116	2	trash	52	36	103	4	6	36	<p>Accuracy=77.77%</p> <p>Recall=52.36%</p> <p>Précision=58.98%</p>	
cardboard	128	35	27	4	0	6																																								
glass	12	242	9	6	35	11																																								
metal	59	11	159	2	0	6																																								
paper	4	27	9	13	5	10																																								
plastic	7	77	3	2	116	2																																								
trash	52	36	103	4	6	36																																								
30%		<table border="1"> <tr><td>cardboard</td><td>201</td><td>27</td><td>49</td><td>2</td><td>12</td><td>2</td></tr> <tr><td>glass</td><td>27</td><td>288</td><td>24</td><td>6</td><td>58</td><td>10</td></tr> <tr><td>metal</td><td>98</td><td>4</td><td>240</td><td>2</td><td>1</td><td>2</td></tr> <tr><td>paper</td><td>13</td><td>16</td><td>20</td><td>21</td><td>24</td><td>2</td></tr> <tr><td>plastic</td><td>11</td><td>83</td><td>12</td><td>1</td><td>168</td><td>4</td></tr> <tr><td>trash</td><td>112</td><td>45</td><td>153</td><td>8</td><td>12</td><td>11</td></tr> </table>	cardboard	201	27	49	2	12	2	glass	27	288	24	6	58	10	metal	98	4	240	2	1	2	paper	13	16	20	21	24	2	plastic	11	83	12	1	168	4	trash	112	45	153	8	12	11	<p>Accuracy=75.18%</p> <p>Recall=53.50%</p> <p>Précision=59.46%</p>	
cardboard	201	27	49	2	12	2																																								
glass	27	288	24	6	58	10																																								
metal	98	4	240	2	1	2																																								
paper	13	16	20	21	24	2																																								
plastic	11	83	12	1	168	4																																								
trash	112	45	153	8	12	11																																								

Nous récapitulons nos résultats obtenus dans le tableau 3.10 suivant

Tableau 3.10 – Résultats VGG 16

Taux	Accuracy	Recall	Précision
30	75.18%	53.50%	59.46%
50	77.77%	52.36%	58.98%
70	81.82%	51.93%	65.21% %

Après 200 époques Nous avons remarqué que le meilleur taux Accuracy = 81.82 % pour un taux Train =70% .

Nous pouvons observer aussi que la précision d'entraînement est en train d'augmenter avec le nombre d'epochs, tandis que la perte d'entraînement diminue. et d'après la matrice de confusion nous concluons que quel que soit la taille de la base train, le VGG 16 a réussi à classer un nombre significatif des images pour la plupart des classes sauf pour les paper et trash à trouver du mal à les reconnaître.

Voilà quelques images mal classées par nos model :




Figure 3.5 - Images mal classées

3.6.4 VGG19

Nous avons utilisé le modèle pré-entraîné VGG 19 sur ImageNet et qui nous l'avons testé sur notre ensemble de données Trashnet et comme il a été cité dans le chapitre précédent notre Vgg19 se compose en bref de 19 couches (16 couches de convolution, 3 couches entièrement connectées, 5 couches MaxPool et 1 couche SoftMax). L'input de la première couche de convolution est une image RGB de taille 224 x 224. Le tableau 3.11 et tableau 3.12 ci-dessous montrent les résultats obtenus :

Tableau 3.11 – Résultats du Modèle avec VGG 19

Taille d'image	Taux Train	ROC	Matrice de confusion	Résultats
Taille 224 x 224	70%			<p>Accuracy=83.02%</p> <p>Recall=55.13%</p> <p>Précision=68.29%</p>
	50%			<p>Accuracy=80.77%</p> <p>Recall=50.56%</p> <p>Précision=63.08%</p>




Tableau 3.12 –Résultats VGG 19

Taux	Accuracy	Recall	Précision
30	77.43%	56.18%	57.69%
50	80.77%	50.56%	63.08%
70	83.02%	55.13%	68.29%

Après 200 époques Nous avons remarqué que le meilleur taux Accuracy = 83.02% pour un Train de 70%

La matrice de confusion montre les bonnes prédictions sur sa diagonale, nous concluons que quel que soit la taille de la base d'apprentissage, le VGG 19 a réussi à bien connaître les classes sauf pour les classes Trash, Cardboard a enregistré des faibles prédictions.

