

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd - Tlemcen -

Faculté de TECHNOLOGIE



MÉMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : génie industriel

Spécialité : chaîne logistique

Par : TERCHI Hadjer

Sujet

Contribution à la réalisation d'un support intelligent pour la classification des déchets à l'aide de deep Learning

Soutenu publiquement, le 23 /06 /2022 , devant le jury composé de :

Mme KOULOUGHLI Sihem	MCA	Université de Tlemcen	Présidente
M. HASSAM Ahmed	MCB	Université de Tlemcen	Examineur
M. BENSENOUCI Hakim	MAA	Université de Tlemcen	Examineur
Mme TRIQUI-SARI Lamia	MCA	Université de Tlemcen	Encadreur
M. BENNEROUF Mohammed	MCA	Université de Tlemcen	Co-Encadreur

Remerciement

Nous tenons tout d'abord à remercier Dieu tout-puissant.

Je tiens tout d'abord à remercier mon encadrant.

*Mme. SARI TRIQUI Lamia et mon Co-encadrant
M.BENNKROUF Mohammed pour son encouragement, son
disponibilité et ces efforts incessants afin de réaliser ce
travail.*

*Mes profonds remerciements aux membres de jury Mme
KOULOUGHLI ,M. HASSAM et M.BENSSNOUCI et pour
l'honneur qu'ils nous ont fait en acceptant d'évaluer mon
travail.*

*Il m'a été difficile d'écrire cette page par souci de n'oublier
les nombreuses personnes qu'il me faut citer pour leur aide et
leur soutien.*

*Tout ceci ne serait rien sans le soutien de ma famille. Un
énorme merci a mes parents pour son encouragement dans
toutes mes décisions.*

*Mes derniers remerciements sont pour toute la famille génie
industriel tous mes enseignants pour ses efforts.*

Dédicace

Je dédie ce travail à mon cher oncle qui nous a quittés tôt et qui attendait ce jour de ma soutenance, paix a son âme.

Je dédie ce mémoire aussi à ma mère qui fait tout pour notre bonheur, mon cher frère Mohamed, ma chère sœur Manar et mon père pour vos encouragements et votre soutien.

Je dédie ce mémoire aussi à M.BENSMINE Abderrahmane paix à son âme qui m'a encouragé pour continuer mes études.

Table des matières

<i>Chapitre I : Notions fondamentale de la chaine logistique directe/inverse</i>	4
1. Introduction.....	5
1.1 La logistique	5
1.3 La chaîne logistique.....	5
1.4 Les maillons de la chaine logistique	6
1.4.1 L’approvisionnement	6
1.4.2 La fabrication/production	6
1.4.3 Stockage	6
1.4.4 Distribution	6
1.4.5 La vente.....	6
1.5 Les flux dans la chaîne logistique	6
1.5.1 Le flux informationnel	7
1.5.2 Le flux physique.....	7
1.5.3 Le flux financier	7
1.6 La chaine logistique inverse	7
1.6.1 Définition.....	7
1.7 Re-manufacturing	9
1.8 Maintenance d’un produit en fin de cycle	11
1.9 Recyclage.....	11
1.10 Technique de collecte et de tri	13
Conclusion	14
<i>-Chapitre II -</i>	15
2. Introduction.....	16
2.1 Intelligence artificielle	16
2.1.1 Machine Learning.....	16
2.1.2 Deep Learning	18
2.1.3 Pourquoi le deep Learning ?	19
2.2 Le deep Learning pour le traitement des images	19
2.3 Le système de vision industriel	20

