



République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la
recherche scientifique



Université Larbi Tébessi - Tébessa
Faculté des Sciences Exactes et des Sciences de la
Nature et de la vie
Département : Mathématique et informatique

Mémoire de fin d'étude
Pour l'obtention du diplôme de MASTER

Domaine : Mathématiques et informatique

Filière : Informatique

Option : Système d'information

Thème :

Smart waste segmentation deep learning based approach

Réaliser par :
Achi Aimen Belgacem

Soutenu publiquement devant le jury composé de :

Président : Pr. Laouer. MR

Eximanateur : Pr. Amroune. M

Ecadreur : Dr. Bourougaa-Tria. S

Année universitaire : 2021/2022

Remerciements

Tout d'abord nous remercions ALLAH pour nous avoir donné la force et le courage dont nous avons eu besoin afin de réaliser ce modeste travail.

Nous tenons à exprimer toute notre reconnaissance à notre encadreur Dr. Bourougaa-Tría. Salima d'avoir soutenu nos choix, de nous avoir conseillé, orienté et aidé durant tout le long de ce projet.

Nous remercions également tout le corps professoral du département de Mathématiques et Informatique de l'Université El Arbi Tébessi qui a contribué à notre formation.

Et enfin, un grand merci à nos familles et amis qui nous ont encouragé, soutenu et suivi tout au long de ce projet.

Dédicaces

*Je dédie ce travail à mes chers et précieux
parents de m'avoir encouragé, aider durant
toutes mes années de scolarité et d'avoir
soutenu mes choix. à **Souhaib** et **Abd
Elrahmen** qui m'ont encouragé , à mon
cher frère **Bilel** et ma sœur & A*. Et à toute
ma famille.*

Résumé

Le volume des déchets solides dans les zones urbaines devient une menace inquiétante qui provoque une détérioration de l'environnement et une menace pour la santé humaine. Pour gérer toute une variété de déchets, il est important de disposer d'un système de gestion des déchets efficace et intelligent. La séparation des déchets en plusieurs éléments est l'une des étapes les plus importantes de la gestion des déchets, et ce processus est généralement effectué manuellement par triage. Pour simplifier le processus, nous avons proposé deux modèles basés sur le réseau de neurones convolutifs qui ont été entraînés (Unet et Mask RCNN). Nous les avons utilisés pour segmenter les déchets et puis pour faciliter le processus de tri des déchets en différents groupes/types tels que le verre, le métal, le papier, le plastique, le carton et les ordures. Le système proposé est testé sur Mju-Waste dataset, développé par Tao Wang de. Notre modèle Unet a atteint une précision de 98 % après 40 époques d'entraînement et une précision moyenne qui dépasse 90 % pour notre modèle Mask RCNN après 50 époques d'entraînement.

Le système de segmentation des ordures que nous proposons rend le processus de séparation des ordures plus rapide, intelligent et optimal.

Mots clés : Tri de déchets, Unet, Mask RCNN, Deep learning, segmentation

Abstract

The volume of solid waste in urban areas is becoming an alarming threat that causes environmental deterioration and a threat to human health. To manage a variety of wastes, it is important to have an efficient and intelligent waste management system. Separating waste into several components is one of the most important steps in waste management, and this process is usually done manually by sorting. To simplify the process, we proposed two trained convolutional neural network-based models (Unet and Mask RCNN). We used them to segment the waste and then facilitate the process of sorting the waste into different groups/types such as glass, metal, paper, plastic, cardboard and garbage. The proposed system is tested on Mju-Waste dataset, developed by Tao Wang from. Our Unet model achieved 98% accuracy after 40 training epochs and an average accuracy that exceeds 90% for our Mask RCNN model after 50 training epochs.

Our proposed garbage segmentation system makes the garbage separation process faster, smarter and optimal.

Keywords : Waste sorting, Unet, Mask RCNN, Deep learning, segmentation.

ملخص

أصبح حجم النفايات الصلبة في المناطق الحضرية تهديداً مقلقاً يتسبب في تدهور البيئة وتهديد صحة الإنسان. لإدارة مجموعة متنوعة من النفايات، من المهم أن يكون لديك نظام فعال وذكي لإدارة النفايات. يعد فصل النفايات إلى عدة مكونات من أهم الخطوات في إدارة النفايات، وعادة ما تتم هذه العملية يدوياً عن طريق الفرز. لتبسيط العملية، اقترحنا نموذجين يعتمدان على الشبكة العصبية التلافيفية التي تم تدريبها (Unet and Mask RCNN). استخدمناها لتجزئة النفايات ومن ثم لتسهيل عملية فرز النفايات إلى مجموعات / أنواع مختلفة مثل الزجاج والمعدن والورق والبلاستيك والكرتون والقمامة. تم اختبار النظام المقترح على مجموعة بيانات Mju-Waste، التي طورتها Tao Wang de. حقق نموذج Unet الخاص بنا دقة 98% بعد 40 حقبة تدريب ومتوسط دقة تتجاوز 90% لطراز Mask RCNN بعد 50 حقبة تدريب. يجعل نظام تجزئة القمامة الذي نقدمه عملية فصل القمامة أسرع وأكثر ذكاءً.

Table des matières

Résumé	III
Abstract	IV
ملخص.....	V
Table des matières	VI
Liste des figures.....	VIII
Liste des tableaux.....	X
Introduction générale	1
1. La structure de l'essai.....	2
Chapitre 1 : La gestion des déchets	4
1. Introduction.....	4
2. Histoire des déchets	4
3. Définition des déchets	5
4. La gestion des déchets.....	5
5. Hiérarchie des déchets	6
5.1. Cycle de vie d'un déchet.....	7
5.2. Efficacité des ressources	8
6. Réduction et Tri des déchets	8
6.1. La collecte des déchets.....	8
6.2. Tri des déchets	10
7. Valorisation des déchets	13
7.1. Recyclage.....	14
7.2. Réutilisation	14
8. Gestion des déchets par région.	17
9. La gestion intelligent des déchets	18
9.1. Le principe de la gestion intelligent des déchets :	18
10. Les profits de la valorisation des déchets	20
11. Conclusion.....	20
Chapitre 2 : L'état de l'art.....	23
1. Introduction.....	23
2. L'intelligence artificielle	23
3. L'apprentissage automatique.....	24
3.1. L'apprentissage supervisé	24
3.2. L'apprentissage non supervisé.....	25
4. Apprentissage profond.....	25
4.1. Histoire et applications du l'apprentissage profond	25

4.2.	Le réseau de neurones convolutifs (CNN).....	26
4.3.	Architecture du CNN	29
5.	<i>DL pour les tâches de la vision par ordinateur</i>	30
5.1.	Classification et localisation	31
5.2.	Détection d'objet	31
5.3.	La Segmentation.....	34
5.4.	La différence entre les tâches de la vision par ordinateur	38
6.	<i>Etude de l'existant</i>	38
7.	<i>Conclusion</i>	42
Chapitre 3 : Segmentation des déchets, Conception, Implémentation et expérimentation		44
1.	<i>Introduction</i>	44
2.	<i>Architecture globale</i>	44
3.	<i>Présentation des données</i>	45
3.1.	Mju-Waste dataset.....	45
3.2.	Annotation des images.....	46
3.3.	Prétraitement des données.....	48
4.	<i>Les Modèles DL proposées pour la segmentation :</i>	49
5.	<i>Métrique d'évaluation :</i>	51
6.	<i>Implémentation et Expérimentation :</i>	52
6.1.	Environnement et outils de travail :.....	52
6.2.	Etapas d'implémentation des modèles DL :.....	55
6.2.4.	Phase d'apprentissage des modèles	57
7.	<i>Expérimentation des résultats</i>	57
7.1.	La performance du modèle de segmentation UNet:.....	57
7.2.	La performance du modèle de segmentation Mask RCNN :	58
7.3.	Comparaison entre nos modèles et les modèles cités dans l'état de l'art :.....	59
7.4.	Prédictions et test	60
8.	<i>Conclusion</i>	62
Conclusion générale		63
	<i>Perspective :</i>	63
Bibliographie		64

Liste des figures

Figure 1.1.La hiérarchie des déchets	7	
Figure 1.2 Poubelle à roulettes en plastique moulé dans le Berkshire	9	
Figure 1.3 Poubelles de tri sélectif	10	
Figure 1.4. Code couleurs pour la collecte sélectives	10	
Figure 1.5.déchargements des déchets dans une carrières spécial	11	
Figure 1.6.mécanisme du Tri automatique	12	
Figure 1.7.Tri manuelle	13	
Figure 1.8.illustration des différents types des balles.....	13	
Figure 1.9.Mis en balles des déchets pour le recyclage	14	
Figure 1.10.Un composteur florissant	15	
Figure 1.11.Valorisation thermique des déchets	16	
Figure 1.12 l'environnement et valorisation des déchets.....	20	
Figure 2.1 l'intelligence artificielle	24	
Figure 2.2 Apprentissage supervisée.....	24	
Figure 2.3 apprentissage non supervisé	25	
Figure 2.4 Opération de convolution	27	
Figure 2.5.fonctions d'activation populaires	27	
Figure 2.6.Opération de sous-échantillonnage	28	
Figure 2.7.La fonction softmax	28	
Figure 2.8.Architecture CNN	29	
Figure 2.9.Architecture VGG16	29	
Figure 2.10.Architecture Resnet	30	
Figure 2.11.Les tâches de la vision par ordinateur	30	
Figure 2.12.Démonstration d'une classification	31	
Figure 2.13Architecture RCNN	32	
Figure 2.14.Archetecture Faster-RCNN	32	
Figure 2.15.Architecture YOLO	34	
Figure 2.16.Démonstration d'une segmentation[.....	34	
Figure 2.17.Comparaison entre segmentation sémantique et segmentation d'instance	35	
Figure 2.18.Architecture Unet	36	
Figure 2.19.Architecture Mask RCNN	37	
Figure 2.20 Comparaison entre segmentation sémantique, classification et localisation, détection d'objets et segmentation d'instances	38	
Figure 3.1.Architecture Globale	45	
Figure 3.2.image du dataset.....	46	
Figure 3.3.mask du d'une image	46	
Figure 3.4. L'annotation du mask RCNN avec lable me.....	47	
Figure 3.5. Redimensionnement d'une image 128x128.....	48	
Figure 3.6.Architecture Unet proposé.....	50	
Figure 3.7Architecture du Mask R-CNN proposé	51	
Figure 3.8.Image d'une fenêtre colab montrant	55	
Figure 3.9 Division de données pour Mask RCNN	Figure 3.10 Division de données pour Unet	57
Figure 3.11.Graphe de Accuracy et Loss pour Unet.....	58	
Figure 3.12.Graphe IOU _Unet.....	58	
Figure 3.13 Les graphes de " Loss " d'entraînement et validation et "Mask loss"	59	

Figure 3.14 Contour le déchets a partir du pred mask.....	60
Figure 3.15 résultats des prédictions	61
Figure 3.16 Crop Mask Unet	61
Figure 3.17 résultats des prédictions avec Mask RCNN.....	62

Liste des tableaux

Tableau 2.1 Histor de DL.....	25
Tableau 2.2 Les travaux d'état e l'art	41
Tableau 3.1 Taille et type d'image dans la dataset	46
Tableau 3.2 Résultats de Unet	58
Tableau 3.3 Résultats de Mask RCNN	59
Tableau 3.4.Comparaison de modèle Unet avec les travaux basés sur segmentation sémantique	59
Tableau 3.5.Comparaison de modèle Mask RCNN avec les travaux basé sur la détection	60

Introduction

générale

Introduction générale

À l'échelle mondiale, les déchets solides annuels devraient dépasser 2,2 milliards de tonnes d'ici 2025, ce qui entraînera un coût de gestion des déchets de 375,5 milliards de dollars [x]. Une mauvaise gestion des déchets aura des conséquences dévastatrices sur l'économie, la santé publique et l'environnement. L'Agence de protection de l'environnement (EPA) a désigné le recyclage des déchets solides municipaux (DSM) comme la deuxième technique "la plus écologique" pour traiter les déchets urbains[1].

Le recyclage optimal des déchets est bénéfique à la fois pour l'économie et pour l'environnement. Il permet notamment de récupérer les ressources brutes, d'économiser l'énergie, de réduire les émissions de gaz à effet de serre, de réduire la pollution de l'eau et d'éviter la création de nouvelles décharges [1].

Le tri est le processus de séparation des déchets. L'objectif est de faciliter le recyclage des déchets. La quantité de déchets mis en décharge diminue considérablement lorsque les déchets sont triés, ce qui se traduit par des niveaux plus faibles de pollution de l'air et de l'eau. Il est important de se rappeler que le tri des déchets doit être effectué en fonction du type de déchets et du traitement et de l'élimination les plus adaptés.

Cela facilite également l'utilisation de plusieurs méthodes de tri des déchets, une intégration de l'intelligence artificielle plus précisément la segmentation des déchets basé sur DL, dans le processus de tri est une nécessité car c'est le seul moyen de garantir une stratégie optimale et rapide pour la réduction des déchets et la valorisation des déchets recyclables.

La séparation manuelle des ordures a un coût élevé. Les progrès récents de l'apprentissage profond ont permis des avancées extraordinaires dans le domaine de la vision par ordinateur. Le réseau neuronal convolutif (CNN) est l'une des techniques d'apprentissage profond les plus connues en raison de sa large utilisation dans la classification, la segmentation et la détection des images. Par conséquent, CNN est proposé dans cette littérature pour effectuer la segmentation des déchets [1].

Dans notre projet, nous visons à segmenter les déchets, pour réussir à les classer ensuite, en plusieurs catégories : papier, métal, verre, plastique, carton et déchets. En utilisant des méthodes d'apprentissage profond, lorsque les ordures sont déposées dans la poubelle, des capteurs intelligents prendront une photo des ordures, puis utiliseront CNN pour reconnaître les ordures

à partir de (forme, bords, couleurs...etc) pour faciliter le tri. De nombreux projets ont été réalisés auparavant dans le même domaine et le meilleur d'entre eux a atteint une précision moyenne de 89%.

Dans ce projet, nous allons essayer d'exploiter les expériences passées pour obtenir une meilleure précision pour la segmentation des déchets en utilisant Unet et Mask RCNN.

1. La structure de l'essai

La suite de ce mémoire est organisée comme suit :

- Chapitre I : Tout d'abord, nous avons commencé notre mémoire par le premier chapitre qui présente la notion de la gestion des déchets.
- Chapitre II : Le deuxième chapitre introduit les concepts de base de l'apprentissage profond, les différentes tâches de la vision par ordinateur pour finir par la présentation d'un aperçu sur les travaux les plus importants basés sur l'apprentissage profond.
- Chapitre III : Dans le dernier chapitre, nous présentons la conception et l'implémentation de notre approche basée sur l'apprentissage profond pour une segmentation intelligente des déchets.

Chapitre 1 :

La Gestions des déchets

Chapitre 1 : La gestion des déchets

1. Introduction

Les villes intelligentes comprennent des environnements intelligents. Les déchets sont des éléments que nous jetons dans notre environnement. Dans la lutte contre le changement climatique, la gestion des déchets et le recyclage sont deux éléments essentiels. Cependant, par manque de temps, d'argent ou de compréhension, il peut être difficile d'avoir plusieurs poubelles et de gérer correctement les déchets. Par conséquent, afin de préserver l'environnement, de lutter contre la pollution et d'économiser du temps, de l'argent et des connaissances, nous devons envisager des poubelles intelligentes, qui permettent de trier les déchets et de les recycler. La croissance exponentielle de la population dans les zones urbaines rend les politiques et stratégies existantes de gestion des déchets solides difficiles.

Dans les villes à croissance rapide, la situation devient plus difficile en raison de l'augmentation de la production de déchets, et de leur gestion qui devient difficile par les installations existantes. La prévention, le recyclage, la réutilisation et la récupération des déchets sont des solutions fondamentales nécessaires pour réduire les déchets solides mis en décharge, en particulier dans les villes à croissance rapide où une gestion plus durable doit être adoptée.

Le tri des déchets consiste à séparer les déchets en différents types. Le traitement correct des déchets passe par un tri efficace. La séparation doit être effectuée le plus tôt possible afin de minimiser la contamination des déchets par d'autres matières. Pour cela, il est nécessaire d'automatiser ce processus afin de faciliter la tâche des entreprises de gestion des déchets.

Dans ce chapitre, nous allons introduire la gestion des déchets, à travers un ensemble de notions, à savoir : une définition des déchets, la gestion des déchets, la hiérarchie des déchets, l'histoire des déchets, la manipulation et le transport des déchets, le recyclage, la réutilisation, la gestion des déchets liquides et les technologies et les avantages de la gestion des déchets.

2. Histoire des déchets

En raison de la faible densité de population et de l'exploitation des ressources naturelles, la quantité d'ordures produites par l'homme a été négligeable pendant la majeure partie de

l'histoire. À l'époque prémoderne, les déchets courants étaient principalement constitués de cendres et de déchets biodégradables humains, qui étaient déversés localement avec un impact minimal sur l'environnement. Les outils en bois et en métal étaient fréquemment réutilisés [1].

L'accumulation d'ordures dans les villes après le début de l'industrialisation et la croissance urbaine continue d'importants centres de population en Angleterre ont entraîné une dégradation rapide de l'assainissement et de la qualité générale de la vie urbaine. En raison de l'absence de lois sur l'enlèvement des ordures, les rues ont été encombrées de déchets. Corbyn Morris, de Londres, a préconisé en 1751 que : « puisque la préservation de la santé du peuple est d'une importance vitale, il est proposé que le nettoyage de cette métropole soit placé sous une supervision publique uniforme, et que toutes les saletés soient transportées par la Tamise à une distance appropriée dans le pays... » [1].

3. Définition des déchets

Dans la littérature, on peut trouver plusieurs définitions du terme "déchet" ; nous pouvons citer les plus utilisées :

✚ « Toute substance ou objet, ou plus généralement tout bien meuble, dont le détenteur se défait ou qu'il a l'intention ou l'obligation de faire » [1].

✚ « Un déchet est un produit ou une substance qui n'est plus adapté à l'usage auquel il était destiné. Alors que dans les écosystèmes naturels, les déchets (c'est-à-dire l'oxygène, le dioxyde de carbone et la matière organique morte) sont utilisés comme nourriture ou comme réactif, les déchets résultant des activités humaines sont souvent très résistants et prennent beaucoup de temps à se décomposer » [2].

✚ « Les déchets sont des substances ou des objets qui sont éliminés ou dont l'élimination est prévue ou exigée par les dispositions du droit national » [3].

Pour conclure la définition, un déchet est toute substance ou objet dont le détenteur se défait ou dont il a l'intention ou l'obligation de se défaire.

4. La gestion des déchets

La gestion des déchets (ou l'élimination des déchets) désigne les actions et les mesures qui doivent être adoptées pour assurer la gestion des déchets depuis leur création jusqu'à leur évacuation finale. Elle comprend la collecte, le transport, le traitement et l'élimination des

déchets, ainsi que le suivi et le contrôle des processus de gestion des déchets, de même que les lois, les technologies et les systèmes économiques liés aux déchets [4].

Les déchets peuvent être solides, liquides ou gazeux et chaque type a des méthodes d'élimination et de gestion différentes. La gestion des déchets concerne tous les types de déchets, y compris les déchets industriels, biologiques et ménagers. Dans certains cas, les déchets peuvent constituer une menace pour la santé humaine, Les pays développés et les régions urbaines et rurales, les secteurs résidentiels et industriels ont tous des techniques de gestion des déchets différentes [5].

La gestion des déchets est essentielle à la création de communautés durables et vivables. Pourtant, de nombreux pays et villes en développement éprouvent des difficultés à cet égard. Selon une enquête, une bonne gestion des déchets est plutôt coûteuse, représentant de 20 à 50

La gestion des déchets est essentielle à la création de communautés durables et vivables. Pourtant, de nombreux pays et villes en développement éprouvent des difficultés à cet égard. Selon une enquête, une bonne gestion des déchets est plutôt coûteuse, représentant de 20 à 50

% des budgets municipaux. L'exploitation de cette fonction municipale essentielle nécessite l'utilisation de systèmes intégrés qui sont efficaces, durables et socialement bénéfiques.