D'après ces résultats nous pouvons voir que la précision d'entraînement est en train d'augmenter avec le nombre d'époques, tandis que la perte d'entraînement diminue.

3.7 Résultats comparative

Le tableau 3.13 présente un récapitulatif des toutes les valeurs de ces indicateurs de performances pour nos modèles :

Tableau 3.13 –Résultats comparative

Modèle	Accuracy	Recall	Précision
MLP	35.62%	35.62%	36.39%
MLP /LBP	47.46%	47.46%	43.36%
CNN	78.26%	41.65%	46.48%
VGG16	81.82%	51.93%	65.21% %
VGG 19	83.02%	55.13%	68.29%

Nous constatons qu'après avoir calculé les indicateurs de performance afin d'évaluer l'efficacité de nos modèles on a abouti à un meilleur accuracy égale à 83.02% et une précision de 68.29% pour VGG19. De là, on remarque que l'utilisation VGG19 permet d'obtenir des valeurs plus satisfaisantes pour les différents indicateurs de performances, une meilleure précision, un meilleur rappel, et une justesse et une spécificité améliorées par rapport aux autres modèles.

L'utilisation du Descripteur LBP sur le modèle MLP nous a aidé à améliorer les performances métriques du modèle en obtenant des taux un peu élevés par rapport au Modèle lui-même.

- Nos architectures CNN, VGG16, VGG19 ont permis d'obtenir un taux d'erreur de classification d'images réduit par rapport à l'utilisation MLP.
- Plus la quantité de données utilisées comme entrées des modèles est grande, plus on obtient des résultats de classification meilleurs (Taux d'erreur réduit et valeurs des indices de performances élevées). Donc, un réseau de neurone convolutif est plus performant s'il est entraîné sur un énorme flux de données.

3.8 Conclusion

Dans ce dernier chapitre nous avons proposé une approche d'identification des déchets basée sur les MLP, les réseaux de neurones convolutionnels. Cette dernière se base sur deux modèles CNN à savoir VGG16 et VGG19. Les résultats obtenus ont montré que VGG19 est plus performant que les autres modèles. Les expérimentations ont montré l'efficacité du Deep Learning dans la classification des images des déchets.

Conclusion Générale

Nous avons adopté une méthodologie de recherche qui consiste à concevoir et implémenter des méthodes de classification supervisée pour analyser les caractéristiques extraites à partir des images de déchets et identifier leurs natures. Bien que les capacités des activités réalisées dans le domaine de classification des images soient nombreuses, aucune méthode n'est jugée fiable à 100%, mais au fur et à mesure les nouveaux travaux essaient d'améliorer les scores pour des meilleurs résultats.

C'est dans ce cadre que s'inscrit notre travail, qui a pour objectif de proposer une application qui réalise une classification des images des déchets en un ensemble de 6 classes (cardboard –glass-paper-metal-plastic-trash). Pour réaliser notre projet nous avons utilisé deux types de réseaux neurones, perspective multi couches MLP et réseaux neurones convolutionnels CNN.

Nous avons testé notre premier modèle en utilisant l'algorithme MLP, en jouant sur la taille d'image, le nombre des couches et pour améliorer nos résultats nous avons appliqué le descripteur LBP qui a contribué à augmenter les performances du modèle MLP. Ensuite, nous avons utilisé un réseaux neurones convolutionnels, en premier temps notre architecture proposée CNNs et nous avons choisi les deux architectures VGG16, VGG19 d'où nos meilleurs taux est respectivement : 78.26%, 81.82% et 83.02.

Les résultats obtenus dans notre projet ont été évalués par plusieurs critères d'évaluations et plusieurs variantes, et vue la difficulté de la base de données TRASHNET, nos résultats semblent satisfaisants et encourageantes.

Nous pouvons donc conclure que la classification d'images avec les méthodes d'apprentissage supervisé profonde est une voie importante de recherche. Notre travail ouvre des perspectives scientifiques à court et à long terme comme :

- Travailler avec une base d'images plus large et plus variée.
- Tester d'autres algorithmes de IA pour augmenter et comparer les résultats et choisir le meilleur modèle.
- Etendre ce projet pour identifier et classer les objets de la vidéo.