2.3.1	Définition de la vision industrielle (machine vision)	20
2.4	La segmentation par seuillage	20
2.5	La reconnaissance en utilisant une base de données.....	21
2.6	Quelque méthode d'imagerie utilisé dans l'industrie.....	21
2.6.1	La radiographie industrielle	21
2.6.2	La camera industriel.....	22
2.6.3	La tomographie industrielle	22
2.7	Etat de l'art.....	23
	Conclusion	30
	<i>Chapitre III : PROGRAMMATION ET IMPLEMENTATION DU CADRE D'ETUDE.....</i>	<i>31</i>
3.	Introduction.....	32
3.1	Positionnement du problème	32
3.2	Deep Learning	32
3.3	Réseau de neurones.....	32
3.4	Fonctionnement du réseau de neurones (backpropagation algorithm)	33
3.5	Les types d'architectures des réseaux de neurones	40
3.5.1	Le perceptron multicouches	40
3.5.2	Le réseau de neurones récurrent (RNN)	41
3.5.3	Le réseau de neurone convolutifs (CNN)	42
3.6	Pourquoi choisir CNN ?	43
3.7	L'architecture d'un réseau de convolution	44
3.7.1	Les couches d'un réseau convolution	44
3.8	Les architecture classique du CNN.....	46
3.8.1	LeNet	46
3.8.2	Alex-Net.....	47
3.8.3	GoogleNet	48
3.8.4	Res-Net.....	49
3.9	Organigramme de l'algorithme.....	50
3.10	Les outils utilisés pour la programmation.....	52
3.11	Les logiciels.....	52

Python	52
Google colab.....	52
3.12 Les bibliothèques	53
3.13 Visualisation des résultats.....	54
3.13.1Préparer l'environnement.....	54
3.13.2Installer les bibliothèques	55
3.13.3Importer les données	56
3.13.4Diviser la base de données.....	57
3.13.5Prétraitement de réseaux de neurones	58
3.13.6L'augmentation de base de données.....	58
3.13.7Le Transfert Learning	58
3.13.8L'entraînement de réseaux de classificateur	58
3.13.9Visualiser les résultats.....	59
CONCLUSION	61
CONCLUSION GENERAL	62
Bibliographie	63

La table des figures

Figure 1 : la chaine logistique dans l'entreprise	5
Figure 2: la chaine logistique inverse.....	8
Figure 3 : Réseau de logistique inverse	9
Figure 4:économie linéaire.....	10
Figure 5:le cycle de vie fermer	11
Figure 6:quantité de quelque déchets spéciaux et dangereux (AND)	13
Figure 7: Le procède du ML classique comparé à celui du Deep Learning.....	19
Figure 8:la segmentation par seuillage.....	21
Figure 9:la reconnaissance en utilisant une base de données.....	21
Figure 10:Caméra intelligente avec logiciel intégré d'apprentissage profond	22
Figure 11:Reconstruction 3D d'une microstructure	22
Figure 12:réseau de neurones	33
Figure 13: réseau de neurones back propagation	33
Figure 14: explication de calcul backpropagation.....	36
Figure 15:Exemple d'un réseau de type perceptron multicouche	41
Figure 16:représentation compact des RNN	42
Figure 17: réseau de neurones convolutifs	43
Figure 18:les couches d'un réseau de neurones covolutionel	44
Figure 19:l'opération de convolution	44
Figure 20:l'opération de la mise en commun	46
Figure 21: Le-Net architecture	47
Figure 22:Alex-Net architecture.....	48
Figure 23:Inception module	48
Figure 24:les blocs résiduels	49
Figure 25: les étapes pour visualiser les résultats	54
Figure 26: connecter avec GPU	54
Figure 27: version de Pytorch	55
Figure 28:les bibliothèques installées	55

Figure 29:importer les bibliothèques sous colab.....	56
Figure 30:connecter a drive.....	56
Figure 31: décompresser le fichier	56
Figure 32:fichier de données	57
Figure 33: diviser la base de données.....	57
Figure 34:l'organigramme de l'optimiseur Adam.....	59
Figure 35:prédiction de nature de déchet	60

Introduction générale

La révolution numérique et technologique actuelle procure des changements importants dans des différents secteurs particulièrement le secteur industriel qui connaît une croissance et un développement exponentiel à tous les niveaux ce processus de changement technologique a débuté avec la révolution industrielle qui a connu un basculement très fort d'une société artisanale vers une industrie commerciale et industrielle voir l'émergence d'industrie virtuelle en adoptant des nouvelles techniques. En effet à l'heure actuelle digitale, sont au cours tous les phénomènes, la vision de l'amélioration continue est déjà bien engagée, et les industriels deviennent plus concurrentiels, plus productifs et misent sur les opportunités et les performances adaptées au sein de leur entreprise pour une meilleure réactivité et un meilleur rendement.