Selon les auteurs du premier examen systématique des preuves scientifiques relatives aux déchets mondiaux, à leur gestion et à leur impact sur la santé et la vie humaines, environ un quart de tous les déchets solides terrestres municipaux ne sont pas collectés, et un autre quart

Est mal géré après la collecte, souvent brûlé dans des feux ouverts et incontrôlés [7].

5. Hiérarchie des déchets

La hiérarchie des déchets fait référence aux "3 R" de la réduction, de la réutilisation et du recyclage (voir la figure 1), qui classe les solutions de gestion des déchets en fonction de leur attrait en termes de réduction des déchets. La plupart des solutions de réduction des déchets s'articulent autour de la hiérarchie des déchets. L'objectif de la hiérarchie des déchets est de tirer le maximum de valeur des choses tout en produisant le moins de déchets possible. Les politiques doivent soutenir les méthodes visant à prévenir la production de déchets, la hiérarchie des déchets est représentée sous la forme d'une pyramide. La hiérarchie des déchets se résume comme suit :

- **Etape 1** : La recherche d'utilisations alternatives pour les déchets produits, comme la réutilisation des déchets.
- **Etape 2** : Le compostage, qui est inclus dans le recyclage.
- **Etape 3** : La récupération des matériaux et la valorisation énergétique des déchets.
- **Etape 4** : L'élimination, soit dans des décharges, soit par incinération sans récupération d'énergie c'est la dernière option pour les déchets qui n'ont pas été évités, détournés ou valorisés.

La hiérarchie des déchets décrit le passage d'un produit(déchet) ou d'une matière à travers les étapes de la gestion des déchets [8].

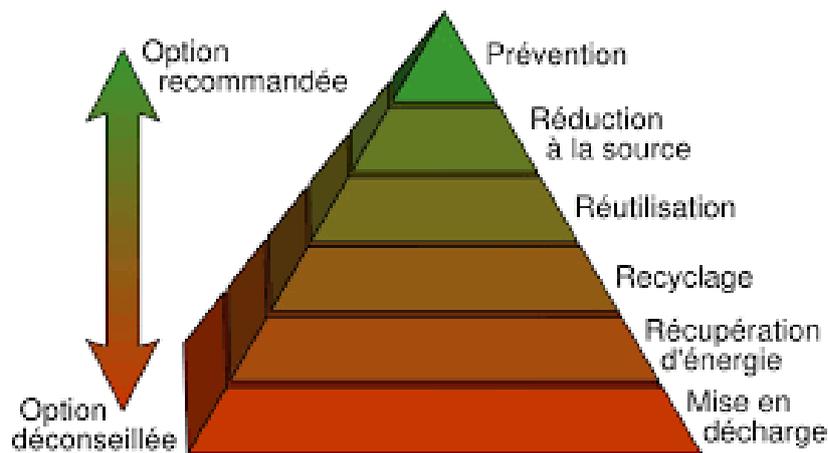


Figure 1.1.La hiérarchie des déchets [8]

5.1. Cycle de vie d'un déchet

Le cycle de vie commence par la conception et se poursuit par la fabrication, la distribution et l'utilisation principale, ainsi que par les étapes de réduction, réutilisation et de recyclage de la hiérarchie des déchets. Chaque étape du cycle de vie d'un produit (déchet) offre des possibilités d'intervention politique, comme le fait de repenser le besoin du produit, de le reconcevoir pour réduire le potentiel de déchets et d'étendre son utilisation. L'analyse du cycle de vie d'un déchet est une méthode permettant de déterminer la durée de vie du déchet [9].

5.2. Efficacité des ressources

L'utilisation efficace des ressources est l'expression de la prise de conscience que les modes de production et de consommation actuels ne peuvent pas soutenir la croissance économique et le développement au niveau mondial., l'humanité épuise les ressources de la planète plus vite qu'elle ne peut les renouveler. La diminution de l'impact environnemental de la fabrication et de la consommation de ces articles, de l'extraction des matières premières à l'élimination finale, est appelée efficacité des ressources [10].

6. Réduction et Tri des déchets

L'un des principaux objectifs de toute gestion des déchets est la réduction de leurs quantités et de leurs nuisances. Chaque citoyen peut et doit participer à la réalisation de cet objectif [12], le tri puis le recyclage ou la réutilisation sont des solutions qui permettent de diminuer la quantité de déchets à mettre en décharge.

6.1. La collecte des déchets

La collecte des déchets englobe différentes techniques ayant pour objet l'élimination de déchets urbains.

6.1.1. La collecte non sélective

La collecte en bordure de trottoir, dans laquelle les déchets sont collectés à intervalles réguliers par des véhicules spécialisés, est la méthode d'élimination la plus populaire dans la plupart des pays européens et africains comme L'Algérie, au Canada, en Nouvelle-Zélande, aux États-Unis. Elle est fréquemment associée à la séparation des déchets en bordure de trottoir. Dans les zones rurales, il peut être nécessaire de transporter les déchets (voir figure 2) jusqu'à une station de transfert. Les déchets sont ensuite acheminés vers un site d'élimination approprié. La collecte par aspiration est utilisée dans certains endroits, où les déchets sont transportés par aspiration à partir d'une maison ou d'une entreprise à l'aide de petits tubes. Des systèmes sont utilisés en Europe et en Amérique du Nord [12]

Malheureusement la collecte par aspiration ne se pratique pas en Algérie jusqu'à présent



Figure 1.2 Poubelle à roulettes en plastique moulé dans le Berkshire [12].

6.1.2. La collecte sélective

La collecte sélective consiste à ramasser séparément une ou plusieurs catégories de déchets dont le verre, les papier et carton, la ferraille qui sont déjà bien connues du public [13].

La collecte sélective est réalisée selon deux systèmes le système d'enlèvement et le système d'apport volontaire, qui pouvant être combinés pour optimiser le taux de collecte Dans **le système d'enlèvement**, les ménages et les entreprises doivent être dotés de sacs coloriés ou bien de bacs additionnels qui se différencient, par la couleur ou par la forme, des bacs d'ordures ménagères. Le dépôt se fait individuellement ou en regroupement. La séparation des déchets selon les possibilités de réutilisation ou de recyclage nécessite un service de collecte à part et une fréquence d'évacuation différente. [13]

En général, pour la collecte sélective additionnelle en **porte - à - porte**, les habitants doivent disposer de 1 ou 2 bacs différents supplémentaires, placés avec les conteneurs des ordures ménagères :

- Un conteneur pour les déchets ultimes issus du tri des ordures ménagères.
- Un conteneur pour les matériaux valorisables comme papiers, cartons, plastiques, métaux [13].



Figure 1.3 Poubelles de tri sélectif [15]

Il existe aussi beaucoup d'autres possibilités de séparation avec bacs ou sacs.

Habituellement, on trouve différents conteneurs pour les matériaux suivants :

- ✓ Verre
- ✓ Cartons textiles
- ✓ Plastiques

Selon la Communauté Européenne Pour garantir une standardisation dans le domaine du recyclage des ordures ils ont établi des codes couleurs pour les conteneurs des déchets [15]

Type de déchets	Autres couleurs non normalisées
 Verre (bouteilles, bocaux)	 Déchets organiques, restes alimentaires (ex : compost)*
 Journaux, annuaires, magazines, prospectus	 Déchets pouvant être recyclés (ou déchets organiques)
 Emballages plastiques vides, métaux, cartons	 Déchets ne pouvant pas être recyclés (ou déchets dangereux)*
	 Emballages et bouteilles en plastique uniquement

Figure 1.4. Code couleurs pour la collecte sélectives [15]

En Algérie, la collecte se fait encore de manière non sélective alors que de nos jours, une gestion environnementale des déchets nécessite la mise en place d'un mode de collecte sélective, dans le but de bénéficier d'une véritable stratégie de valorisation des déchets [13].

6.2. Tri des déchets

Il s'agit du processus de séparation des déchets secs et humides. L'objectif est de faciliter le recyclage des déchets secs et le compostage des déchets humides. La quantité de déchets mis en décharge diminue considérablement lorsque les déchets sont triés, ce qui entraîne une baisse

des niveaux de pollution de l'air et de l'eau. Il est important de se rappeler que le tri des déchets doit se faire en fonction du type de déchets et du traitement et de l'élimination les plus appropriés. Cela facilite également l'utilisation de plusieurs méthodes de traitement des déchets, comme la réutilisation, le recyclage et l'incinération [14]

6.2.1. Processus de Tri des déchets :

Pour valoriser le plastique, le papier, le carton, l'aluminium, un processus de tri par matière est indispensable. Les matières triées peuvent ensuite être retransformées en nouveaux, le processus de tri déroule selon les étapes suivantes :

6.2.2. Déchargement et pré-tri des déchets :

Le camion arrive au centre de tri et pèse. Les déchets sont ensuite déversés sur l'aire de déchargement de la carrière de réception. Dans la carrière, des excavatrices poussent les déchets sur des tapis pour les transférer vers des baies de tri. Les techniciens évacuent ensuite les déchets non recyclables [14]



Figure 1.5. déchargements des déchets dans une carrière spécial [17]

6.2.3. Tri automatisé

Dans cette partie, il reste sur le tapis, le papier, les canettes, les bouteilles, les bouteilles en plastique, les canettes, Le passoire divise ensuite les déchets en 2 catégories : Les déchets dits " légers « papiers, cartons... » Les déchets lourds « bouteilles en plastique, flacons, briques alimentaires, canettes... » Les gros électro-aimants adsorbent les emballages en acier tels que les canettes en fer et les compriment directement en billes d'acier. Le séparateur capte les petits éléments en aluminium. Les trieurs optiques séparent les différents plastiques (transparents et

opaques) et les briques alimentaires. Les déchets sont ainsi automatiquement triés par taille et par poids, puis transférés sur un tapis roulant pour un tri manuel en fonction du matériau [17].



Figure 1.6.mécanisme du Tri automatique [17]

6.2.4. Tri manuelle

Enfin, pour la dernière étape du processus de tri, les ordures arrivent du tri automatique sur deux tapis, Des agents sont présents aux environs des tapis pour préciser la sélection des éléments recyclables.

Ils les extraient du tapis et les déposent dans des différents bacs [17].

Sur le tapis des déchets légers : papiers, journaux, cartons, ils retirent :

- Bac papiers,
- Bac journaux
- Bac magazines carton

Sur le tapis de déchets lourds : bouteilles en plastique, briques alimentaires, boîtes de conserve en aluminium, ils enlèvent

- Bac pour les bouteilles en plastique.
- Les pour les briques alimentaires.
- Bac pour les canettes en aluminium.



Figure 1.7.Tri manuelle [17]

Les déchets sont alors triés par matière et conservés dans les bacs. Ils sont ensuite transmis à une presse à balles pour être compressés par celle-ci en gros cubes appelés balles [14].



Figure 1.8.illustration des différents types des balles[17]

Le tri des déchets est essentiel pour de nombreuses raisons, notamment les obligations légales, les économies financières et la préservation de la santé humaine et de l'environnement, il est aussi la seule moyenne pour rassurer une stratégie optimale pour la réduction des déchets.

7. Valorisation des déchets

La valorisation des déchets sert la protection de l'environnement puis qu'elle tend à diminuer les quantités de déchets à stocker, qui sont une source de pollution des sols et des eaux souterraines et elle permet en même temps de réduire l'exploitations des matières premières.

7.1. Recyclage

Le recyclage est une technique de récupération des ressources qui consiste à collecter et à réutiliser des déchets tels que des canettes de boisson vides (voir figure 3). Cette procédure implique le démantèlement et la réutilisation de matériaux qui seraient autrement mis au rebut. Le recyclage présente divers avantages et, grâce aux nombreuses nouvelles technologies qui rendent encore plus de choses recyclables, il est possible d'assainir l'environnement [16].



Figure 1.9. Mis en balles des déchets pour le recyclage [16].

Le recyclage n'est pas seulement bon pour l'environnement, mais aussi pour l'économie. Les ressources utilisées pour fabriquer les objets peuvent être recyclées pour créer de nouveaux articles. Les matériaux recyclés peuvent être collectés séparément des déchets à l'aide de conteneurs et de véhicules de collecte spéciaux, un processus connu sous le nom de collecte en bordure de trottoir. Dans certaines villes, tous les matériaux recyclables sont collectés dans un seul bac, et le tri est ensuite effectué dans un lieu central. Le "recyclage à flux unique" est le terme qui désigne ce dernier processus. [16].

7.2. Réutilisation

La réutilisation n'est pas le recyclage, car le recyclage modifie la forme physique d'un objet ou d'un matériau. La réutilisation est généralement préférée au recyclage parce que la réutilisation consomme généralement moins d'énergie et de ressources que le recyclage. Nous citerons les différents types de réutilisation des déchets ci-dessous :

7.2.1. Retraitement biologique

Les matières végétales, les restes de nourriture et les produits en papier sont des exemples de matières organiques récupérables qui peuvent être valorisées en utilisant des méthodes de compostage et de digestion pour dégrader la matière organique (voir figure 4). Les déchets organiques sont ensuite recyclés en paillis ou en compost pour être utilisés dans l'agriculture ou l'aménagement paysager. En outre, les gaz résiduels issus du processus (comme le méthane) peuvent être récupérés et utilisés pour produire de l'électricité et de la chaleur (PCCE/cogénération), ce qui permet d'accroître l'efficacité. Les processus et technologies de compostage et de digestion se présentent sous diverses formes [18].



Figure 1.10. Un composteur florissant [18].

Leur complexité varie du modeste tas de compost domestique à la digestion industrielle à grande échelle de déchets résidentiels mixtes. Les processus de décomposition biologique sont divisés en deux catégories : aérobie et anaérobie. Des hybrides de ces deux méthodes sont utilisés dans plusieurs méthodes. La digestion anaérobie de la partie organique des déchets solides est plus écologique que la mise en décharge ou l'incinération. [18].

7.2.2. Récupération d'énergie

La conversion de déchets non recyclables en chaleur, en électricité ou en combustible utilisables par un certain nombre de procédés tels que la combustion, la gazéification, la Pyrolyse, la digestion anaérobie et la récupération des gaz de décharge est connue sous le nom de valorisation énergétique des déchets. La transformation des déchets en énergie est un terme utilisé pour décrire ce processus. La hiérarchie de la gestion des déchets non dangereux comprend la valorisation énergétique des déchets. La valorisation énergétique, qui transforme les déchets non recyclables en courant électrique et en chaleur. La valorisation énergétique des déchets représente 16 % de la gestion des déchets dans le monde [18].

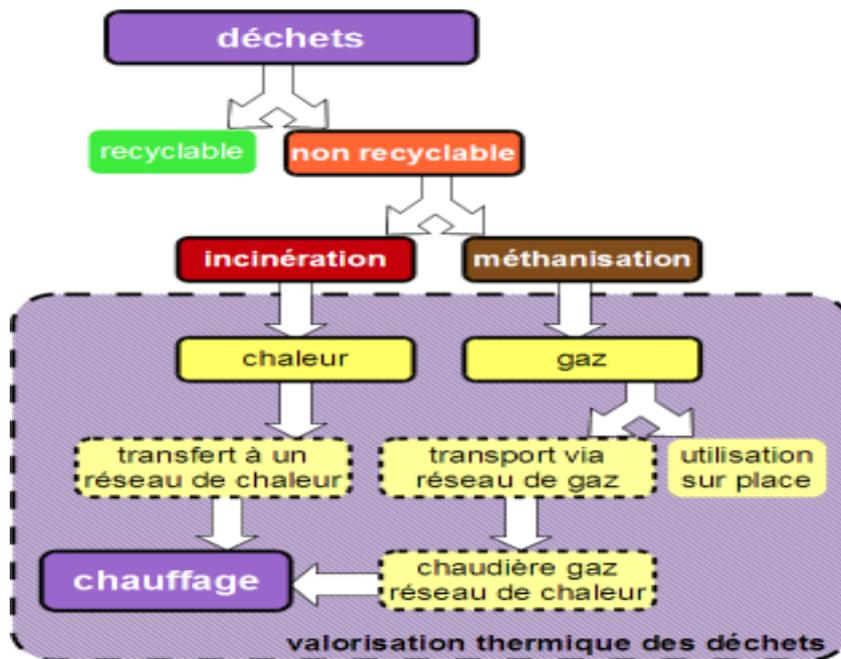


Figure 1.11. Valorisation thermique des déchets [18]

7.2.3. La méthode de pyrolyse

La pyrolyse est fréquemment utilisée pour récupérer du carburant à partir de divers déchets résidentiels et industriels. En utilisant divers déchets (tels que les déchets végétaux, les déchets alimentaires et les pneus l'environnement,).

La pyrolyse est la décomposition thermochimique des composés organiques par la chaleur en l'absence de quantités stœchiométriques d'oxygène, ce qui donne lieu à une variété de gaz hydrocarbonés. Les molécules d'un objet vibrent à des fréquences si élevées pendant la pyrolyse qu'elles commencent à se décomposer. La vitesse de la pyrolyse augmente avec la température. Dans les applications industrielles, les températures sont supérieures à 430 °C (800 °F) [18].

7.2.4. Récupération des ressources

La réorientation systématique des déchets destinés à l'élimination vers un autre usage spécifique est connue sous le nom de valorisation des ressources. Il s'agit du processus d'extraction ou de récupération de matériaux et de ressources à partir de matières recyclables, ou de leur conversion en énergie. Dans une usine de récupération des ressources, plusieurs tâches sont effectuées. Non seulement la récupération des ressources est bénéfique pour l'environnement.

De nombreux produits mis au rebut, comme les cartes de circuits imprimés, contiennent des métaux qui peuvent être recyclés à profit, ce qui illustre l'utilité du recyclage des ressources. Les copeaux de bois provenant de palettes et d'autres matériaux d'emballage peuvent être

réutilisés dans des produits horticoles. Les copeaux recyclés peuvent recouvrir des chemins, des allées ou des surfaces d'arène.

L'application de pratiques rationnelles et cohérentes de gestion des déchets peut apporter une série d'avantages, notamment [18] :

- **Économique** : L'amélioration de l'efficacité économique par l'utilisation, le traitement et l'élimination des ressources, ainsi que la création de marchés pour les produits recyclables, peuvent conduire à des pratiques plus efficaces dans la production et la consommation de produits et de matériaux, ce qui entraîne la récupération de matériaux précieux pour la réutilisation et la création de nouveaux emplois et de nouvelles opportunités commerciales.
- **Social** : Les conséquences qui en découlent comprennent des communautés civiques plus attrayantes du fait de la réduction des impacts négatifs sur la santé grâce à des pratiques de gestion des déchets efficaces. De meilleurs avantages sociaux peuvent conduire à de nouvelles formes d'emploi et peut-être sortir les communautés de la pauvreté, en particulier dans les nations et les villes émergentes.
- **Environnement** : l'amélioration de la qualité de l'air et de l'eau et la réduction des émissions de gaz à effet de serre peuvent être obtenues en diminuant ou en éliminant les incidences négatives sur l'environnement par la réduction, la réutilisation et le recyclage, ainsi qu'en minimisant l'exploitation des ressources.
- **Équité intergénérationnelle** : Le respect des bonnes pratiques de gestion des déchets peut se traduire par une économie plus stable, une société plus équitable et plus inclusive, et un environnement plus propre pour les générations futures.

8. Gestion des déchets par région.

Seule la mise en décharge contrôlée des déchets est en mesure de répondre aux exigences élémentaires en matière d'hygiène et de protection de l'environnement.

Le Maroc a récolté les avantages d'un système de décharge sanitaire d'une valeur de 300 millions de dollars. Bien que cette dépense puisse sembler onéreuse, le gouvernement du pays estime qu'elle lui permettra d'économiser 440 millions de dollars en dommages causés par l'élimination inadéquate des déchets [20].

Royaume-Uni le ministère de l'environnement, de l'alimentation et des affaires rurales est chargé des politiques de gestion des déchets au Royaume-Uni (DEFRA). Le "Waste Management Plan for England" est un recueil des politiques de gestion des déchets en Angleterre. [21].