Bibliographie

- [1] ABDOLI. S, Rfid application in municipal solid waste management system Int. J. Environ. Res., 3(3):447-454, Summer 2009
- [2] Alain Damien, Guide du traitement des déchets, DUNOD, 4^{ème} édition, Paris, 2006.
- [3] Afshine Amidi, Shervine Amidi: VIP Cheatsheet: Convolutional Neural Networks November 26, 2018 Stanford University, pp 1-5. CS 230 – Deep Learning
- [4] A. K. Jain, J. Mao, et K. M. Mohiuddin, "Artificial neural networks: A tutorial," Computer, vol. 29, no. 3, pp. 31-44, 1996. IEEE
- [5] Arebey, M., Hannan, M., Basri, H., Begum, R. A., and Abdullah, H. (2011). Integrated technologies for solid waste bin monitoring system. Environmental monitoring and assessment, 177(1-4):399–408
- [6] Aurélien Géron. Machine Learning avec Scikit-Learn. DUNOD, 2eme Edition 2019 .
- [7] BENSMAIL Salem et AINOUCHE Mohand Cherif (2010) La problématique de la gestion des déchets solides à travers les modes de traitement des déchets ménagers et hospitaliers : Cas de la commune de Bejaia, magister UNIVERSITE ABDERRAHMANE MIRA DE BEJAIA.
- [8] CAROLINE ETIENNE, Apprentissage profond appliqué à la reconnaissance des émotions dans la voix , Thèse de doctorat de l'Université Paris-Saclay Le 18 décembre 2019
- [9] C. Bircanoglu, M. Atay, F. Beser, O. Genc and M. A. Kizrak, "RecycleNet: Intelligent waste sorting using deep neural networks", Proc. INISTA, pp. 1-7, 2018.
- [10] Chowdhury, Belal and Chowdhury, Morshed 2007, RFID-based real-time smart waste management system, in ATNAC 2007 : Australasian Telecommunication Networks and Applications Conference 2007, Christchurch, New Zealand. Sunday 2 December-Wednesday 5 December 2007., Institute of Electrical and Electronics Engineers, Inc (IEEE), Piscataway, N.J., pp. 175-180.
- [11] Chloé-Agathe Azencott , Introduction au Machine Learning. Dunod, 2015 .
- [12] Claudia Cirelli et Bénédicte Florin , Sociétés urbaines et déchets ,Presses universitaires François-Rabelais, 2015
- [13] Cloude Touzet, « Les réseaux de neurones artificiels introduction au connexionisme », 1992
- [14] Courtine D. « Décharge proscrite », édition economica, Paris, 1996
- [15] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," Psychological review, vol. 65, no. 6, p. 386, 1958.

- [16] Glouche, Y. and Couderc, P. (2013). A smart waste management with self- describing objects. In The Second International Conference on Smart Systems, Devices and Technologies (SMART'13)
- [17] Hassan, Muneeb ul. VGG16 – Convolutional Network for Classification and Detection. NeuroHive. [En ligne] 2018
- [18] Hamza Cheniti , these doctorat ,La Gestion Des Dechets Urbains Solides : Cas De La Ville D'annaba, 2014
- [19] He, Kaiming, et al. Deep Residual Learning for Image Recognition. arXiv preprint arXiv:1512.03385. 2015.
- [20] Ian Goodfellow, Yoshua Bengio et Aaron Courville . Deep learning. MIT press Cambridge, London. 2016.
- [21] Jonathan Bouchard, « Methodes de Vision et d'Intelligence Artificielles pour la reconnaissance de SJ.Jecimens Coralliens », A l' obtention de la Maitrise en Genie de la Production Automatisee, Ecole de Technologie Superieure, Universite du Quebec, 2011.
- [22] Journal Officielle N°77 du 15 décembre 2001 page 7.
- [23] Judith Hurwitz and Daniel Kirsch . Machine Learning For Dummies ,IBM Limited Edition 2018 by John Wiley & Sons, Inc.
- [24] Karen Simonyan * & Andrew Zisserman + Visual Geometry Group, Department of Engineering Science, University of Oxford arXiv preprint arXiv:1409.1556v6. 10 april 2015.
- [25] Karim, Raimi. Illustrated: 10 CNN Architectures. Towards Data Science 2019.
- [26] Kawaguchi, Kiyoshi. The McCulloch-Pitts Model of Neuron.
- [27] Krizhevsky, Alex, Sutskever, Ilya et Hinton, Geoffrey E. ImageNet Classification with deep convolutional neural networks. Communications of the ACM. 60, 2012, 6, pp. 84–90.
- [28] LeCun, Yann, et al. Backpropagation applied to handwritten zip code recognition. Neural computation. 1, 1989, 4, pp. 541–551.
- [29] LeCun, Yann, et al. Gradient-based learning applied to document recognition. Proceedings of the IEEE. 86, 1998, 11, pp. 2278–2324.
- [30] L. Heasman (1997) Leaching tests to assess the environmental impact of waste. Proceedings 66ardinia 97, Sixth International Waste Management and Landfill Symposium, 293 – 298.