Ce concept de progression permet de passer d'une politique tout à fait axée sur le produit à une économie client (la production ne concentre plus sur le produit, mais plutôt sur les exigences du client, c'est pour cela les entreprises tentent de faire des changements au niveau de leur chaîne logistique par l'utilisation de nouvelles stratégies, actualisation de nouveaux procédés de fabrication en appuyant sur l'écoute du client afin de rester compétitive dans un marché très concurrentiel.).

La bonne gestion de la chaîne logistique permet aux entreprises industrielles et commerciales, de se positionner dans un marché très concurrentiel et répondre de manière efficace aux différentes fluctuations.

La chaîne d'approvisionnement a été toujours une préoccupation pour les professionnels de l'industrie à cause de son emplacement stratégique dans la planification des affaires. Ça veut dire que la bonne gestion de la chaîne représente un avantage concurrentiel. Principalement pour assurer la pérennité, dont la condition essentielle est la disponibilité de ressources flexibles aux changements. En effet, les entreprises de logistique sont soumises à une concurrence mondiale en plus, ils sont généralement intégrés dans la chaîne d'approvisionnement.

La logistique se positionne également comme un support inestimable pour les initiatives publiques et privées visant l'utilisation rationnelle de ressources en quantité réduites. Particulièrement la mise en place de systèmes très complexes de recyclage des emballages et des produits finis, ainsi que le recyclage des déchets. C'est l'occupation de la logistique inverse, le développement rapide de la logistique inverse a subi de profonds changements dans les mentalités et les pratiques. (François Fulconis, 2009/4)

Dans le cadre de l'amélioration continue, une exigence est primordiale qui connaît toutes les chaînes logistiques, l'écoconception. La finalité de chaque produit est étudiée dès la conception, le challenge actuel est davantage la production de produits réutilisables afin de limiter la quantité de déchets émise ou donner une deuxième vie à un produit qui est déjà en fin de cycle, c'est dans ce contexte que l'objectif se donne, nous allons étudier un problème de gestion des déchets en adoptant des techniques élaborées tel que l'intelligence artificielle.

Introduction générale

La numérisation des procédés de traitement pour une meilleure gestion plus efficaces et rapide avec des impacts sociétaux et environnementaux.

La gestion des déchets s'est avérée extrêmement considérable à cause de son influence sur le monde économique actuel. Une meilleure gestion de déchets nécessite une technologie avancée, y compris un processus plus grand et plus flexible ce qui nécessite l'utilisation des technologies performante comme Deep Learning, car elle répond à tous les besoins dans une chaîne logistique inverse performant.

Dans ce travail, nous allons présenter trois chapitres dont lequel on va décrire en globalement la chaîne logistique et la chaîne logistique inverse en mettant en évidence l'importance de recyclage afin de réduire le taux de déchet par des techniques de triage élaboré inspirer de l'intelligence artificielle et le Deep Learning le détail de chaque chapitre est représenté par l'organigramme ci dessous. L'objectif de cette étude consiste à classifier les déchets en utilisant Deep Learning et l'approche populaire CNN.

chapitre 1

- chaîne logistique
- chaîne logistique inverse
- maintenance et re-manufacturing
- recyclage
- les techniques de collecte et tri
- positionnement du problème
- la solution proposée

chapitre 2

- l'intelligence artificielle
- Machine learning
- Deep learning
- classification des images
- système de vision industriel
- Etat de l'art du waste classification

chapitre 3

- positionnement du problème
- Deep learning
- réseau de neurones et son fonctionnement
- les architectures d'un réseau de neurones
- les couches de convolution
- l'organigramme de l'algorithme
- les outils utilisés
- application réelle

Chapitre I

Notions fondamentale de la chaine logistique directe/inverse

1. Introduction

Les évolutions organisationnelles des entreprises ont un impact significatif sur la gestion et la distribution des produits. L'introduction de nouvelles stratégies a facilité l'émergence et la croissance des chaînes d'approvisionnement. Cela représente un avantage concurrentiel que l'entreprise souhaite conserver. Les stratégies logistiques ont permis de concevoir, planifier, exécuter et contrôler les différents flux de la chaîne logistique. Ces flux prennent en charge la conception, la fabrication et la distribution des produits ou des services afin de satisfaire les exigences du client.