En Zambie, ASAZA est une organisation communautaire dont le principal objectif est de soutenir les efforts du gouvernement et des autres partenaires coopérants pour améliorer le niveau de vie des communautés défavorisées. L'objectif principal du projet est de réduire le problème des déchets sauvages, qui entraînent la contamination de l'environnement et la détérioration des terres. Dans le même temps, ASAZA contribue à atténuer les problèmes de chômage et de pauvreté en générant des revenus et en rémunérant les participants, les femmes et les jeunes non qualifiés [21].

En Algérie, La plupart des décharges actuelles peuvent être classées comme décharges sauvage présentant de très nombreux inconvénients, parmi lesquels [13] :

- Aspect déplaisant à cause des odeurs, des poussières et des éléments volatiles légers transportés par le vent
- Pollution des sols, des eaux souterraines et des eaux
- Prolifération d'insectes et de rongeurs, vecteurs de maladies contagieuses.
- Risque d'incendie, d'explosion, de glissement

9. La gestion intelligent des déchets

Des méthodes techniques intelligentes basées sur l'apprentissage profond ont contribué, également à la gestion des déchets plus précisément ils sont intégrés dans le processus de collecte et tri.

9.1. Le principe de la gestion intelligent des déchets :

Se concentre sur la résolution des problèmes de gestion des déchets solides mentionnés précédemment à l'aide de capteurs, de systèmes de surveillance intelligents et d'applications mobiles. Les capteurs constituent la première solution de gestion intelligente des déchets permettant de rendre le processus de collecte des déchets plus efficace. Les capteurs peuvent

mesurer le niveau de remplissage des conteneurs, fournir des informations actualisées à tout moment et avertir les services de gestion des déchets de les vider lorsqu'ils sont pleins ou presque pleins. Ces dispositifs permettent d'optimiser le meilleur itinéraire possible contenant des conteneurs entièrement remplis et de créer des horaires intelligents pour les conducteurs. La sélection des conteneurs minimise également le besoin en personnel de collecte des déchets car leurs tâches sont déduites. Grâce à leurs fonctionnalités GPS, ils peuvent également alerter les entreprises de gestion des déchets ou les municipalités si un incident indésirable se produit, comme une hausse soudaine de la température ou le déplacement du conteneur [19].

➤ **Avantages des solutions de gestion intelligente des déchets :**

- Réduction du coût de la collecte et de la consommation inutile de carburant pour les entreprises de collecte.
- Analyse des données géo-spécifiques de la production de déchets
- Réduction des émissions de CO2.
- Garantir la rapidité de la collecte des déchets.

➤ **Vers un tri intelligent des déchets :**

De nombreuses recherches sont menées dans le domaine du tri des déchets afin de faciliter le processus et pour assurer une valorisation intelligente et rapide des déchets. Malgré l'évolution de l'intelligence artificielle qui touche tous les domaines, il n'existe pas une stratégie mondiale basé qui intègre et assure la collecte et le tri des déchets à la fois.

L'automatisation du tri des déchets est un défi pour notre collectivité, nous présentons quelques travaux basés sur l'intelligence artificielle au service du tri des déchets dans le chapitre suivant.

10. Les profits de la valorisation des déchets

La gestion des déchets présente de nombreux bénéfices, qui conduisent tous à un avenir écologique plus propre et plus sain.

La gestion des déchets permet aux gens de réduire, réutiliser et recycler les matériaux de nombreuses fois. Certains des points suivants peuvent être considérés comme des avantages de la gestion des déchets pour tous ceux qui y participent :

- La protection de l'environnement
- La promotion de l'efficacité énergétique
- La conservation des matières premières et des ressources limitées
- La création d'une communauté plus forte et plus unifiée
- La création de plus d'emplois
- Une amélioration des finances personnelles



Figure 1.12 l'environnement et valorisation des déchets| [23]

11. Conclusion

Le tri des déchets consiste à séparer les déchets en différents types. Le traitement correct des déchets passe par un tri efficace. La séparation doit être effectuée le plus tôt possible afin de minimiser la contamination des déchets par d'autres matières. Pour cela, il est nécessaire d'automatiser ce processus afin de faciliter la tâche des entreprises de gestion des déchets

Nous devrions faire de notre mieux pour aider à protéger Mère Nature. En éliminant nos déchets correctement, nous aurons un environnement plus propre et un air plus frais à respirer. Nous devrions former les jeunes à l'élimination correcte des déchets et leur apprendre à prendre soin de l'environnement. C'est très important pour préserver l'environnement.

Dans ce chapitre, nous avons introduit la gestion des déchets, à travers un ensemble de notions, à savoir : une définition des déchets, l'histoire des déchets, la gestion des déchets, la hiérarchie des déchets, la réduction et le tri des déchets, la valorisation des déchets, pour finir avec les technologies qui sert à une gestion intelligente des déchets.

Dans le chapitre suivant, nous détaillerons quelques travaux connexes dans le domain du tri intelligent des déchets.

Chapitre 2 :

L'état de l'art

Chapitre 2 :

L'état de l'art

1. Introduction

L'intelligence artificielle est officiellement devenue une discipline scientifique qui vise à décomposer l'intelligence en fonctions élémentaires afin de créer des machines capables d'imiter les capacités cognitives humaines. La réflexion, ainsi que la communication et la mémoire qui est la capacité d'enregistrer et de conserver les données.

Dans ce chapitre nous allons explorer plus en détail l'apprentissage profond, nous allons couvrir exactement les réseaux de neurones et ses différents types et architectures, nous introduisons les différents concepts de la vision par ordinateur, et la présentation des travaux connexes.

2. L'intelligence artificielle

Beaucoup d'entre nous sont incapables de faire la distinction entre l'intelligence artificielle (IA), l'apprentissage machine (ML) et l'apprentissage profond (DL), mais bien que ces trois termes soient souvent utilisés de manière interchangeable, ils ne désignent pas les mêmes choses. Voici une figure qui tente de visualiser la distinction ou la relation entre eux (voir figure 1). L'apprentissage automatique est un moyen d'analyser les données. Il est également considéré comme une branche de l'intelligence artificielle fondée sur l'idée que les systèmes peuvent apprendre à partir de données, déterminer des modèles et prendre des décisions de manière autonome, avec une intervention humaine minimale [26].

En raison des nouvelles technologies informatiques, l'apprentissage automatique moderne ne peut être comparé à l'apprentissage automatique du passé. Il est né de la reconnaissance des formes et de la théorie selon laquelle les ordinateurs peuvent apprendre sans être programmés pour effectuer des tâches spécifiques. Les chercheurs intéressés par l'intelligence artificielle voulaient savoir si les ordinateurs pouvaient apprendre à partir de données. L'aspect itératif de l'apprentissage automatique est important car, lorsque les modèles sont exposés à de nouvelles données, ils peuvent s'adapter de manière autonome. Ils apprennent des calculs précédents pour produire des décisions et des résultats fiables et reproductibles. C'est une science qui n'est pas nouvelle, mais qui a pris un nouvel élan [26].

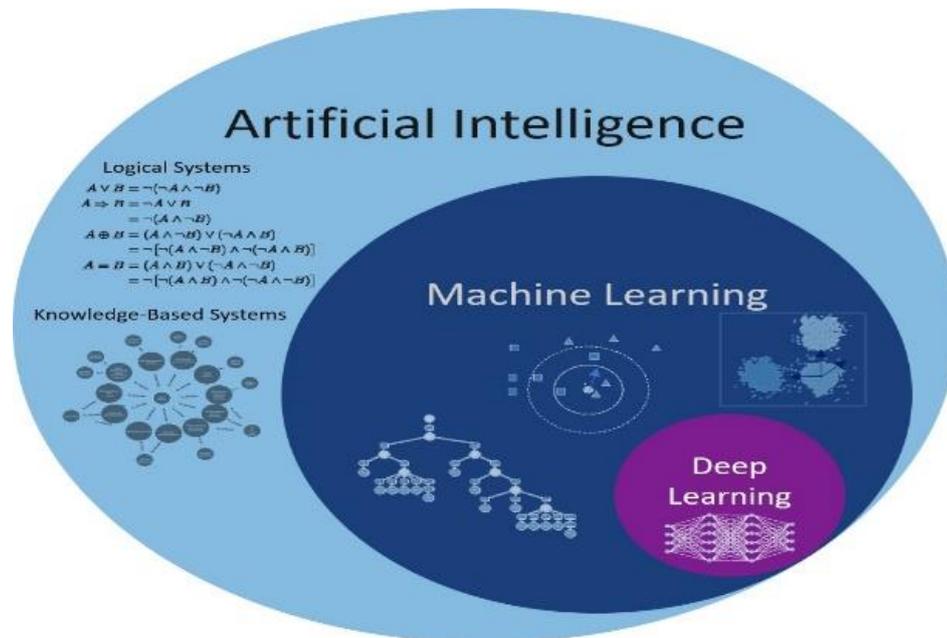


Figure 2.1 l'intelligence artificielle [26]

3. L'apprentissage automatique

L'apprentissage automatique (ML : Machine Learning) est un sous domaine de l'IA axé sur la création des systèmes qui apprennent à résoudre un problème ou améliorent leurs performances en fonction de données sur lesquelles ils travaillent [24].

Ce champ d'étude comporte des algorithmes capables d'extraire des règles mathématiques à partir de l'ensemble de données en s'entraînant sur ses exemples, afin d'appliquer ces règles sur de nouvelles données pour l'évaluation et l'amélioration continue. Ces algorithmes sont les moteurs du ML. En général, deux classes principales d'algorithmes sont utilisées aujourd'hui : l'apprentissage supervisé et l'apprentissage non supervisé [25].

3.1. L'apprentissage supervisé

Les algorithmes de cette classe apprennent à tirer des conclusions après entraînement sur des données dites annotées (étiquetées) auparavant et dont le résultat est déjà prédéfini [24].

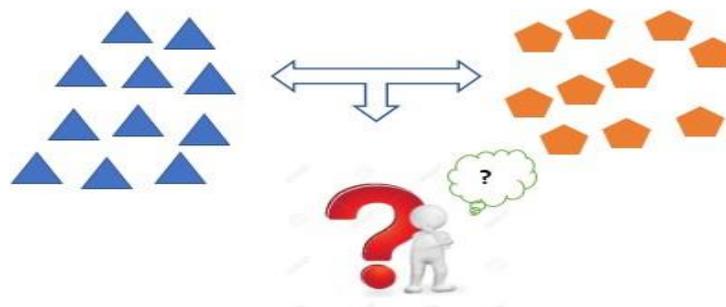


Figure 2.2 Apprentissage supervisée

3.2. L'apprentissage non supervisé

Dans cette classe, les algorithmes utilisent une approche plus indépendante dans laquelle une machine apprend à identifier des connaissances dans un ensemble de données dont le résultat n'est pas prédéfini, et sans aucune intervention externe servant à la guider.

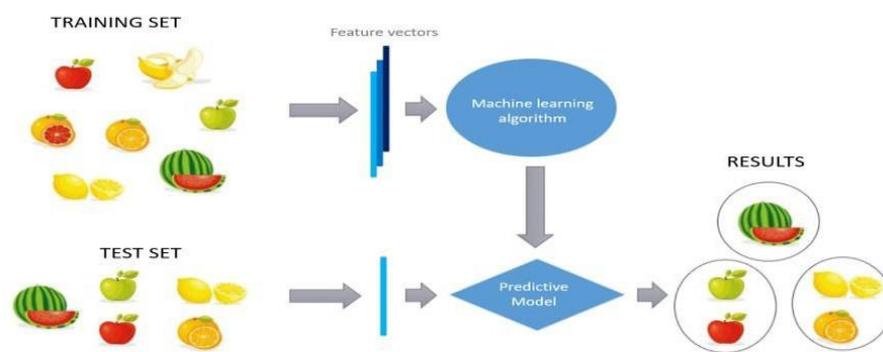


Figure 2.3 apprentissage non supervisé [16].

Parmi les fameux algorithmes de ce mode d'apprentissage, on trouve l'algorithme du K-means, le Mean Shift, le PCA (Principal Component Analysis), etc. [24]

4. Apprentissage profond

Le DL est un ensemble de méthodes du ML basées sur des architectures de réseaux de neurones, visant à imiter la « profondeur » des couches d'un cerveau humain. Dans ce dernier, une action est la concrétisation d'une suite de communications synaptiques entre nombreuses couches de traitement. Le DL réunit une classe d'algorithmes d'apprentissage correspondants à ces architectures profondes. Il est souvent utilisé pour un apprentissage qui fait l'extraction des traits utiles des données et également apprendre à mieux les exploiter. Dans la rétro-propagation de gradient, le system est constitué d'une série de modules appelés couches dont chacun représente une étape de traitement qui comporte des paramètres ajustables qui, pour chaque élément de la base de données, font rapprocher la valeur de la sortie de la valeur désirée. Cela fait appel à la fois à des connaissances en neurosciences et en mathématiques et à la maîtrise technologique [27].

4.1. Histoire et applications du l'apprentissage profond

Le tableau 2.1 suivant présente un bref historique de l'apprentissage profond :

Tableau 2.1 Historie de DL

1943	Le premier modèle mathématique d'un réseau de neurones	1989	Q-Learning et les machines lisent les chiffres écrits à la main
------	--	------	---

1950	La prédiction de l'apprentissage automatique	1995	Machines à vecteur de support
1952	Premiers programmes d'apprentissage automatique	1997	Proposition de mémoire à long terme
1957	Poser les bases des réseaux neuronaux profonds	1998	Apprentissage par gradient
1959	Découverte des cellules simples et complexes	2009	Lancement d'ImageNet
1960	Théorie du contrôle	2011	Création d'Alex Net
1965	Les premiers réseaux d'apprentissage profond	2012	L'expérience du chat
1979-80	Un ANN apprend à reconnaître des modèles visuels	2014	Visage profond
1985	Un programme enseigne comment prononcer les mots anglais.	2014	Réseaux adversaires génératifs (GAN)
1986	Amélioration de la reconnaissance des formes et de la prédiction des mots	2016	Produits puissants d'apprentissage automatique

Le Deep Learning change le regard du monde sur les technologies. L'intelligence artificielle (IA) et ses branches, à savoir l'apprentissage automatique (ML) et l'apprentissage profond, suscitent actuellement beaucoup d'engouement.

Voici donc des applications Deep Learning qui domineront le monde en 2018 et au-delà :

- ✚ Voitures autonomes.
- ✚ Apprentissage profond dans les soins de santé.
- ✚ Recherche vocale et assistants à commande vocale.
- ✚ Ajout automatique de sons aux films muets.
- ✚ Traduction automatique.
- ✚ Génération de texte automatique.
- ✚ Génération d'écriture automatique.
- ✚ Reconnaissance d'images.

4.2. Le réseau de neurones convolutifs (CNN)

Le réseau de neurones convolutifs (CNN : Convolutional Neural Network) est un type particulier de réseaux de neurones dédié au traitement des données multidimensionnelles. Cette technique de DL est la première méthode basée sur les réseaux hiérarchiques à plusieurs niveaux qui a révolutionné l'IA notamment dans le domaine du traitement d'image. La connexion étroite et les

informations spatiales entre les couches du CNN le rendent particulièrement adapté à la reconnaissance des images et l'extraction automatique de leurs caractéristiques de corrélation [28].

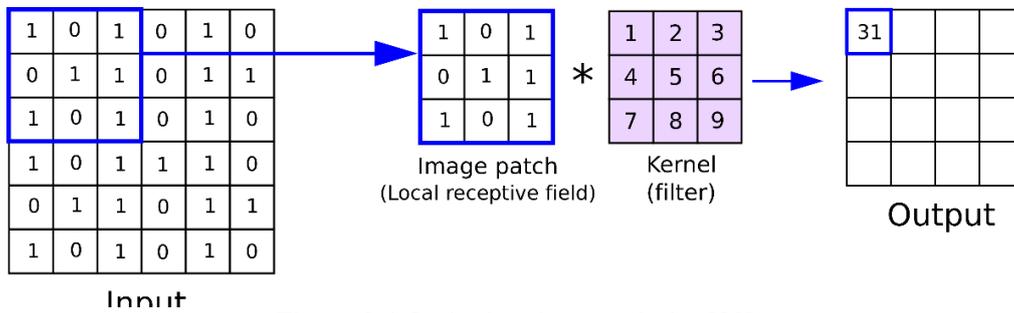


Figure 2.4 Opération de convolution[30]

L'architecture CNN consiste en la combinaison de plusieurs types de couches, on distingue :

La couche **convolution (convolutional layer)** : Consiste en l'application d'un filtre linéaire sur son entrée, dont les coefficients subissent des ajustements de la même manière que ceux d'un réseau de neurones classique. Cette couche se concrétise par la génération d'une carte caractéristique de l'entrée qui peut être une image ou bien la sortie d'une autre couche. Le type particulier de partage de poids dans une couche de convolution ne réduit pas uniquement les degrés de liberté, mais il assure aussi l'équivariance à la translation entre l'entrée et sa carte caractéristique [29]

La couche d'**activation (activation layer)** : Après la convolution, une unité linéaire rectifiée (ReLU) est appliquée à chaque élément de la carte caractéristique [29].

Activation Function	Equation	Example	1D Graph
Linear	$\phi(z) = z$	Adaline, linear regression	
Unit Step (Heaviside Function)	$\phi(z) = \begin{cases} 0 & z < 0 \\ 0.5 & z = 0 \\ 1 & z > 0 \end{cases}$	Perceptron variant	
Sign (signum)	$\phi(z) = \begin{cases} -1 & z < 0 \\ 0 & z = 0 \\ 1 & z > 0 \end{cases}$	Perceptron variant	
Piece-wise Linear	$\phi(z) = \begin{cases} 0 & z \leq -1/2 \\ z + 1/2 & -1/2 \leq z \leq 1/2 \\ 1 & z \geq 1/2 \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multilayer NN	
Hyperbolic Tangent (tanh)	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multilayer NN, RNNs	
ReLU	$\phi(z) = \begin{cases} 0 & z < 0 \\ z & z > 0 \end{cases}$	Multilayer NN, CNNs	

Figure 2.5. fonctions d'activation populaires [31]

La couche de **sous-échantillonnage (Pooling)** : Sert à calculer le maximum ou la moyenne sur une région d'une carte caractéristique pour extraire un sous échantillonnage de l'entrée. Cette étape réduit la dimensionnalité, augmente l'échelle, et prend également en charge l'invariance de

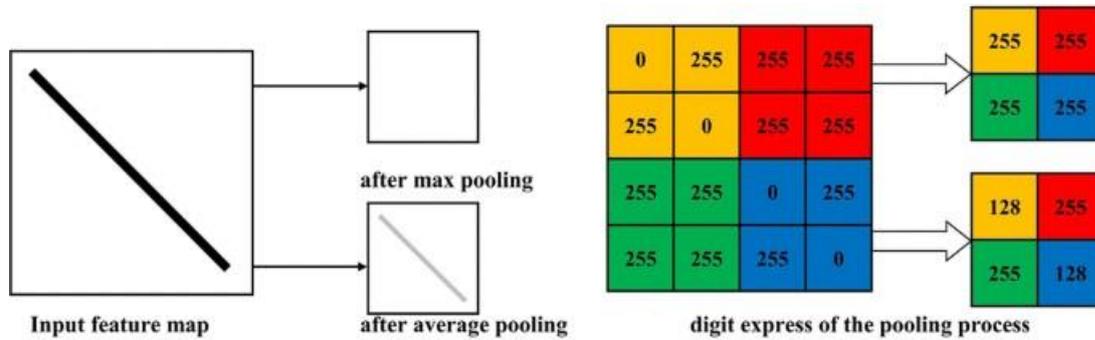


Figure 2.6. Opération de sous-échantillonnage [32]

traduction entre l'entrée et la sortie [29].

Les **réseaux de neurones multicouches standards (entièrement connectés) (fully connected layers)** : Prennent en entrée les cartes caractéristiques vectorisées résultantes des autres couches de CNN. Ils servent à une classification multi-classes basée généralement sur la fonction softmax qui transforme l'entrée en probabilités en traversant leurs couches [29].

La fonction **softmax** : Est une forme de régression logistique qui normalise des valeurs en entrée sous forme d'une distribution probabiliste.