- [31] McCulloch, Warren S et Pitts, Walter. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics. 5, 1943, 4, pp. 115–133.
- [32] Mille A., Les Réseaux Bayésiens A la recherche de la vérité. Cours Cognition et connaissance, Université Claude Bernard Lyon 1, pp. 1-9, 2007.
- [33] Neelesh Karthikeyan. Review of Deep Transfer Learning Models for Image Classification College of Engineering Guindy, Anna University, Chennai, India , 2022
- [34] O’Shea, Keiron et Nash, Ryan. An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458. 2015.
- [35] Pierre Buysens, Fusion de différents modes de capture pour la reconnaissance du visage appliquée aux e_ transactions DOCTORAT de l’UNIVERSIT’E de CAEN Le 4 Janvier 2011
- [36] R. A. Aral, S. R. Keskin, M. Kaya and M. Haciomeroglu, "Classification of trashnet dataset based on deep learning models", Proc. BigData, pp. 2058-2062, Dec. 2018.
- [37] Rumelhart, David E, Hinton, Geoffrey E et Williams, Ronald J. Learning representations by back-propagating errors. Nature. 323, 1986, 6088, p. 533.
- [38] Service Public Fédéral Justice, 2012
- [39] Simonyan, K., Vedaldi, A., & Zisserman, A. (2014). Deep inside convolutional networks: Visualising image classification models and saliency maps.
- [40] Sinha, Arnab, and Paul Couderc. "Using owl ontologies for selective waste sorting and recycling." 2012.
- [41] Szegedy, Christian, et al. Going deeper with convolutions. arXiv preprint arXiv:1409.4842. 2014.
- [42] Thung, Gary and Mingxiang Yang. “Classification of Trash for Recyclability Status.” (2016).
- [43] T. Kennedy, OscarNet: Using transfer learning to classify disposable waste. In CS230 Report: Deep Learning; Stanford University: Stanford, CA, USA, 2018.
- [44] V. Ruiz, Á. Sánchez, J. F. Vélez and B. Raducanu, "Automatic image-based waste classification", Proc. IWINAC, vol. 2, pp. 422-431, 2019.
- [45] https://www.researchgate.net/figure/Mise-en-correspondance-neurone-biologique-neurone-artificiel_fig15_242536334
- [46] https://github.com/bwproud/mask_rcnn_recyclables/blob/master/data.zip

- [47] <https://docs.microsoft.com/fr-fr/azure/machine-learning/concept-deep-learning-vs-machine-learning>
- [48] <https://www.natural-solutions.eu/blog/entrainement-dun-reseau-de-neurones-convolutifs#:~:text=L'entra%C3%Aement%20d'un%20CNN,pense%20que%20cette%20image%20appartient.>
- [49] <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5088816-apprenez-a-construire-un-cnn-et-gagnez-du-temps-avec-le-transfer-learning>
- [50] http://staff.univ-batna2.dz/sites/default/files/merzougui_ghalia/files/support_de_cours_-deep_learning-chapitre3-cnn.pdf
- [51] <https://datascientest.com/convolutional-neural-network>
- [52] https://en.wikipedia.org/wiki/Local_binary_patterns
- [53] <https://medium.com/@yannicksergeobam/comprendre-les-re%C3%A9seaux-de-neurones-convolutifs-cnn-d5f14d963714>
- [54] <https://inside-machinelearning.com/fonction-dactivation-comment-ca-marche-une-explication-simple/>
- [55] <https://www.jedha.co/formation-ia/cross-validation>
- [56] http://www.xavierdupre.fr/app/mlstatpy/helpsphinx/c_metric/roc.html
- [57] <https://www.lebigdata.fr/python-langage-definition>
- [58] <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>
- [59] <https://research.google.com/colaboratory>
- [60] <https://www.tensorflow.org/learn?hl=fr>
- [61] <https://keras.io/>
- [62] <https://scikit-learn.org/stable/>