1.1 La logistique

1.2 La logistique est l'art de gestion et de maîtrise des flux (physique, financiers, d'information) aux meilleures conditions économiques afin d'atténuer les besoins du client. Faite en sorte que la logistique du produit gère toutes les étapes de la vérification physique des flux jusqu'à la planification des ressources. La chaîne logistique se compose de cinq maillons : la production, l'approvisionnement, le stockage et la distribution (y compris le transport). Ces maillons sont confrontés à une concurrence accrue. Due à l'émergence des nouveaux besoins des clients les entreprises ont été obligées de suivre les avancées technologiques dans le transport, la maintenance... Etc. Ce qui implique l'apparition de nouveaux prestataires logistiques sur le marché.

1.3 La chaîne logistique

La chaîne logistique est l'assurance stratégique et logistique qui relie les actions décisives allant de l'approvisionnement au client.

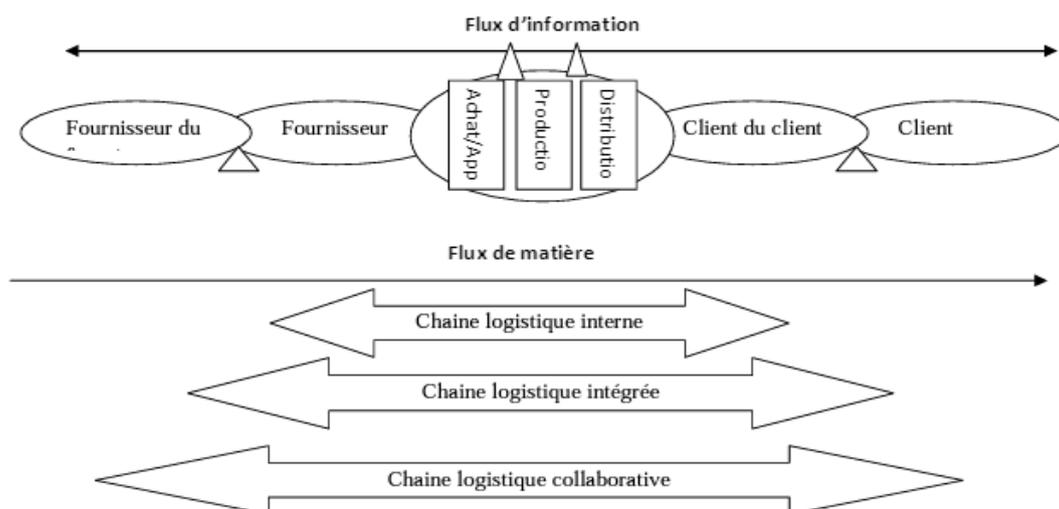


Figure 1 : la chaîne logistique dans l'entreprise (hichem, 2020)

Autrement, elle s'agit de cycle de vie d'un produit ainsi, le processus d'approvisionnement, de production, de stockage et de distribution exige une fluidité et une synchronisation entre tous les maillons de la chaîne.

1.4 Les maillons de la chaîne logistique

1.4.1 L'approvisionnement

L'approvisionnement est la phase centrée de la chaîne logistique et désigne le fait d'acheter un bien ou un service qui va être considéré comme une fourniture des matériaux nécessaire pour fabriquer un produit final. Le maillon d'approvisionnement nécessite une bonne planification et coordination de toutes les contraintes environnantes telles que le coût, la disponibilité et le choix de fournisseur. On vise deux flux dans cette étape :

Le flux d'information qui est primordial pour l'envoi et la réception de la commande.

Le flux physique qui correspond à l'acheminement de la matière première au client.

1.4.2 La fabrication/production

Cette phase désigne toutes les activités de transformation de matière première en produit fini ou semi-fini. Le challenge dans cette étape est d'optimiser le processus industriel afin de le rendre souple et plus effectif. Ce maillon indique la puissance de la chaîne logistique et représente sa réactivité à la variabilité de la demande du marché.

1.4.3 Stockage

Cette phase désigne les produits finis ou semi-finis stockés. On cherche dans cette étape à gérer le nombre de stock car plus le nombre est remarquable plus la Chaîne logistique est moins flexible, la gestion du stock est la clé de succès de l'optimisation de la chaîne

1.4.4 Distribution

Ce maillon représente toutes les opérations de transport et de distribution du produit fini au client, l'un des enjeux de cette étape est le choix du transport (maritime, aérien, routier, ferroviaire, fluviale) en prenant compte tenu de l'importance de la demande et la rentabilité globale.