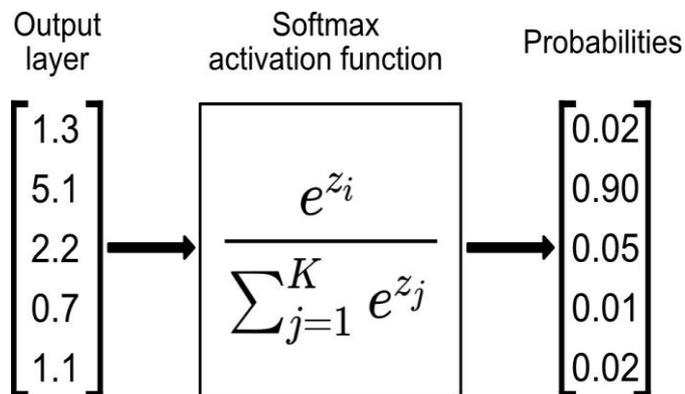


Figure 2.7. La fonction softmax [33]

Les couches de convolution et les couches de sous-échantillonnage prennent en considération la structure spatiale de leur entrée, l'équivariance inhérente à la traduction et l'invariance de la traduction, ce qui explique leurs performances dans le domaine de la vision par ordinateur et de la reconnaissance d'objet [29].

4.3. Architecture du CNN

Dans ce qui suit, on présente les architectures les plus populaires du CNN et celles utilisées pour le domaine Waste :

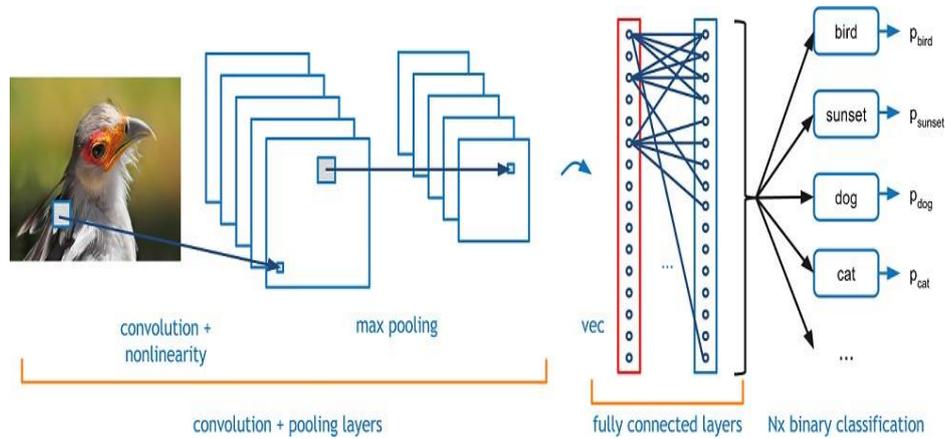


Figure 2.8. Architecture CNN [34]

VGG Net

En 2014, Simonyan et Zisserman ont proposé l'architecture de réseau VGG. Ce modèle utilise seulement 3×3 couches convolutives au-dessus du réseau CNN standard (pooling max, entièrement connecté, et couche softmax). Les résultats ont montré que la performance du réseau VGG dépassait les d'autres modèles à l'époque. L'architecture VGG à succès est disponible en deux tailles, VGG16 et 19. Les nombres 16 et 19 faisaient référence aux nombres de couches de poids dans le réseau. VGG19 était meilleur que VGG16 car il avait une couche plus profonde mais malheureusement cette propriété a augmenté la taille du modèle.

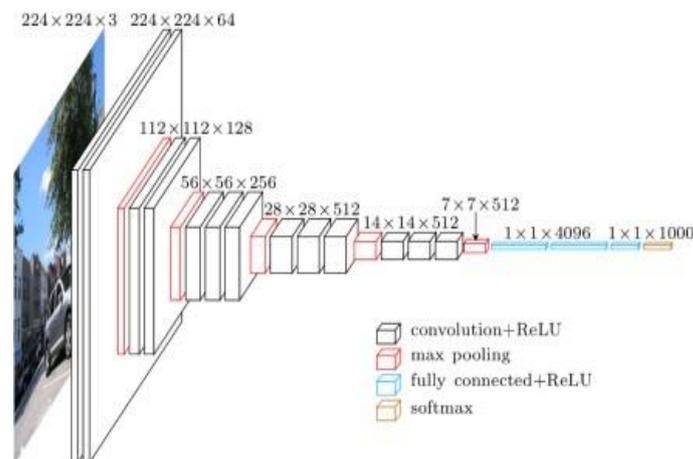


Figure 2.9. Architecture VGG16 [34]

ResNet

En 2015, le réseau de neurones résiduels (ResNet) de Kaiming He et al a introduit une nouvelle architecture avec des « skip connections » et présente une normalisation par lots. De telles connexions de saut sont également connues sous le nom d'unités fermées ou d'unités récurrentes fermées et ont une forte similitude avec les éléments réussis récents appliqués dans les RNN. Grâce à cette technique, ils ont pu entraîner un NN avec 152 couches tout en ayant une complexité inférieure à celle de VGGNet. Il atteint un taux d'erreur parmi les 5 premiers de 3,57%, ce qui surpasse les performances de niveau humain sur cet ensemble de données. [37]

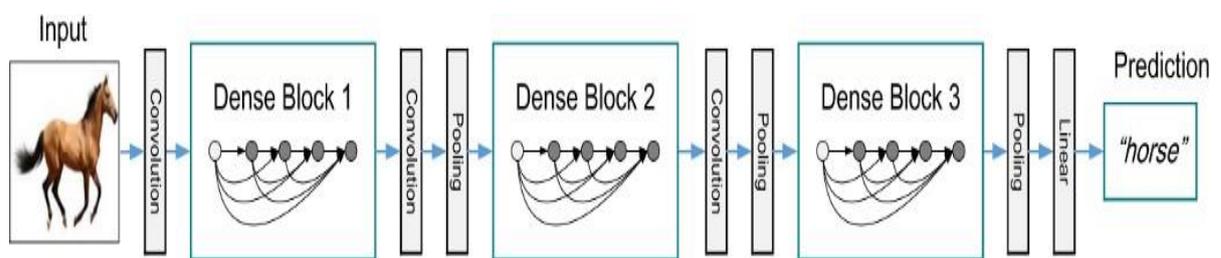


Figure 2.10. Architecture Resnet [37]

5. DL pour les tâches de la vision par ordinateur

Ces dernières années, le DL a bouleversé de plus en plus d'applications, notamment dans le traitement du langage naturel, l'analyse des sentiments et surtout dans le domaine de la vision par ordinateur, elle a été efficace dans des tâches qui semblent difficiles à traiter avec les techniques traditionnelles du domaine, principalement la segmentation sémantique, la segmentation d'instances la classification et la reconnaissance d'objets.

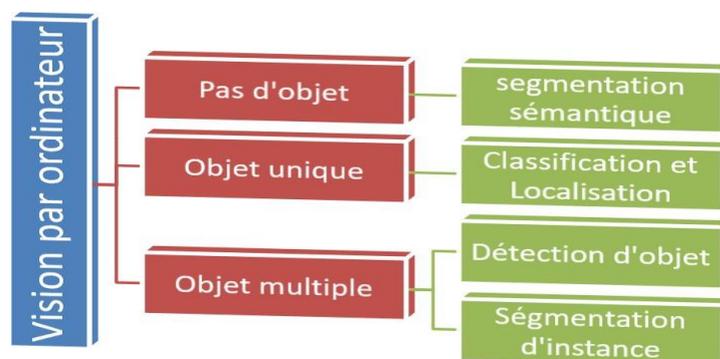


Figure 2.11. Les tâches de la vision par ordinateur [48]

5.1. Classification et localisation

Cette tâche est composée de deux parties :

- La classification appartient à la catégorie de l'apprentissage supervisé, qui a pour objectif la classification de pixels entre objet ou bien arrière-plan. [46].

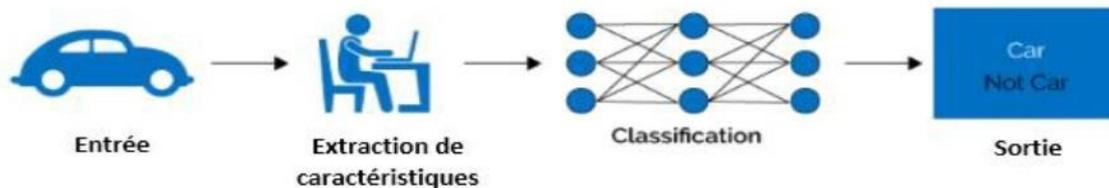


Figure 2.12. Démonstration d'une classification [46]

- La Localisation Cette partie est traitée comme un problème de régression. On génère des valeurs contenues qui constituent les coordonnées et les dimensions de la bBox qui englobe l'objet unique détecté dans l'image.

5.2. Détection d'objet

Cette stratégie fonctionne de la même manière que la classification et localisation, sauf le fait qu'elle détecte tous les objets qui figurent dans l'image de l'entrée (multiple objets).

5.2.1. Les techniques DL utilisées pour la détection

Les méthodes de détection d'objet basées sur le deep learning sont multiples, les algorithmes de R-CNN font partie des méthodes permettant d'appliquer les modèles de deep Learning au problème de détection d'objet. En voici quelques-uns :

5.2.1.1. Architecture RCNN :

Le principe de cette méthode est basé sur l'utilisation d'un algorithme de recherche sélective pour extraire 2000 régions de l'image appelées régions d'intérêt (ROI). Ces régions candidates sont transformées en carrés et introduites dans un CNN pour la génération de la carte vectorielle des caractéristiques. La couche de sortie du réseau neuronal entièrement connecté du CNN constitue une entrée pour un classificateur de machine à support vectoriel (SVM) pour indiquer la classe de l'objet dans la région d'intérêt [38].

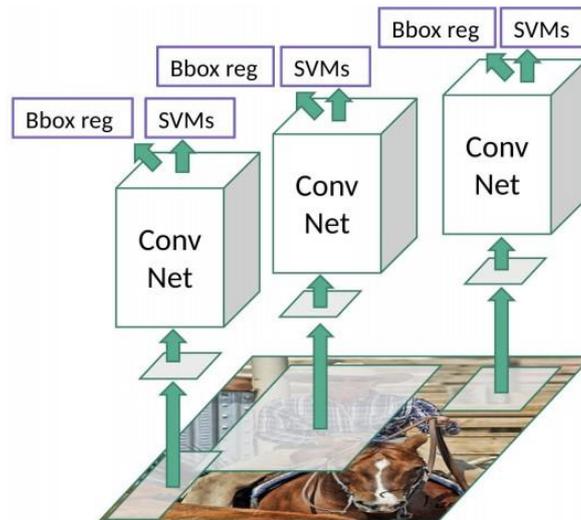


Figure 2.13 Architecture RCNN [38]

5.2.1.2. Architecture Faster-RCNN

Faster RCNN est une architecture de détection d'objets présentée par Ross Girshick, Shaoqing Ren, Kaiming He et Jian Sun en 2015, et est l'une des célèbres architectures de détection d'objets qui utilise des réseaux de neurones à convolution comme YOLO (You Look Only Once) et SSD (Single Shot Détecteur) [43]

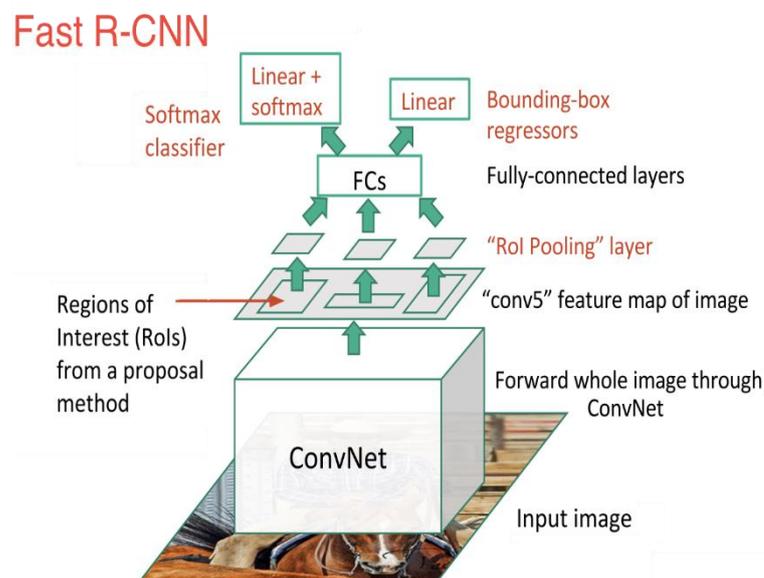


Figure 2.14. Architecture Faster-RCNN [43]

Faster RCNN est composé de 3 parties :

- Partie 1 : Couches de convolution :

Dans cette couche, les filtres qui seront entraînés pour extraire les caractéristiques devront être appropriés à l'image, par exemple, pour entraîner des filtres pour extraire les caractéristiques appropriées d'un visage humain, ces filtres vont apprendre en formant des formes et des couleurs qui n'existent que dans le visage humain.

➤ **Partie 2 : Réseau de propositions de région (RPN) :**

RPN est un réseau entièrement convolutif qui prédit simultanément les limites d'objet et les scores d'objectivité à chaque position. Le RPN est formé de bout en bout pour générer des propositions régionales de haute qualité [45]

➤ **Partie 3 : Prédiction des classes et des cadres englobants :**

En utilisant un autre réseau de neurones entièrement connecté qui prend comme entrée les régions proposées par le RPN et prédit la classe d'objets (classification) et les boîtes englobantes (régression). [43]

5.2.1.3. Architecture YOLO :

YOLO (You Only Look Once) est un algorithme qui utilise des réseaux de neurones pour fournir une détection d'objets en temps réel. Cet algorithme est populaire en raison de sa vitesse et de sa précision. Il a été utilisé dans diverses applications pour détecter les feux de circulation, les personnes, et les animaux [41].

L'algorithme YOLO utilise des réseaux de neurones convolutifs (CNN) pour détecter des objets en temps réel. Comme son nom l'indique, l'algorithme ne nécessite qu'une seule propagation vers l'avant à travers un réseau de neurones pour détecter les objets [41].

Cela signifie que la prédiction dans l'ensemble de l'image est effectuée en une seule exécution d'algorithmes. Le CNN est utilisé pour prédire simultanément diverses probabilités de classe et cadres de délimitation.

L'algorithme YOLO fonctionne à l'aide des trois techniques suivantes :

- Blocs résiduels
- Régression de la boîte englobante
- Intersection sur Union (IOU)

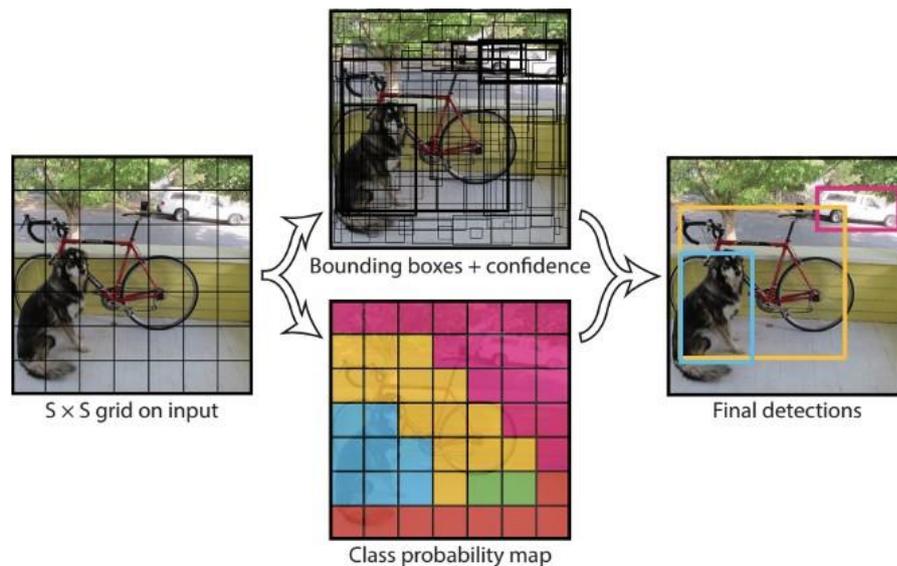


Figure 2.15. Architecture YOLO [41]

5.3. La Segmentation

L'une des opérations les plus importantes de la vision par ordinateur est la segmentation. La segmentation d'images consiste à regrouper des parties d'une image appartenant à la même classe d'objets. Ce processus est également appelé classification au niveau des pixels. En d'autres termes, il consiste à partitionner des images (ou des images vidéo) en plusieurs segments ou objets [44].

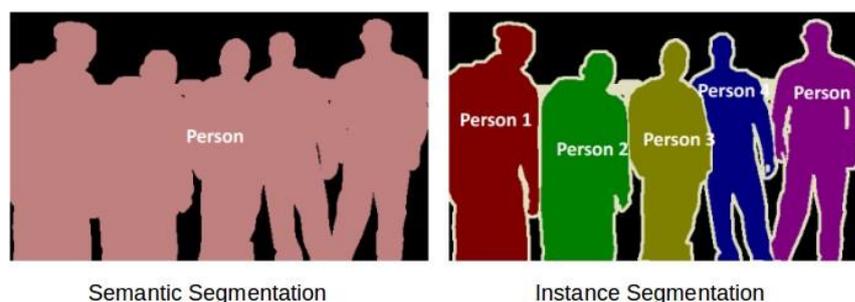


Figure 2.16. Démonstration d'une segmentation [44]

5.3.1. Les types de segmentation

Il existe 2 principaux types de segmentation d'image :

- Segmentation sémantique
 - Segmentation d'instance
- La segmentation sémantique classe chaque pixel dans un ensemble fixe de catégories sans différencier les instances d'objet. En d'autres termes, la segmentation sémantique traite de l'identification/classification d'objets similaires en une seule classe à partir du niveau du pixel. Comme le montre l'image ci-dessus, tous les objets ont été classés comme une seule entité (personne). La segmentation sémantique est également connue sous le nom de segmentation d'arrière-plan car elle sépare les sujets de l'image de l'arrière-plan [44].
 - La segmentation d'instance, ou reconnaissance d'instance, traite de la détection correcte de tous les objets d'une image tout en segmentant avec précision chaque instance. C'est donc la combinaison de la détection d'objets, de la localisation d'objets et de la classification d'objets. En d'autres termes, ce type de segmentation va plus loin pour distinguer clairement chaque objet classé comme instances similaires. Comme le montre l'exemple d'image ci-dessus, pour la segmentation d'instance, tous les objets sont des personnes, mais ce processus de segmentation sépare chaque personne en une seule entité. La segmentation sémantique est également connue sous



le nom de segmentation de premier plan car elle accentue les sujets de l'image au lieu de l'arrière-plan [44].

5.3.2. Les technique DL utilisées pour la segmentation

5.3.2.1. Architecture Unet

Cette architecture ayant la forme « U » d'où son nom, se compose de trois sections : la section de contraction, le goulot d'étranglement et la section d'expansion.

La section de contraction est composée de nombreux blocs de contraction, qui prennent chacun une entrée sur laquelle ils appliquent deux couches de convolution 3X3 suivies d'une couche de regroupement max 2X2. Le nombre de cartes caractéristiques résultantes après chaque bloc, double pour apprendre les structures complexes de manière rentable.

La couche la plus basse sert de liaison entre la couche de contraction et la couche d'expansion. Elle utilise deux couches CNN 3X3 suivies d'une couche de convolution jusqu'à 2X2.

Mais le noyau de cette architecture demeure dans la section d'extension qui tout comme la couche de contraction, est constituée de plusieurs blocs d'expansion (Le nombre de blocs d'expansion est similaire à celui de blocs de contraction). Chaque bloc transporte l'entrée vers deux couches CNN 3X3 suivies d'une couche de sur-échantillonnage 2X2.

On ajoute à cela que le nombre de cartes caractéristiques utilisées par la couche convolutionnelle est réduit à la moitié pour préserver la symétrie. Néanmoins, à chaque fois, l'entrée est également ajoutée par des cartes caractéristiques de la couche de contraction correspondante. Cette opération

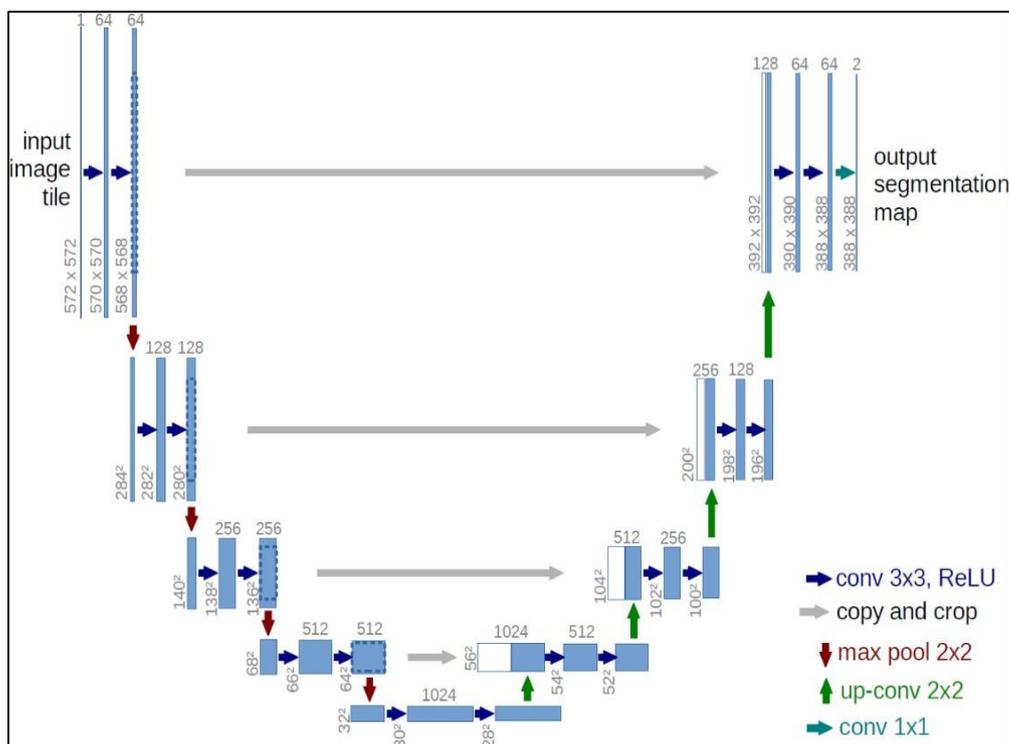


Figure 2.18. Architecture Unet [42]

assureraient l'utilisation des caractéristiques acquises lors de la contraction de l'image dans sa reconstruction. Le mappage résultant passe à travers une autre couche CNN 3X3 avec le nombre de mappages d'entités égal au nombre de segments désirés [42].

5.3.2.2. Architecture Mask RCNN

Mask R-CNN est un réseau de neurones convolutifs (CNN) à la pointe de la technologie en termes de segmentation d'images et d'instances. Mask R-CNN a été développé au-dessus de Faster R-CNN, un réseau neuronal convolutif basé sur la région [44].

Mask R-CNN a été construit en utilisant Faster R-CNN. Alors que Faster R-CNN a 2 sorties pour chaque objet candidat, une étiquette de classe et un décalage de boîte englobante, Mask R-CNN est l'ajout d'une troisième branche qui sort le masque d'objet. La sortie de masque supplémentaire est distincte des sorties de classe et de boîte, nécessitant l'extraction d'une disposition spatiale beaucoup plus fine d'un objet. Mask R-CNN est une extension de Faster R-CNN et fonctionne en ajoutant une branche pour prédire un masque d'objet (région d'intérêt) en parallèle avec la branche existante pour la reconnaissance de la zone de délimitation [44].

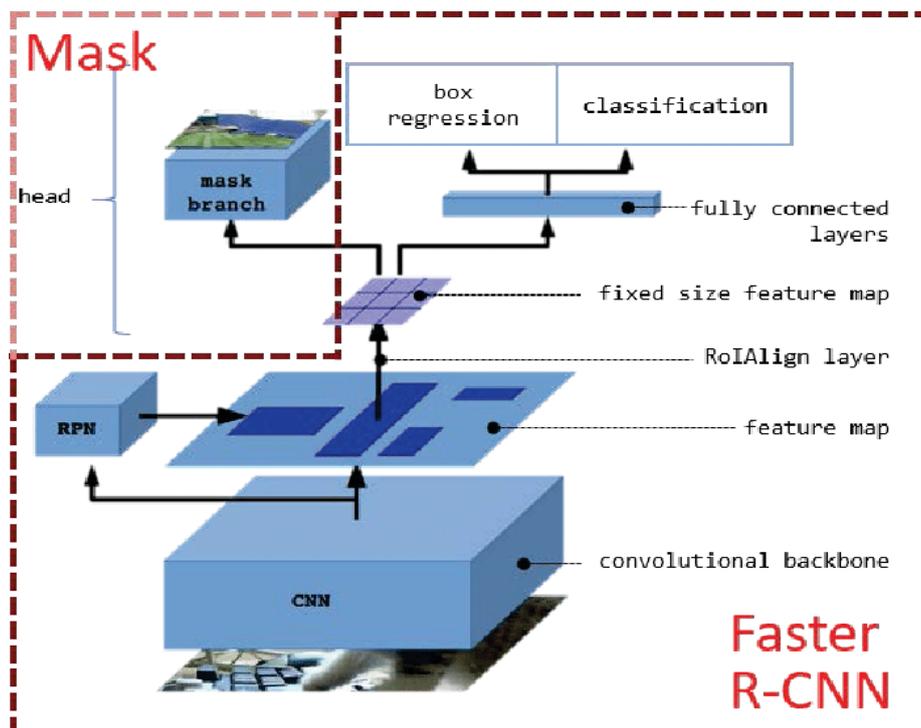


Figure 2.19. Architecture Mask RCNN [44]

Le tableau suivant réunit chaque modèle de DL avec son domaine de validité :

Modèle DL	Domaine d'utilisation
Rcnn	Détection d'objet
Faster Rcnn	Détection d'objet
YOLO	Détection d'objet
Unet	Segmentation
Mask Rcnn	Segmentation + Détection

Table 2.1. Domaine des tâches de vision par ordinateur

5.4. La différence entre les tâches de la vision par ordinateur

Les tâches de vision par ordinateur sont présentées dans la figure 21, qui souligne les différences entre elles :

- Classification : Il suffit de classer l'objet principal dans l'image.
- Classification + Localisation : Nous voulons aussi connaître la boîte de délimitation de l'objet principal.
- Détection d'objets : Il y a plusieurs objets dans l'image, et nous voulons connaître la classe et la zone de délimitation de chaque objet pour toutes les classes connues.
- Segmentation sémantique : Classifier chaque pixel dans un ensemble fixe de catégories sans différencier les instances d'objet.
- Segmentation d'instance : Classifier les objets individuels et les localiser.

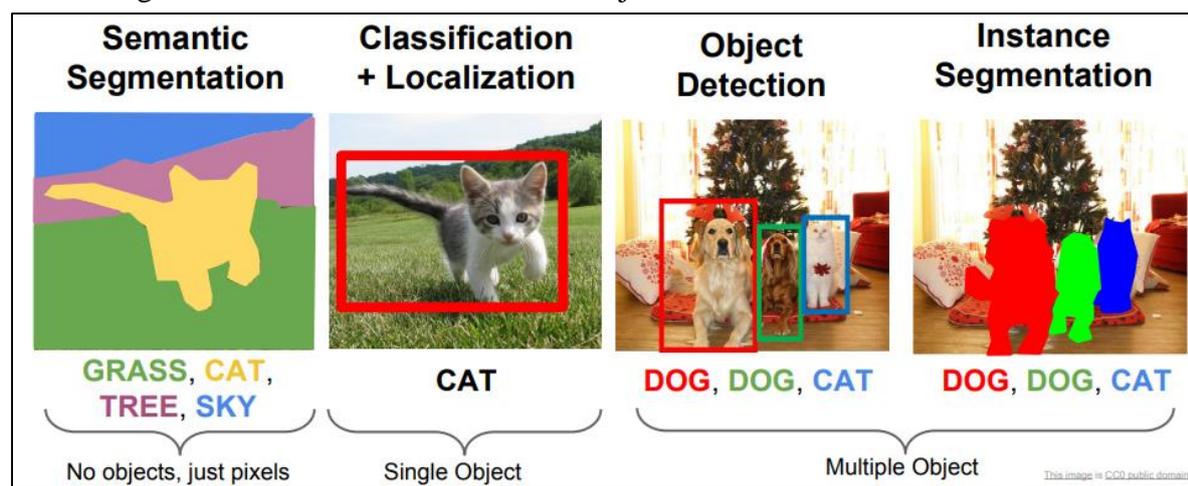


Figure 2.20 Comparaison entre segmentation sémantique, classification et localisation, détection d'objets et segmentation d'instances [30]

6. Étude de l'existant

L'étude de l'existant est une étape de base, permettant d'élaborer une synthèse bibliographique des connaissances théoriques sur le thème traité. Dans ce qui suit, nous allons

présenter quelques travaux basés sur l'apprentissage profond et l'apprentissage automatique appliqué à la gestion des déchets.

La difficulté de segmenter, localiser et de classer automatiquement des déchets présente un grand intérêt pour la communauté de la vision par ordinateur. Cependant, il existe relativement peu de travaux dans la littérature qui traitent de la tâche spécifique de la segmentation des déchets. Nous pensons que cela est dû en partie à la faible disponibilité des ensembles de données publiques utilisés pour la segmentation des déchets [50].

Ci-dessous, nous passons brièvement en revue quelques travaux récents sur la classification, la détection et la segmentation des déchets :

Selon [50], ils ont proposé une approche de vision par ordinateur pour classer les déchets en catégories. L'objectif de ce projet est de prendre des images des déchets et de les classer en six catégories : verre, papier, métal, plastique, carton et ordures. Les modèles utilisés sont des machines à vecteurs de support (SVM) avec des caractéristiques SIFT et CNN, ils ont montré que le SVM était plus efficace que le CNN [50].

Dans cette étude [51], ils ont travaillé sur deux types de déchets : les déchets biologiques et les déchets recyclables. Dans cette étude, le dataset utilisé pour la classification des déchets est reconstruit avec le réseau AutoEncoder. Les ensembles de caractéristiques sont ensuite extraits en utilisant CNN. Ils ont utilisé le SVM. L'accuracy est supérieure à 95% [51].

Selon le projet [52] qui a adopté une stratégie d'apprentissage profond pour la détection automatique des déchets. En entraînant le modèle Faster R-CNN avec deux réseaux (RPN et le ResNet). Pour améliorer la précision de la méthode, ils ont effectué une augmentation des données. AP de l'approche proposée atteint jusqu'à 80% [52].

TACO [53] est un dataset public destiné pour la détection et la segmentation des déchets. Ce projet décrit d'abord le dataset. Ensuite ils ont utilisé le Mask RCNN pour réaliser une détection des déchets. TACO contient 1500 images, l'accuracy atteint 55% [53].

D'après [54] ce travail s'appuie sur une méthode de détection des déchets, puis une classification en 8 catégories. Les données ont été fusionnées à partir de datasets publics. Le classificateur est entraîné de manière semi-supervisée en utilisant des données non étiquetées. Les résultats de l'approche proposée atteignent jusqu'à 70% de précision moyenne dans la détection des déchets et environ 75% de précision dans la classification. [54].

Selon [55] ils ont créé une dataset pour la segmentation d'objets (déchets). MJU-Waste, qui est public pour faciliter la recherche future dans ce domaine. Ils ont traité le problème de la segmentation des déchets à partir d'une image couleur. Pour l'interaction robotique avec les déchets. Plus précisément, leur méthode intègre les informations d'intensité et de profondeur à plusieurs niveaux (Depth Mask). Ils ont utilisé cette méthode sur un ensemble des modèles DL fondés sur la segmentation (DeepLabV3, PSPNET, CCNet, FCN-8s-). Une intersection-sur-union (IoU) moyenne atteignant 87%, 81% ,86% et 82 respectivement sur MJU-Waste dataset. [55].

Selon [56], ils ont introduit une méthode DL pour la segmentation sémantique des déchets en sept catégories. La structure de leur modèle est similaire à celle de SegNet et suit une structure basée sur FPA. La FPA est utilisée pour améliorer l'intégration des caractéristiques à plusieurs niveaux. Ils ont obtenu une intersection-sur-union (IoU) moyenne atteignant 0,87 et 0,67, respectivement, sur les bases de données RdIC et RdOC [56].

Selon [57], ils ont d'abord collecté et nettoyé les annotations pour créer une dataset des déchets de construction, comprenant 5 366 images. Ensuite, une technique de segmentation sémantique, basée sur DeepLabv3+, est introduite pour développer un modèle de segmentation des déchets de construction. Selon [57], ils ont obtenu une intersection moyenne sur l'union (mIoU) de 0,56 dans la segmentation de neuf types de matériaux [57].

Pour les besoins de cette recherche, différents ensembles de données ont été trouvés dans la littérature qui représentent trois contextes principaux : déchets à l'extérieur, intérieur, et déchets sous-marin.

Une brève description des principaux ensembles de données utilisés pour la gestion des déchets et de leurs caractéristiques est fournie ci-dessous :

Type	Dataset	Nombre de classe	Nombre d'image	Type d'annotation	Environnement
Segmentation	MJU-Waste	1	2475	Mask	Intérieur
Segmentation	Extended TACO	7	4562	Bbox	étiqueter
Détection	TrashCan	7	7212	Mask	sous-marin
Détection	Trash icra	7	7668	Bbox	sous-marin
Classification	Trashnet	5	2194	étiqueter	Intérieur
Classification	Waste pic	34	23 000	étiqueter	étiqueter

Détection	Drinking waste	4	4810	Bbox	Intérieur
Classification	Open Litter Map	+ 100	+ 100	Multi classes	l'extérieur

Table 2.2. Dataset pour le domaines des déchets[54]

Ci-dessous, nous passons un résumé de tous les travaux mentionnés avant pour la gestion des déchets :

Tableau 2.2 Les travaux d'état e l'art

Critère		Classes	Dataset	Modèle utilisé	Métrique dévaluation
Approches	Tao Wang.et al. [55] 2021	1	MJU-Waste	FCN-8s + ML	IOU = 0.82
				CCNet + ML	IOU = 0.86
				PSPNET + ML	IOU = 0.82
				DeepLabV3+ ML	IOU = 0.87
Segmentation	Caiyun Zh enDanhua Cao1[56] 2022	7	RdIC dataset RdOCdataset (privé)	SegNet +FPA	IOU = 0.87 IOU = 0.67
				Weisheng Lu, Junjie Chen, and Fan Xue[57] 2022	1
Détiction	Sylwia Majchrowska [54] 2022	Plusieurs types de déchets Recyclable et non-recyclable	TACO TrashNet TrashCan MJU-waste	EfficientDet-D2(detection) EfficientNet-B2(classification)	map=70%(detection) map=75%(classification) AP=85% (Mju-waste)

Détection	PedroF. Proença and Pedro Simões[53] 2020	8	Taco	Mask RCNN	Accuracy = 55%
	YingWang, Xu Zhang 52] 2020	1	Garbage dataset	Faster RCNN	AP = 80%

7. Conclusion

Dans ce chapitre, nous avons abordé l'aspect théorique de l'apprentissage profond avec ses domaines d'application, tout en expliquant les modèles que DL peut offrir, puis une présentation des modèles de segmentation et de détection avec leurs architectures pour conclure avec une comparaison entre les tâches de la vision par ordinateur et une présentation d'un aperçu sur les travaux les plus importants basés sur l'apprentissage profond.

Chapitre 3 :

Segmentation des déchets,

Conception, Implémentation et

expérimentation

Chapitre 3 :

Segmentation des déchets, Conception, Implémentation et expérimentation

1. Introduction

Ces dernières années, le domaine de l'informatique s'intéresse de plus en plus à l'automatisation des processus dans tous les domaines la gestion des déchets et aussi touchés,

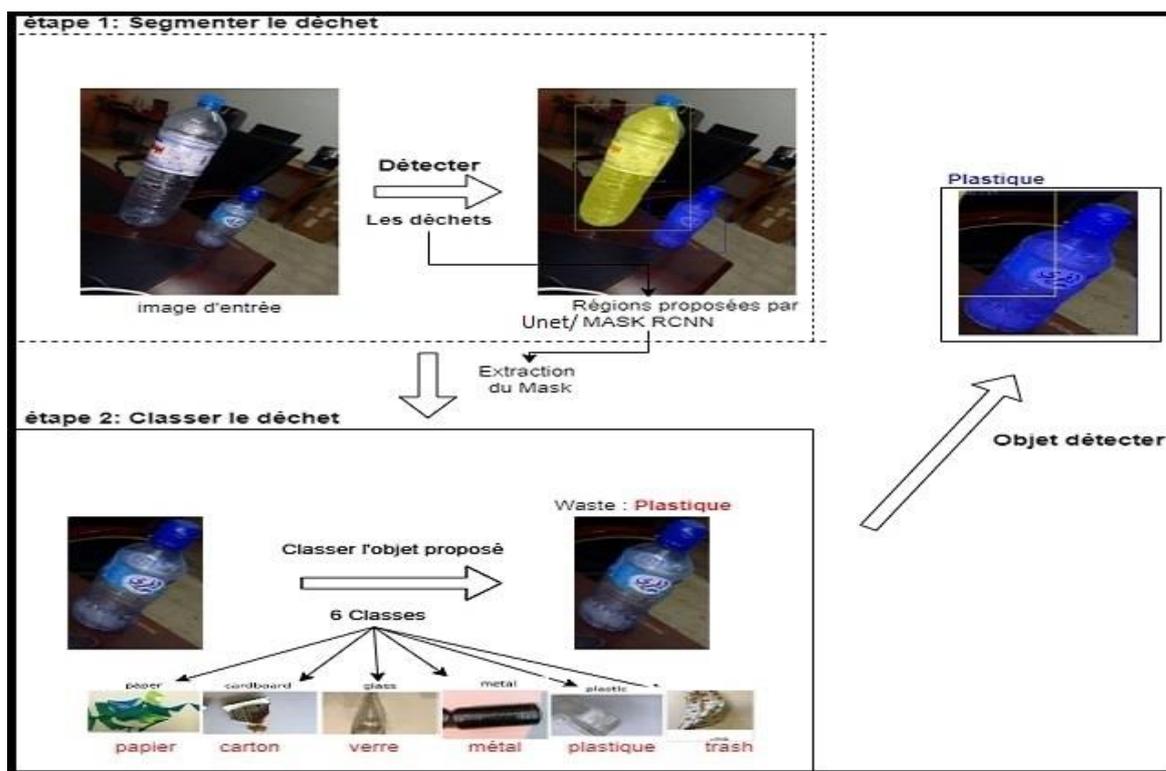
Pour cela, de nombreuses approches DL pour le tri des déchets ont été proposées dans la littérature. En général les technique DL peuvent être divisées en deux catégories différentes : les techniques de segmentation et les techniques de détection.

Dans ce chapitre nous avons proposé deux méthodes de segmentation, concernant la segmentation des déchets pour pouvoir les classer après, en plusieurs catégories (papier, plastique, métal...) afin d'obtenir un tri optimal.

L'objectif principal de cette étude est de segmenter les différents types de déchets, la base de données Mju-Waste est utilisé pour évaluer les performances des modèles proposées. Finalement, nous avons analysé les résultats et nous avons les comparés avec d'autre recherches dans le même domaine.

2. Architecture globale

Nous avons présenté l'objectif de notre travail à partir de la segmentation des déchets comme étant la première phase de la solution que nous avons proposée. Avant de passer à la deuxième phase qui concerne l'approche de classification, L'architecture globale est présentée dans la (figure 3.1) pour mieux comprendre nos objectifs.



Nous avons traité dans ce travail la première phase de l'architecture globale et plus précisément la segmentation des déchets.

Pour cela, nous proposons deux approches basées sur DL, la première se fondant sur la segmentation sémantique (Unet) et la deuxième sur la segmentation d'instance (Mask RCNN).

3. Présentation des données

Nous présenterons la dataset public utilisée pour notre travail, ainsi que le prétraitement et l'annotation appliqués à cette base de données.

3.1. Mju-Waste dataset

Ils ont créé cette base de données en collectant des déchets sur un campus universitaire en les ramenant dans un laboratoire, puis ils ont pris des photos de personnes tenant des déchets dans leurs mains. Toutes les images du jeu de données sont capturées à l'aide d'une caméra RGB Microsoft Kinect [55]

La version actuelle de dataset, MJU-Waste V1, contient 2475 images.