1.4.5 La vente

Dans cette étape, le challenge est d'élargir la marge de gain, on prend en considération les prix compétitifs du concurrent, l'efficacité de cette phase peut être déterminée par la performance de l'optimisation de ce problème.

1.5 Les flux dans la chaîne logistique

La chaîne logistique contient trois flux principaux :

1.5.1 Le flux informationnel

Représente l'ensemble d'information transmise/échangée entre les différents maillons de la chaîne d'approvisionnement. Cette information peut être de nature commerciale tous qui concernent le produit, la livraison...Etc. Ou techniques tels que la capacité de production le niveau du stock, les spécifications des produits.

1.5.2 Le flux physique

Le flux physique s'intéresse à la circulation du produit/marchandise tout au long de la chaîne d'approvisionnement. Il influence les contraintes suivantes :

$$\left\{ \begin{array}{l} \text{l'emplacement du site} \\ \text{les moyens de transport utilisés} \end{array} \right.$$

1.5.3 Le flux financier

C'est toute activité de trésorerie des entreprises (la vente des produits, l'achat de matière première ou bien les équipements, pièces de rechange...Etc., ce flux est géré dans le service financier ou comptabilité.

1.6 La chaîne logistique inverse

1.6.1 Définition

La logistique inverse est un domaine vaste, qui fait appelle a plusieurs notions de la chaîne d'approvisionnement c'est pour cela de nombreux auteur ont proposé des définitions sur la chaîne logistique inverse pondéré sur le produit.



Figure 2: la chaîne logistique inverse

- (M. Thierry, 1995): c'est la gestion des produits, composant et matériaux usagés relève la responsabilité de l'entreprise de fabrication afin de maximiser la valeur économique le plus raisonnable possible et minimiser la quantité des déchets.

- (Beaulieu, mai 2000): c'est l'ensemble d'activités de gestion afin de re-fabriquer des produits secondaires en ajoutant une valeur a ce produit

D'autre auteur souhaitent de parfaire l'approche de la logistique inverse :

- (D.S. Rogers, 2001) (M. Fleishmann, 1997): c'est le processus de planification, de mise en œuvre et de suivi des flux dès le point de consommation jusqu'au point d'origine, pour le but trouver un moyen du bonne gestion de processus

(Chouinard, 2003): c'est la récupération des biens du circuit marchands ou bien des consommateurs, entre autre l'objectif est d'assurer la gestion et la planification de la collecte, l'évaluation, le tri, le démontage et la redistribution ainsi que la gestion des stocks des produits restaurés et précieux.

D'un autre coté la logistique inverse sert a valoriser les matière en fin de vie dont l'objectif est le développement durable.

Considérant que ces activités implique le changement des habitudes de consommation.la base d'une chaine d'approvisionnement durable est la vision a long terme. (Dupont, 2003)

La logistique inverse s'intéresse aux flux associée issus des activités logistiques directes telles que la gestion des déchets, emballage, retours...Etc. la création de la chaine logistique inverse consiste à valoriser les reflux sous une forme économique énergétique ou sociale ; c'est une partie primordiale ce qui influence la durabilité

La logistique inverse désigne les flux physiques qui suivent le chemin inverse et remontent la chaine.il concernait principalement la gestion des déchets et des produit en fin de vie (valorisation, réemploi et le recyclage) et s'inscrivait dans une problématique écologique, actuellement la logistique inverse va au delà de ce domaine d'activité afin d'inclure la gestion

Des produits non conforme, la gestion de produit en fin de cycle, le traitement des déchets générer lors de la production, transport et livraison (DUPONT, 6/11/2018)

Cette figure montre les relations et les acteurs de la chaine logistique inverse, les partie prenant de ce réseau sont les clients, les distributeurs, les entreprises a travers le système de production et les fournisseurs, les autres partie prenantes extérieurs de ce réseau représente les collecteurs, les réparateurs ou bien les centres de recyclages. (DUPONT, 6/11/2018)