Tableau 3.1 Taille et type d'image dans la dataset

Taille	Type
640 x 480	RGB

Les objets sont tenus à la main et situés principalement au centre de l'image.

Dans la plupart des cas, il n'y a qu'un seul objet par image. La figure – 3.3 illustre quelques exemples du dataset [55].

3.2. Annotation des images

Cette tâche consiste à créer la partie label du dataset. Notre base de données sera utilisée pour la segmentation des déchets.

- **Annotation Unet :**



Figure 3.2.image du dataset



Figure 3.3.mask du d'une image

Les modèles basées DL orientées segmentation nécessitent des images et leurs masques en entrée pour effectuer l'apprentissage. Les masques sont des images noires avec des taches pour indiquer la présence d'un objet.

Le logiciel utilisé pour l'annotation des images pour notre Dataset c'est PixelMe.

- **Annotation Mask RCNN**

Les modèles basées DL orientées segmentation d'instance nécessitent une annotation basée sur bbox, en d'autres termes le masque est représenté sous forme d'un polygone.

Le logiciel d'annotation le plus adapté pour la segmentation d'instance est celui de LABELME, la figure – 3.6 illustre un exemple d'annotation avec un fichier Json pour l'image suivante :

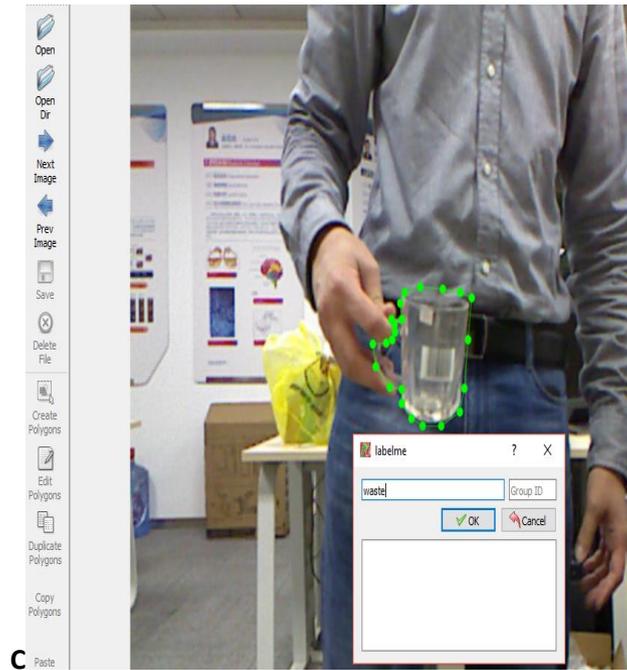


Figure 3.4. L'annotation du mask RCNN avec lable me

Les informations sur les déchets seront stockées dans un fichier JSON comme illustrédans l'image suivante :

```

{
  "version": "5.0.1",
  "flags": {},
  "shapes": [
    {
      "label": "waste",
      "points": [
        [
          334.4306569343065,
          151.55474452554742
        ],
        [
          346.10948905109484,
          143.52554744525546
        ],
        [
          423.4817518248175,
          156.66423357664232
        ],
        [
          404.5036496350365,
          209.21897810218977
        ],
        [
          395.0145985401459,
          282.2116788321168
        ]
      ],
      "group_id": null,
      "shape_type": "polygon",
      "flags": {}
    }
  ],
  "imagePath": "waste_val (84).png",
  "imageData": "iVBORw0KGgoAAAANSU...AAAAHgCAIAAAC6s0uzAAEA",
  "imageHeight": 480,
  "imageWidth": 640
}

```

✓ Ensemble des images annotées à main = **1500 images**

Les attributs du fichier JSON :

- Lable : la classe d'objet (Waste)
- Points : les coordonner du masque
- Shape type : Polygone pour toutes les images du dataset
- Image_Path
- La taille d'image

3.3. Prétraitement des données

Le prétraitement des données est un processus qui prépare les données brutes et les rend adaptées à un modèle d'apprentissage automatique. Il s'agit de la première étape indispensable à la mise au point d'un modèle d'apprentissage automatique.

Les données du dataset ne sont pas homogènes et nécessitent certains traitements, pour augmenter l'efficacité de nos modèles d'apprentissage automatique.

Pour le Modèle UNet :

✓ Conversion des masques en binaire

Nous avons opté pour un encodage sur 2 bits pour les masque, $G(i)$ tout en translatant les intensités à l'intervalle $[lmin, lmax]$ inclus dans $[0, 1]$ en appliquant la formule :

```
Si mask[i<38] =0
Si mask[i==38] =1
```

✓ Redimensionner :

Avant de pouvoir alimenter notre modèle DL, nous devons nous assurer que les images et les mask ont toutes la même taille. Par conséquent, une taille standard de 128×128 est recommander

Nous définissons la tâche de segmentation comme un problème de classification dans lequel le réseau doit apprendre à classer les pixels dans l'une des deux classes $[0,1]$

(0 pour BG et 1 pour le déchet)

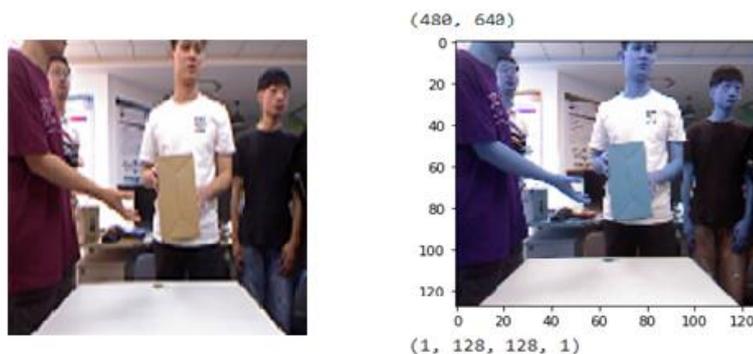


Figure 3.5. Redimensionnement d'une image 128×128

Pour Mask RCNN :

- ✓ Conversion des polygones en Mask, Cette tâche consiste à accéder au fichier Json, puis à l'attribut « Shape_type » pour le transformer à un Mask, et générer une liste qui représente le Mask.

4. Les Modèles DL proposées pour la segmentation :

Afin de répondre au souci de la segmentation des déchets, nous proposons deux modèles DL, le premier fondé sur la segmentation sémantique et le deuxième basé sur une segmentation d'instance respectivement, sur notre ensemble de données, UNET et le MASK RCNN.

4.1.1. Modèle UNet proposé :

L'architecture du modèle utilisé est illustrée à la figure suivante. Elle consiste en un chemin de contraction (côté gauche) et un chemin d'expansion (côté droit). Nous pouvons récapituler le mécanisme de fonctionnement de notre méthode proposé suivant le processus ci-dessous :

- La première section (encodeur) est utilisée pour récupérer le contexte d'une image. Ce bloc constitue d'une combinaison de couches de convolution et de max pooling permettant de collecter les caractéristiques d'une image et de diminuer le nombre de paramètres du réseau. Cela consiste de deux couches de convolution 3x3 répétitives. Chaque couche est suivie d'une fonction d'activation ReLU et d'une couche dropout (0.2) qui aide à prévenir le surajustement (overfitting). Ensuite, une couche de max pooling 2x2 est appliquée pour réduire les dimensions spatiales.
- Le goulot d'étranglement relie l'encodeur et le réseau de décodeurs et complète le flux d'informations. Il se compose de deux couches de convolutions 3x3, où chaque couche est suivie d'une fonction d'activation ReLU et une couche dropout (0.2).
- Le deuxième bloc (décodeur) permet la localisation précise grâce à la convolution transposée et permet également de retrouver la taille initiale de l'image. Le décodeur commence par un sur-échantillonnage (upsampling) de la carte des caractéristiques (feature map) suivie d'une couche de convolution 2x2 transposée. Après, deux couches de convolutions 3x3 sont utilisées, où chaque convolution est suivie d'une fonction d'activation ReLU et dropout (0.2). La sortie du dernier décodeur passe par une couche de convolution 1x1 avec une fonction d'activation softmax.

L'architecture du modèle unit utiliser selon nos besoin est illustré dans la figure suivantes :

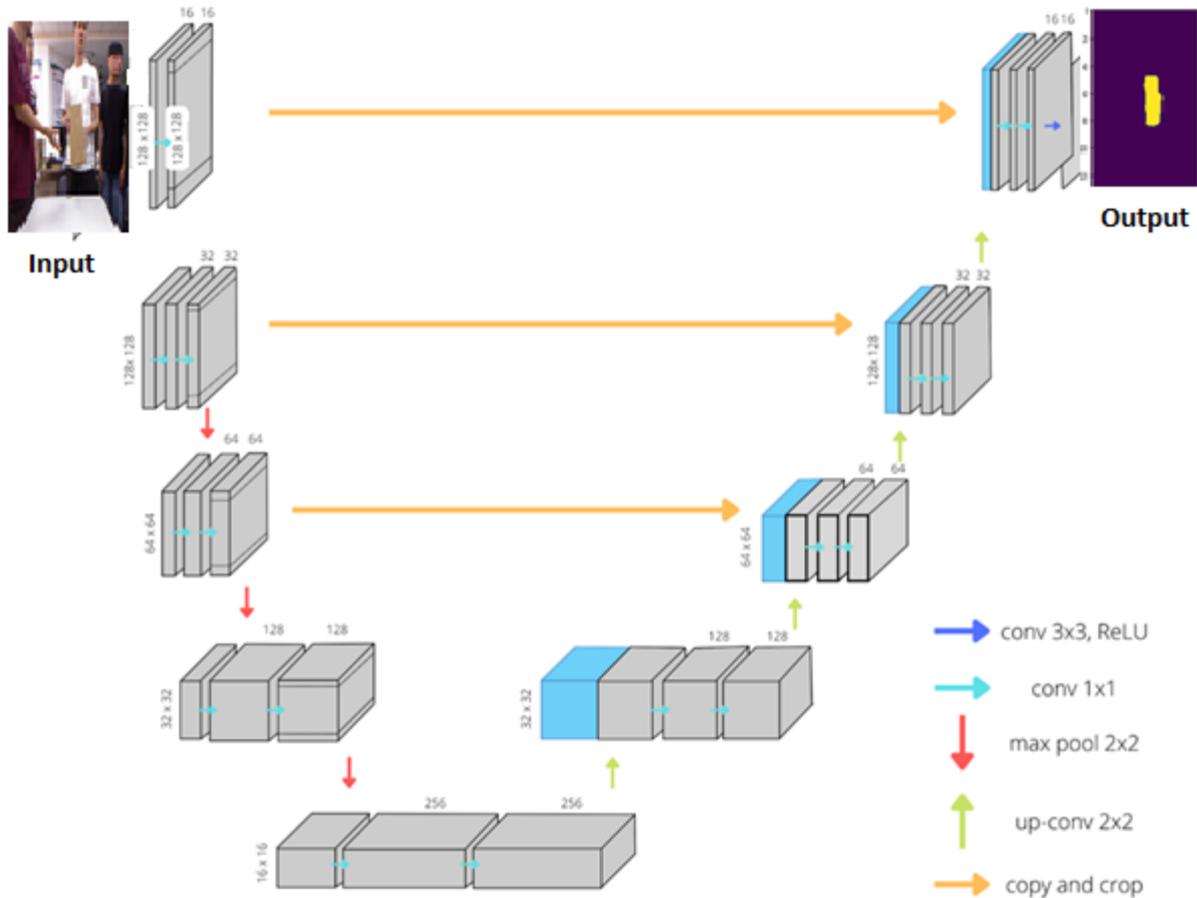


Figure 3.6. Architecture Unet proposé

4.1.2. Modèle Mask RCNN proposé :

Rappelons le principe du Faster R-CNN, vu en chapitre 2, qui propose en sortie deux classes pour chaque objet candidat, une classe label et une autre pour les bounding boxes. En effet, le Mask R-CNN ajoute une troisième branche au Faster R-CNN et propose en sortie le masque de l'objet d'intérêt. Ce modèle fait la localisation de l'objet, la segmentation de l'objet sur les images. Le but est de classer les objets individuellement et localiser chacun avec des bounding boxes et de la segmentation dans le but de classer chaque pixel en un ensemble fixe de catégories.

Nous pouvons récapituler le mécanisme de fonctionnement de notre méthode proposé suivant les deux étapes ci-dessous. :

- La toute première étape se compose de deux réseaux de base qui utilisent le Resnet 101 et le RPN. Ces réseaux effectuent une tâche par image afin de proposer un ensemble de

régions, les propositions étant des régions de la carte des entités qui comprennent l'objet(déchets).

- Au cours de la deuxième étape, le réseau prévoit le box et la classe d'objet de chacune des régions proposées par le Resnet 101 et le RPN lors de la première étape. Toutes les régions proposées peuvent être représentées par une taille différente, tandis que les couches entièrement connectées dans les réseaux exigent toujours un vecteur de taille fixe pour effectuer la prédiction. C'est pour cela que la taille des régions proposées elle sera fixée à travers les pools de ROI.

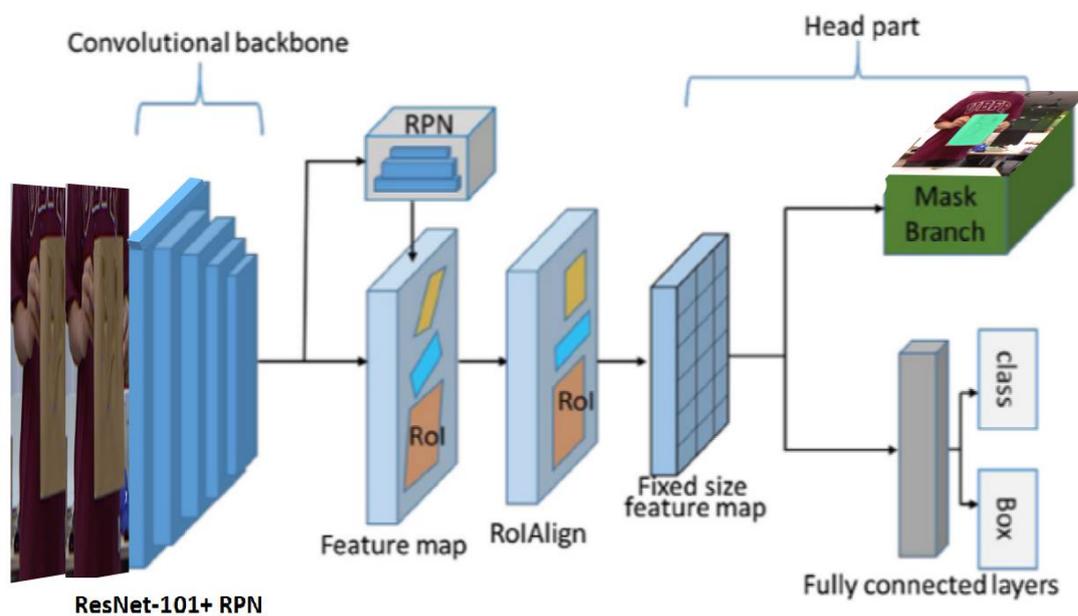


Figure 3.7 Architecture du Mask R-CNN proposé

L'architecture de notre modèle Mask RCNN est présentée dans la figure suivante :

5. Métrique d'évaluation :

Dans le but d'évaluer nos modèles, nous avons utilisé un certain nombre de métriques :

jaccard Similarity (IoU) : Intersection over Union) : La métrique la plus utilisée, elle calcule le taux d'intersection entre la prédiction et l'observation parmi leur union. Elle est donnée par la formule suivantes :

$$IoU = IOU = \frac{TP}{TN+TP+FN} \dots\dots\dots(1)$$

Accuracy : Indique le nombre de pixels correctement prédits par le modèle par classes, elle est donnée par la formule :

$$Accuracy = \frac{TP}{TP+FN} \dots\dots\dots(2)$$

Précision : La précision (P) est définie comme le nombre de vrais positifs (TP) sur le nombre de vrais positifs plus le nombre de faux positifs (FP)

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(3)$$

Recall : Le rappel (R) est défini comme le nombre de vrais positifs (TP) sur le nombre de vrais positifs plus le nombre de faux négatifs (FN).

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(4)$$

6. Implémentation et Expérimentation :

Dans cette partie, nous définirons d'abord l'environnement de travail, les langages de programmation, les bibliothèques et le framework utilisés. Ensuite, nous présenterons les résultats des différentes étapes du système en analysant les performances des modèles utilisés, afin de conclure par une comparaison par rapport à l'état de l'art.

6.1. Environnement et outils de travail :

6.1.1. Google Colaboratory

L'entraînement d'un modèle d'apprentissage profond peut nécessiter une charge de travail importante au niveau du CPU/GPU, c'est pourquoi nous avons utilisé la plateforme en cloud de Google Colab. Colaboratory est un projet de recherche de Google créé pour aider à généraliser l'enseignement et la recherche en apprentissage automatique. Il s'agit d'un environnement Jupyter notebook qui ne nécessite aucune configuration pour être utilisé et qui fonctionne entièrement sur le cloud.[59]



6.1.2. Langage de programmation Python

Python est un langage de programmation puissant et facile à apprendre. Il dispose de structures de données de haut niveau et permet une approche simple mais efficace de la programmation orientée objet. Parce que sa syntaxe est élégante, que son typage est dynamique et qu'il est interprété, Python est un langage idéal pour l'écriture de scripts et le développement rapide d'applications dans de nombreux domaines et sur la plupart des plateformes.[58]



Alors, les bibliothèques Python les plus utilisées dans notre approche sont :

6.1.3. Tensorflow

TensorFlow s'agit d'une bibliothèque Open Source de calcul numérique et de Machine Learning. Elle simplifie le processus d'acquisition de données, d'entraînement des modèles de Machine Learning, de génération de prédictions et de raffinement des résultats futurs.



TensorFlow regroupe des modèles et des algorithmes de Machine Learning et de Deep Learning. Le langage Python offre une API front-end pratique et confortable pour créer des applications à l'aide de ce framework. Il est possible de se servir de ce framework pour entraîner et exécuter des réseaux de neurones profonds pour la classification de chiffres manuscrits, pour la reconnaissance d'image, pour le plongement lexical, pour les réseaux de neurones récurrents

6.1.4. Scikit-learn

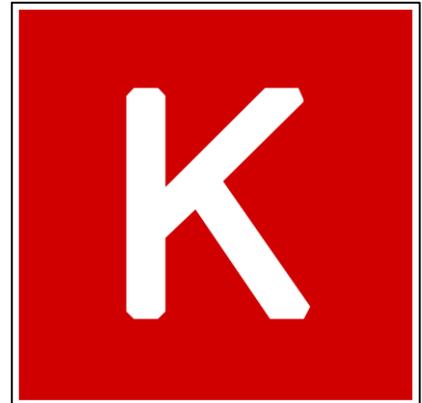
Scikit-learn est une bibliothèque libre Python destinée à l'apprentissage automatique. Elle est développée par de nombreux contributeurs notamment dans le monde académique par des instituts français d'enseignement supérieur et de recherche comme Inria. Elle propose dans son framework de nombreuses bibliothèques d'algorithmes à implémenter, clé en main. Ces bibliothèques sont à disposition notamment 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.

6.1.5. Keras

Keras est une API de réseaux de neurones de haut niveau, écrite en Python et capable de fonctionner sur TensorFlow ou Theano. Il a été développé en mettant l'accent sur l'expérimentation rapide. Être capable d'aller de l'idée à un résultat avec le moins de délai possible est la clé pour faire de bonnes recherches. Il a été développé dans le cadre de l'effort de recherche du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System), et son



principal auteur et mainteneur est François Chollet, un ingénieur Google. En 2017, l'équipe TensorFlow de Google a décidé de soutenir Keras dans la bibliothèque principale de TensorFlow. Chollet a expliqué que Keras a été conçue comme une interface plutôt que comme un cadre d'apprentissage end to end. Il présente un ensemble d'abstractions de niveau supérieur et plus intuitif qui facilitent la configuration des réseaux neuronaux indépendamment de la bibliothèque informatique de backend. Microsoft travaille également à ajouter un backend CNTK à Keras aussi.

6.1.6. NumPy

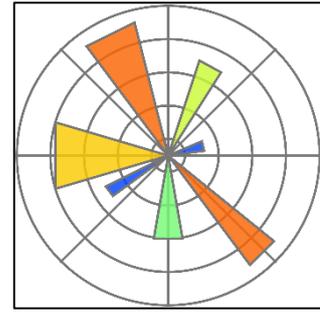
NumPy est le paquetage fondamental pour le calcul scientifique en Python. Il s'agit d'une bibliothèque Python qui fournit un objet tableau multidimensionnel, divers objets dérivés (tels que les tableaux masqués et les matrices), ainsi qu'un assortiment de routines permettant d'effectuer des opérations rapides sur les tableaux, notamment des opérations mathématiques, logiques, de manipulation de formes, de tri, de sélection, d'E/S, de transformées de Fourier discrètes, d'algèbre



linéaire de base, d'opérations statistiques de base, de simulation aléatoire et bien plus encore.

6.1.7. Matplotlib

Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy. Matplotlib est distribuée librement et gratuitement sous une licence de style BSD.



6.2. Etapes d'implémentation des modèles DL :

Dans cette partie nous avons présenté les tâches nécessaires pour l'implémentation de nos modèles.

6.2.1. Accès à Google drive à partir du Google colab

Il y a deux méthodes pour se connecter à Google drive à partir de Google colab, une méthode manuelle ou via un code Python. Pour la méthode manuelle, il s'agit d'appuyer sur l'icône qui représente un répertoire avec le symbole Google Drive comme le montre la [figure](#), située dans la barre des fichiers à gauche de la fenêtre de colab.

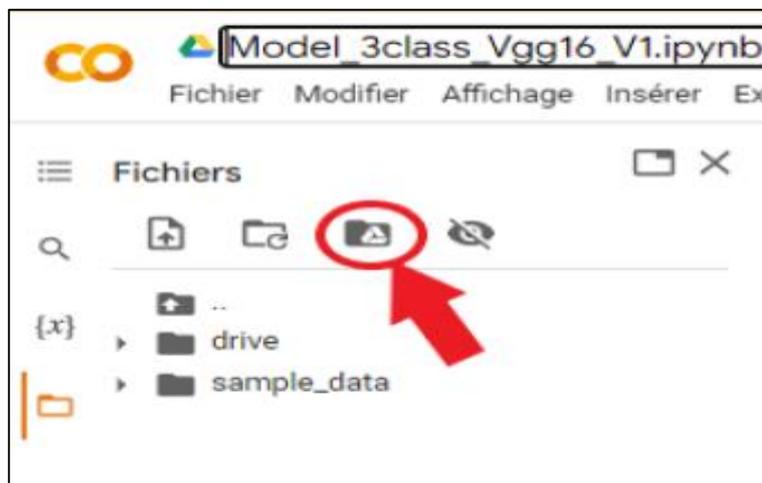


Figure 3.8. Image d'une fenêtre colab montrant

La deuxième méthode consiste à exécuter les deux instructions Python suivantes :

```
from google.colab import drive
drive.mount('/content/drive')
```

6.2.2. Chargement des données :

Nous avons, dans cette étape effectué un chargement des données, en les transférant dans le Colab. Voici le code permettant de réaliser cette opération.

➤ **Unet :**

```

path_images = "/content/drive/MyDrive/waste_unet/Data/Dataset_unet/JPEG
Images"
path_masks = "/content/drive/MyDrive/waste_unet/Data/Dataset_unet/Seg
mentationClass"
images = [] #Vecteur pour les images
masks = [] #Vecteur pour les Mask
names = [f for f in listdir(path_masks) if isfile(join(path_images, f
))]
for file in tqdm(names):
    img = cv2.imread(join(path_images, file), 0)
    img = cv2.resize(img, (128,128)) #resize Image
    images.append(img)
    msk = cv2.imread(join(path_masks, file), 0)
    msk = cv2.resize(msk, (128,128)) #resize Mask

    msk[msk<38]=0 #Binarization mask
    msk[msk==38]=1
    masks.append(msk)
return np.array(images), np.array(masks)

```

➤ **Mask RCNN :**

```

dataset_dir = os.path.join(dataset_dir, subset)
# Train or validation dataset
filenames = os.listdir(dataset_dir)
jsonfiles, annotations=[], []
for filename in filenames:
    if filename.endswith(".json"):
        jsonfiles.append(filename)
        annotation =
json.load(open(os.path.join(dataset_dir, filename)))
        #Confirmer c'est la photo existe dans la dataset
        imagename = annotation['imagePath']
        if not
os.path.isfile(os.path.join(dataset_dir, imagename)):
            continue
        if len(annotation["shapes"]) == 0:
            continue
        #Filtrage
        annotations.append(annotation)

print("In {source} {subset} dataset we have {number:d} annotation
files."
      .format(source=source,
subset=subset, number=len(jsonfiles)))

####Afficher le nombre d'images et les annotations valid####
print("In {source} {subset} dataset we have {number:d} valid annotations."
      .format(source=source, subset=subset, number=len(annotations)))

```

6.2.3. Division de données

nous avons divisé la dataset, 90% et 10% pour l'entraînement et la validation respectivement pour le modèle Unet, et concernant la masque RCNN 70% à l'entraînement et 30% à la validation :

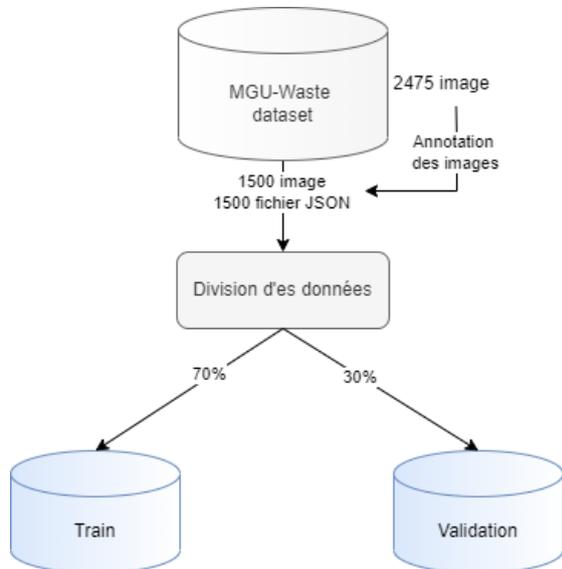


Figure 3.9 Division de données pour Mask RCNN

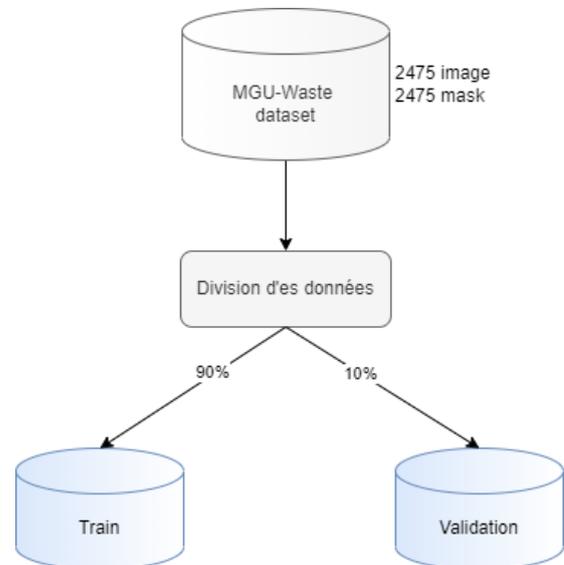


Figure 3.10 Division de données pour Unet

6.2.4. Phase d'apprentissage des modèles :

Nous utilisons la fonction fit et train pour entraîner Unet et Mask RCNN respectivement :

➤ **Unet :**

```
model.fit(X_train, y_train_cat, batch_size = 16, verbose=1, epochs=40,
validation_data=(X_test, y_test_cat), shuffle=False)
```

➤ **Mask RCNN :**

```
model.train(dataset_train, dataset_val, learning_rate=0.001, epochs=50,
layers='all')
```

7. Expérimentation des résultats

7.1. La performance du modèle de segmentation UNet:

Pour la représentation des performances de nos Modèle Unet au fil du temps pendant l'entraînement, et la validation nous avons générer les graphes suivants :

- Un graphe de "accuracy" de l'entraînement et "accuracy" de validation
- Un graphe de "Loss" de l'entraînement et "Loss" de validation

➤ Un graphe de "IOU" de l'entraînement et "IOU" de validation

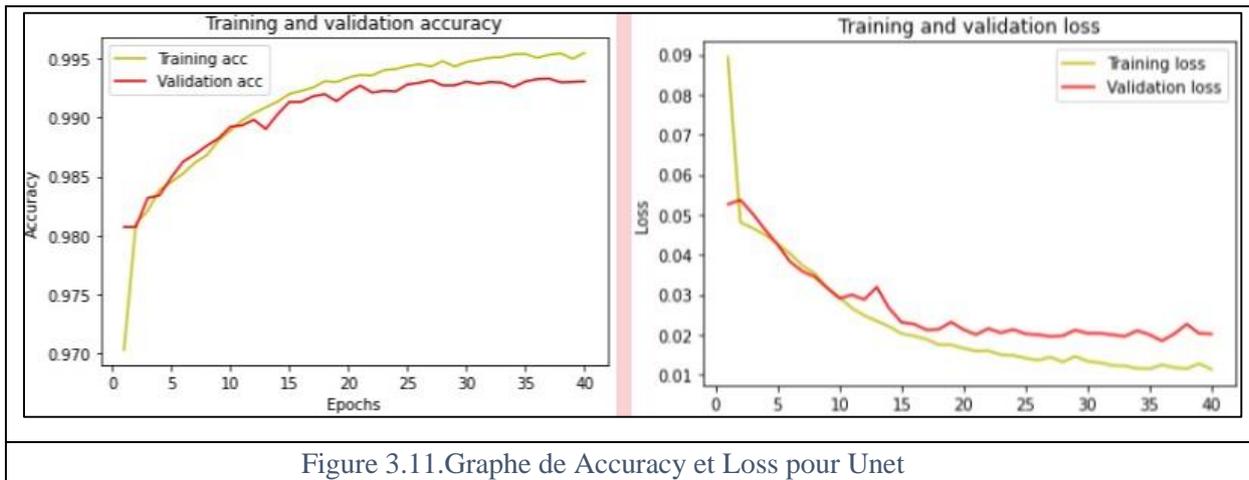


Figure 3.11.Graphe de Accuracy et Loss pour Unet

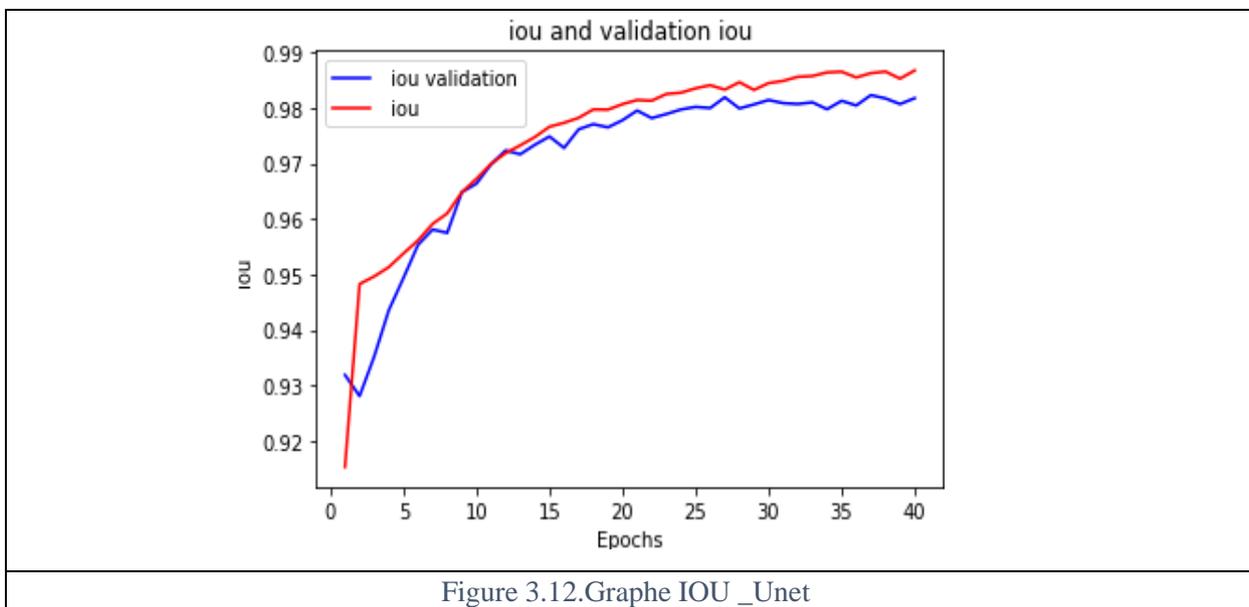


Figure 3.12.Graphe IOU _Unet

Afin d'entraîner notre modèle Unet avec différents paramètres, le tableau 3.2 suivant représente les meilleurs résultats obtenus :

Tableau 3.2 Résultats de Unet

Accuracy	99,5 %
Loss	0,02
IOU	98%

7.2. La performance du modèle de segmentation Mask RCNN :

Les graphes suivants représentent, « Loss » d'entraînement et validation, et « Mask loss » :

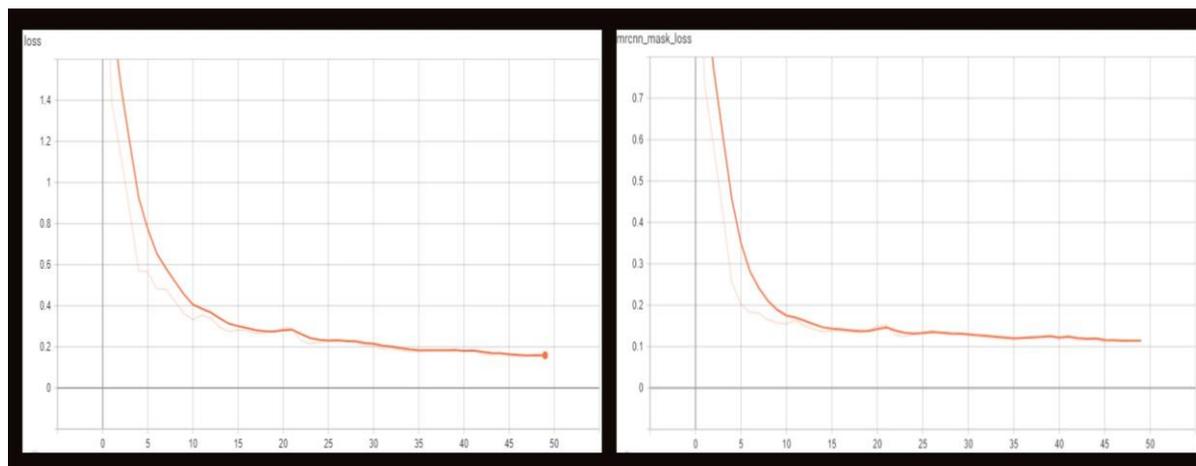


Figure 3.13 Les graphes de " Loss " d'entraînement et validation et "Mask loss"

Afin d'entraîner notre modèle Mask RCNN avec différents paramètres, le tableau suivant représente les meilleurs résultats obtenus :

Tableau 3.3 Résultats de Mask RCNN

Métrique	IOU	LOSS	AP
Modèle			
Mask Rcn	91%	0,1	90%

7.3. Comparaison entre nos modèles et les modèles cités dans l'état de l'art :

Le tableau 3.4 ci-dessous est une comparaison des résultats du modèle UNet avec les travaux mentionnés dans l'état de l'art plus précisément les travaux basés sur la segmentation sémantique des déchets, où nous pouvons voir que notre modèle surpasse la plupart des travaux récemment publiés pour la segmentation des déchets.

Tableau 3.4. Comparaison de modèle Unet avec les travaux basés sur segmentation sémantique

Model	Article	Dataset	Class	IOU(%)
DeepLabV3+ ML	[55]	MJU-Waste	1	89%
DeepLabV3+	[57]	Dataset privé	7	57%
SegNet	[56]	RdOCdataset (privé)	2	87%
Notre Model_UNet		MJU-Waste	1	98,23

Nous avons comparé les approches basées sur la segmentation d'instance et la détection des déchets dans l'état de l'art, avec notre modèle Mask RCNN qui est fondé sur la segmentation des instances :

Tableau 3.5. Comparaison de modèle Mask RCNN avec les travaux basé sur la détection

Model	Article	Dataset	Class	AP(%)
DeepLabV3+ ML	[55]	MJU-Waste	1	85%
Mask RCNN	[53]	TACO	8	70%
Faster-RCNN	[54]	Garbage dataset	2	80%
Notre Model_Mask RCNN		MJU-Waste	1	90%

7.4. Prédiction et test

7.4.1. Prédiction avec Unet :

Afin d'évaluer notre modèles, une prédiction sur les images est nécessaire pour visualiser les résultats des métrique obtenus.

Nous chargeons donc les images et les redimensionnons à la taille utilisée lors de la phase d'entrainement Ensuite, nous avons chargé le modèle et lancé la prédiction du mask en appelant la fonction "Predict"

Les figures 3.14 3.15 ci-dessous montrent des illustrations des mask prédictees.

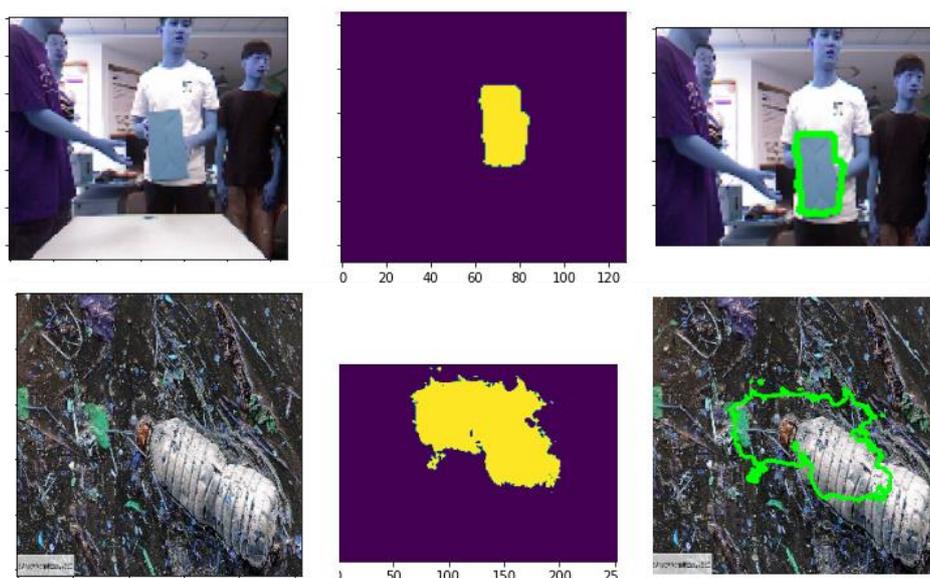


Figure 3.14 Contour le déchets a partir du pred mask

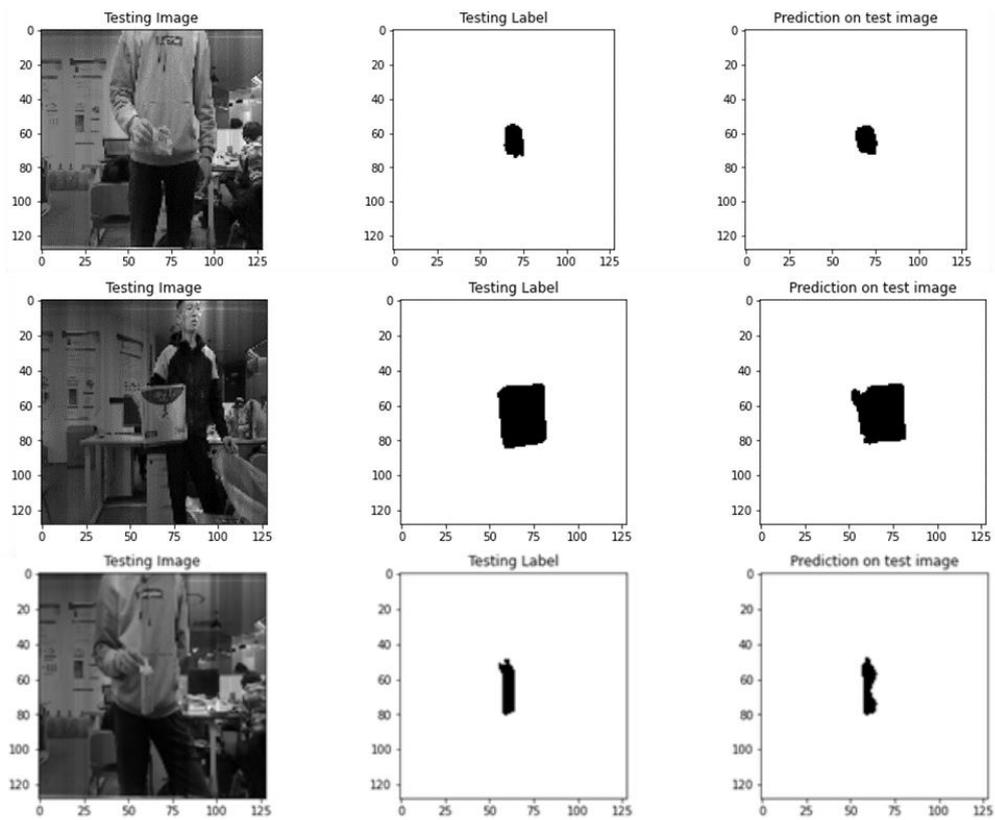


Figure 3.15 résultats des prédictions avec Unet

On a défini une méthode python qui sert à croper le mask généré par Unet pour faciliter la classification des déchets après la segmentation.