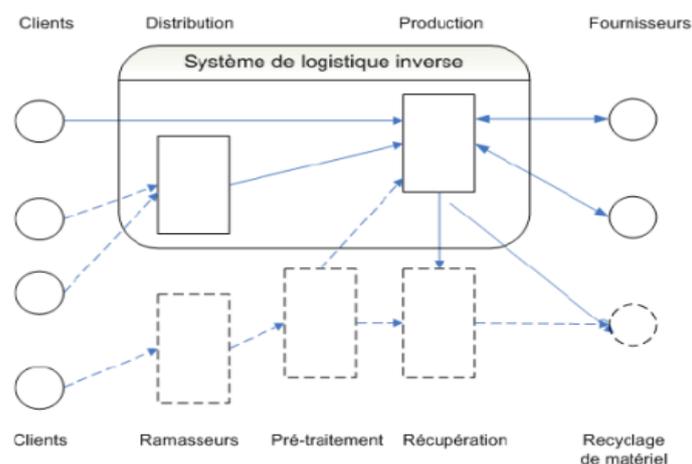


Figure 3 : Réseau de logistique inverse (Lambert, 2003) (M. Fleishmann, 1997)

1.7 Re-manufacturing

Pendant la révolution industrielle, les enjeux environnementaux n'était pas pris en compte dans la conception et la fabrication des produits, mais ces dernier années ils sont devenu un casse tête majeur pour les industriels en raison de l'augmentation croissance de l'utilisation d'énergie et des ressources matérielles, et le développement des entreprises en adoptant le

Processus industriel du « prendre, fabriquer, jeter » ; l'économie absorbe les ressources naturelles et supprimer les déchets des décharges.



Figure 4: économie linéaire

Cette situation à entraîner une grave pénurie de ressources et de changement climatique ce qui nécessite un traitement de déchets en urgence

Nombreux concepts, on était introduits pour résoudre ce problème tel que « life cycle thionine, design for envirement, envirementally concious manufacturing...Etc. ».

La Commission européenne a adopter le nouveau concept d'économie circulaire et l'objective de ce concept est le maintient de la valeur de produit et de ressources dans le cycle de vie. La préfabrication est l'une des options utilisées pour la création d'une boucle du cycle de vie d'un produit. La norme BS8887-2(2009) de la British Standards Institution définit la préfabrication comme le processus suivant qui consiste à « rendre à un produit au moins ses performances d'origine avec une garantie équivalente ou supérieure à celle du produit nouvellement fabriqué ». Ou meilleure que celle du produit nouvellement fabriqué.

A l'époque de la Seconde Guerre mondiale, ils ont été exceptionnellement besoin de réutiliser les pièces automobiles à cause de non disponibilité des pièces de rechanges, Pièces automobiles en raison de la rareté des ressources naturelles utilisées pour construire des avions, des navires et des chars pour la guerre. Tanks pour la guerre. La re-manufacturing connaît une croissance régulière aux États-Unis et en Europe, mais aussi dans plusieurs pays du monde ; avec les progrès de la technologie, le champ d'application de l'industrie de la rénovation s'est considérablement étendu.

Technologie, le champ d'application de l'industrie du re-manufacturing s'est considérablement étendu à d'autres secteurs variés, dont les équipements Médical, l'aérospatiale, l'électronique et l'équipement électrique, ainsi que le mobilier de bureau. (Ismail 2016)