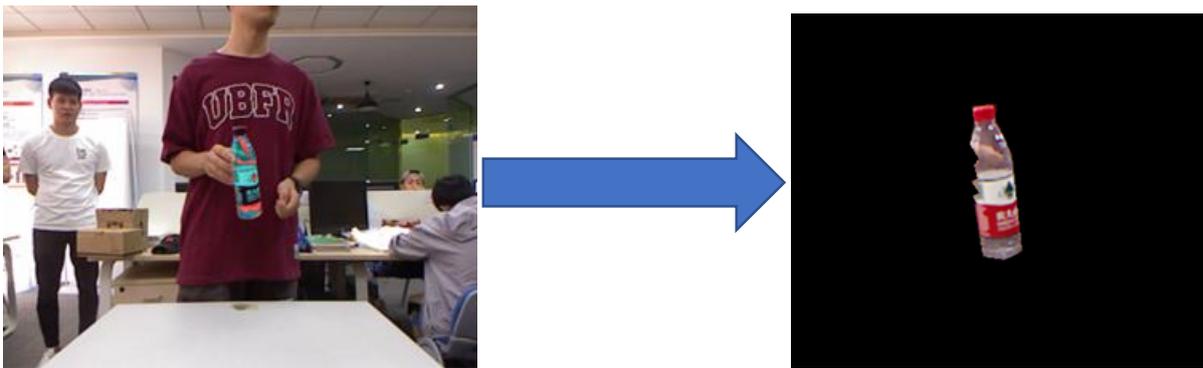


Figure 3.16 Crop Mask Unet

7.4.2. Prédiction avec Mask RCNN

Nous avons sélectionné différentes images de tailles différentes et de types divers (jpg et png) dans des environnements distincts, « Laboratoire Lamis de notre université », à l'extérieurs et même avec des déchets sous-marine, dans le but d'évaluer les compétences de notre modèle proposé dans plusieurs environnements, et quelques fois le type et la taille d'image d'entrer.

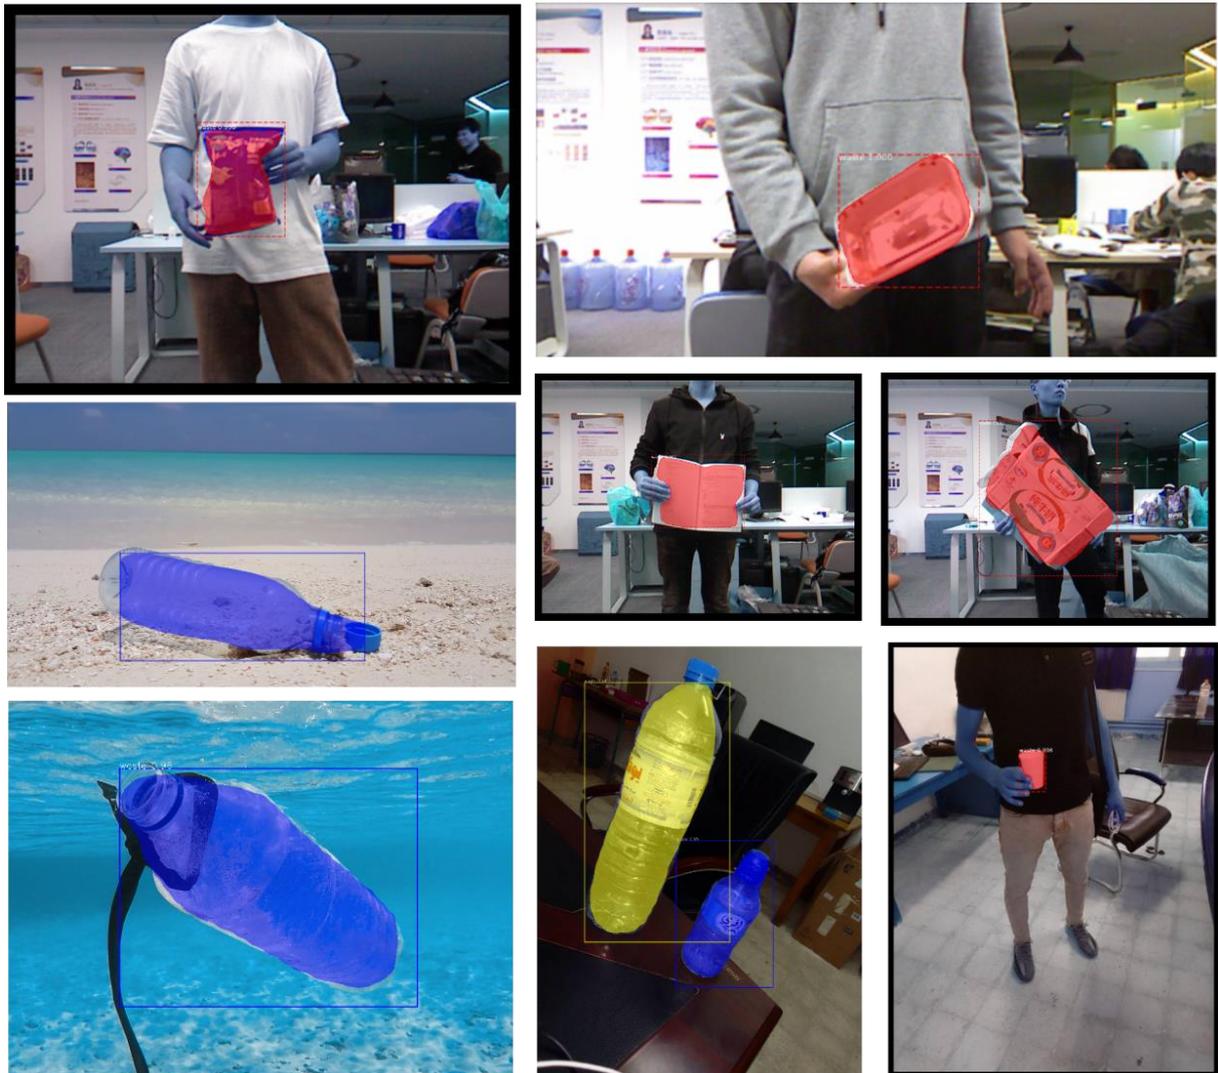


Figure 3.17 Résultats des prédictions avec Mask RCNN

8. Conclusion

Ce chapitre présente notre contribution dans le domaine du tri intelligent des déchets à l'aide de technologies d'apprentissage profond. Nous avons proposé deux algorithmes basés sur l'apprentissage profond afin d'améliorer la précision du processus de tri des déchets. Comme résultat de notre algorithme utilisant Unet avec 40 époques d'apprentissage et Mask RCNN avec 50 époque d'apprentissage, nous avons pu atteindre un union intersection ($iou= 98\%$) et $AP=90$ pour Mask RCNN, ce qui est le pourcentage le plus élevé jamais connu dans ce domaine, ce qui signifie que notre formation, le test et la validation du dataset est excellent.

Conclusion

générale

Conclusion générale

Afin de réduire l'impact environnemental de l'élimination inappropriée des déchets, en particulier les déchets ménagers (c'est-à-dire le papier, le plastique, le verre et les déchets organiques), nous proposons un système automatisé basé sur l'apprentissage profond et les méthodologies classiques qui vise à segmenter correctement et séparer les déchets en catégories de recyclage. Le verre, le métal, le papier et le plastique. Les résultats suggèrent que l'approche UNET est une stratégie efficace pour ce problème, avec le meilleur scénario atteignant 98% d'union d'intersection en utilisant 40 époques et une précision moyenne qui dépasse 90% avec le Masque RCNN.

Ce pourcentage est supérieur à tous les précédents dans le même domaine de recherche, ce qui signifie que nous avons pu atteindre notre objectif souligné d'obtenir une précision de reconnaissance des ordures en utilisant le jeu de données "Mju-Waste" de Wang [55].

Cependant, les approches CNN sont plus coûteuses en termes de calcul que les techniques plus anciennes et nécessitent des ordinateurs plus puissants. En outre, diverses stratégies telles que l'augmentation et le réglage fin peuvent améliorer la précision des systèmes CNN, ce qui sera examiné dans des recherches futures. En outre, lorsqu'il y a plus de données, le CNN a tendance à produire de meilleurs résultats.

Perspective :

Dans les recherches futures, nous travaillerons à développer notre modèle CNN pour :

- Intégrer la segmentation en temps réel dans nos modèles, l'avantage de cette tâche est de pouvoir servir dans le domaine robotique ainsi que de pouvoir l'intégrer dans le processus de tri des déchets et d'automatiser cette tâche pour qu'elle soit plus rapide.
- Suite aux résultats obtenus pour la segmentation des déchets, nous souhaitons améliorer notre segmentation et travailler sur plusieurs types de déchets avec plusieurs classes.
- Nous allons travailler sur une autre tâche de vision par ordinateur plus précisément la détection pour la comparer avec le résultat de la segmentation, et déterminer qui est le plus performant pour le tri des déchets.

Bibliographie

- [1] D. Hoornweg and P. Bhada-Tata, What a Waste: A Global Review of Solid Waste Management, World Bank, Washington, DC, USA, 2012
- [2] <https://sisu.ut.ee/waste/book/11-definition-and-classification-waste>
- [3] <http://www.basel.int/theconvention/overview/textoftheconvention/tabid/1275/default.asp>
- [4] "division des statistiques des nations unies - statistiques de l'environnement". unstats.un.org. consulté le 23 mai 2022.
- [5] "editorial board/aims & scope". waste management. 34 (3) : ifc. mars 2014.doi:10.1016/s0956-053x(14)00026-9.
- [6] davidson, gary (juin 2011). " waste management practices : literature review "(pdf). dalhousie university - office of sustainability. récupéré le 23 mai 2022.
- [7] " solid waste management ". banque mondiale. consulté le 20 mars 2022.
- [8] "health crisis : up to a billion tons of waste potentially burned in the open every year". phys.org. récupéré le 20 mars 2022.
- [9] lignes directrices pour les stratégies nationales de gestion des déchets : passer des défis aux opportunités . programme des nations unies pour l'environnement. 2013. isbn 978-92-807-3333-4.
- [10] florence nightingale, selected writings of florence nightingale, ed. lucy ridgely seymer (new york : the macmillan co., 1954), pp. 38287.
- [11] "siemens" (pdf). www.siemens.com
- [12] kaufman, scott m. ; krishnan, nikhil ; themelis, nickolas j. (1 août 2010). "a screening life cycle metric to benchmark the environmental sustainability of waste management systems". environmental science & technology. 44 (15) : 5949_5955.
- [13] LIVRE .
- [14] "Pourquoi devrais-je trier mes déchets correctement ? | ems". www.em-solutions.co.uk. consulté le 20septembre 2022.
- [15] <https://www.construc-teurdemaison.net/conseils/habitat/maitriser-le-tri-selectif-des-dechets-1326/>.
- [16] montgomery county, maryland. division of solid waste services. "curbside collection".
- [17] " <https://sitetom.syctom-paris.fr/le-parcours-des-dechets/tom-traite/le-centre-de-tri.html>.
- [18] czajczyńska, d. ; anguilano, l. ; ghazal, h. ; krzyżyńska, r. ; reynolds, a.j. ; spencer, n. ; jouhara, h. (septembre 2017). " Potentiel des procédés de pyrolyse dans le secteur de la gestion des déchets ". thermal science and engineering progress. 3: 171–197.doi:10.1016/j.tsep.2017.06.003.
- [19] <https://www.epa.gov/transforming-waste-tool/zero-waste-case-study-san-francisco>.
- [20]<https://www.cnn.com/2018/07/13/how-san-francisco-became-a-global-leader-in-waste-management.html>
- [21] <https://www.epa.gov/transforming-waste-tool/zero-waste-case-study-san-francisco>
- [22]<https://www.mondial-infos.fr/limportance-du-recyclage-et-de-la-reutilisation-des-plastiques>
- [23] J.-C. Noël and Institut français des relations internationales, Intelligence artificielle : vers une nouvelle révolution militaire?, vol. 82. 2018. Accessed: May 18, 2022. [Online]. Available:<https://www.ifri.org/fr/publications/etudes-de-lifri/focus-strategique/intelligence-artificielle-vers-une-nouvelle>

[24] Qu'est-ce que le machine learning ? <https://www.oracle.com/dz/artificial-intelligence/what-is-machine-learning.html>. Consulté le : 2022-03-18.

[25] MACHINE LEARNING. <https://dataanalyticspost.com/Lexique/machine-learning>. Accédé le : 2022-03-18.

[26] Machine Learning vs Deep Learning - Wo liegt der Unterschied ? <https://data-science-blog.com/blog/2018/05/14/machine-learning-vs-deep-learning-wo-liegt->

[27] DEEP LEARNING. <https://dataanalyticspost.com/Lexique/deep-learning/>. Accédé le : 2022-03-18.

[28] Lening Li, Xuqing Jia, Wende Tian, Suli Sun et Wu Cao. Identification de fuites chimiques basée sur un réseau neuronal à convolution. In *Computer Aided Chemical Engineering*, volume 44, pages 2329-2334. Elsevier, 2018.

[29] A. Pai et al., "Characterisation of errors in deep learning-based brain MRI segmentation," 2016. Accessed: May 18, 2022. [Online]. Available: https://christian-igel.github.io/paper/CoEIDL-bBMRIS.pdf?fbclid=IwAR02_n39oe4jxNaPS5VKyxbrKS3uFSQV8EeDC2xXX_HJ2oXTNsYeDvv3o4Y.

[30] Convolutional Neural Networks (CNNs). <https://anhreynolds.com/blogs/cnn.html>. Accédé le : 2022-03-18.

[31] What is Perceptron : A Beginners Tutorial for Perceptron. <https://www.simplilearn.com/what-is-perceptron-tutorial>. Accédé le : 2022-04-10.

[32] Nadeem Akhtar and U Ragavendran. Interpretation of intelligence in cnn-pooling processes : A methodological survey. *Neural Computing and Applications*, pages 1–20, 2022.

[33] Softmax Activation Function Explained. <https://towardsdatascience.com/softmax-activation-function-explained-a7e1bc3ad60>. Accédé le : 2022-04-10

[34] Introduction to Convolutional Neural Networks. <https://towardsdatascience.com/convolutional-neural-network-17fb77e76c05>. Accédé le : 2022-04-10.

[35] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pages 1097–1105, 2012.

[36] Step by step VGG16 implementation in Keras for beginners. <https://towardsdatascience.com/step-by-step-vgg16-implementation-in-keras-for-beginners-a833c686ae6c>. Accédé le : 2022-04-10.

[37] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778, 2016.

[38] Ross Girshick, Jeff Donahue, Trevor Darrell, et Jitendra Malik. Réseaux convolutifs basés sur les régions pour une détection et une segmentation précises des objets. *IEEE transactions on pattern analysis and machine intelligence*, 38(1) :142-158, 2015.

[39] R-CNN, Fast R-CNN, Faster R-CNN, YOLO - Object Detection Algorithms.

<https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>. Consulté le : 2022-04-10.

[40] Deep Learning for Object Detection : A Comprehensive Review. <https://towardsdatascience.com/deep-learning-for-object-detection-a-comprehensive-review-73930816d8d9>. Accédé le : 2022-06-15.

- [41] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. You only look once : Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 779–788, 2016.
- [42] Olaf Ronneberger, Philipp Fischer et Thomas Brox. U-net : Convolutional net- works for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention, pages 234-241. Springer, 2015.
- [43] Achraf KHAZRI. 2019. Faster RCNN Object detection towards data science. [En ligne] 09/ 04/ 2022. <https://www.towardsdatascience.com/faster-rcnn-object-detection-f865e5ed7fc4>.
- [44] ODEMAKINDE, Elisha. 2021. Mask R-CNN : A beginner's guide [En ligne] 19/ 05/ 2022. <https://www.viso.ai/deep-learning/mask-r-cnn/>.
- [45] al, Ren et. Papers with code. [En ligne] <https://www.paperswithcode.com/method/rpn>.
- [46] Zhang & Zakhor, Richard & Avideh (2014). "Automatic Identification of Window Regions on Indoor Point Clouds Using LiDAR and Cameras". *VIP Lab Publications*. [CiteSeerX 10.1.1.649.303](https://doi.org/10.1.1.649.303)
- [47] Mohamed, Aly (2005). "Survey on multiclass classification methods" (PDF). *Technical Report, Caltech*.
- [48] <https://deepomatic.com/fr/difference-entre-la-computer-vision-la-reconnaissance-dimages>
- [49] Bishop, C. M. (2006), *Pattern Recognition and Machine Learning*, Springer, ISBN 978-0-387-31073-2
- [50] Yang, M.; Thung, G. Classification of Trash for Recyclability Status; CS229 Project Report; Stanford University: Stanford, CA, USA, 2016.
- [51] Toğaçar, M., Ergen, B., Cömert, Z., 2020. Waste classification using autoencoder network with integrated feature selection method in convolutional neural network models.
- [52] Wang, Y.; Zhang, X. Autonomous garbage detection for intelligent urban management. MATEC Web Conf. **2018**, 232, 01056. [CrossRef] Consulté 27/05/2022
- [53] Proença, Pedro F, Simões, Pedro, 2020. TACO: Trash Annotations in Context for Litter Detection. arXiv Preprint arXiv:2003.06975 Consulté 27/05/2022
- [54] Sylwia Majchrowska a, Agnieszka Mikołajczyk , Maria Ferlin , Zuzanna Klawikowska Marta Plantykw , Arkadiusz Kwasigroch , Karol Majek ,2022 . Deep learning-based waste detection in natural and urban environments .journal homepage: www.elsevier.com/locate/wasman Consulté 27/05/2022
- [55] Tao Wang, Yuanzheng Cai, Lingyu Liang and Dongyi Ye 2020 . AMulti-Level Approach toWaste Object Segmentation in Context for semantic segmentation . Consulté 27/05/2022
- [56] Caiyun Zheng1 · Danhua Cao1 · A similarity-guided segmentation model for garbage detection under road scene. Conf. **2022**, <https://doi.org/10.1007/s12200-022-00004-9> Consulté 27/05/2022

[57] Lu, W., Chen, J., & Xue, F. (2022). Using computer vision to recognize composition of construction waste mixtures: a semantic segmentation approach. *Resources, Conservation & Recycling*, 178, 106022. Consulté 27/05/2022

[58] “Le tutoriel Python.” <https://docs.python.org/fr/3.10/tutorial/> (accessed May 13, 2022).

[59] Bienvenue dans Colaboratory -

Colaboratory https://colab.research.google.com/?utm_source=scs-index Accessed: 2022-06-03