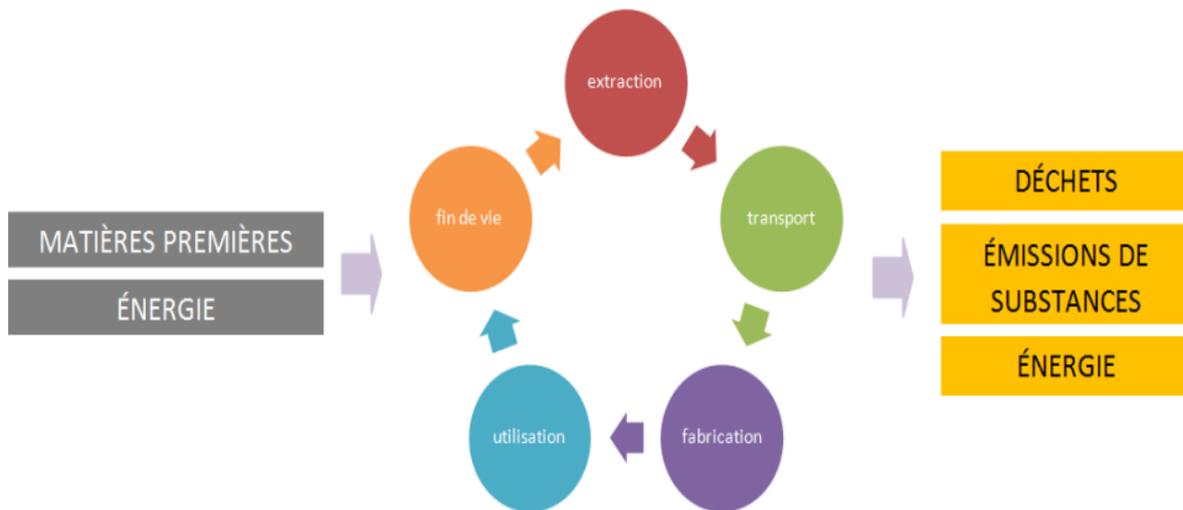


Figure 5: le cycle de vie fermier (dunod, 2006)

1.8 Maintenance d'un produit en fin de cycle

D'après la norme AFNOR :

On peut définir la maintenance comme l'ensemble des actions qui sert à maintenir ou rétablir un bien pour le but d'assurer la détermination du service sans oublier la contrainte du coût qui doit être optimal.

- **Maintenir** : désigne la fonction de prévention d'un système fonctionnel
- **Rétablir** : veut dire la correction consécutive d'une perte de fonction
- **Coût optimal** c'est la fonction qu'on cherche à l'optimiser

La maintenance est l'ensemble d'activités regroupées en deux classes les activités techniques et les activités de gestion.

1.9 Recyclage

C'est le processus de gestion des déchets en donnant à un objet de fin de cycle une deuxième vie, il comprend trois étapes essentielles la collecte, le tri enfin le recyclage.

Le recyclage était longtemps négligé, mais aujourd'hui, il est favorisé par les industriels à cause de la montée des prix de matière première donc ils ont passé à cette solution qui va diminuer les coûts d'imploration de matière premier. On peut citer le processus de recyclage de quelques éléments :

Plastique : le matériau le plus émergent dans le marché, il représente un enjeu considérable à cause de sa valeur calorifique qui vient de sa matière première « le pétrole », la grande variété de plastique et l'évolution de technique de recyclage font les activités de cette industrie.

Il existe deux types de recyclage : mécanique et chimique. D'abord, quand les déchets sont arrivés au centre de recyclage, il suit une série de procédés de nettoyage (lavage, séparation, affinage) afin de les préparer pour le broyage et finit par une matière première recyclée.

Verre : le verre est un matériau utilisé beaucoup dans nos maisons et son processus de recyclage et le suivant : après le tri sélectif des habitants, les collectivités convoient ce verre vers un centre de traitement qui va s'occuper de la fusion et la fabrication d'un nouveau produit ensuite, il va être transporté directement aux consommateurs.

Papier : on peut voir l'utilisation du papier recyclé dans l'impression et il suit le processus suivant : après la collecte et le tri le papier va être mis en balles et ensuite, ils vont le déchiqueter dans une cuve avec de l'eau ; une longue étape malaxage à bon lieu : elle va permettre de gonfler les fibres végétales et les séparer et filtrer pour éliminer les indésirables (on peut aussi éliminer l'encre par une série de nettoyages successifs) ; la pâte obtenue est ensuite réintégrée dans un processus de fabrication du papier.

Bois : les déchets du bois proviennent de trois principales sources : exploitation forestière (Les branchages, coupe...Etc.), les rebuts (Palettes de transport...Etc.), déchets ménagers (Meuble, mobiliers...Etc.).

Ce bois va être trié selon sa qualité (traité ou bien non traité) ensuite broyée puis débarrassée de ses résidus.

Le problème de traitement des déchets a été parmi les plus anciens problèmes depuis l'existence de l'industrie, mais au début la consommation était faible et l'utilisation de petite gamme de produits ce qui n'inquiétait pas la présence de déchets et actuellement avec la variété des produits consommables ce secteur a pris une autre tournure et devient une préoccupation mondiale, à cause de la consommation massive et la carence de technologies qui assure le traitement.

Les statistiques des déchets mondiaux s'accroissent d'un jour à un autre avec des quantités importantes et malgré l'existence de quelque centre de tri le problème reste toujours d'actualité puisque la balance entre la quantité émise et la quantité traitée est déséquilibrée et afin de rétablir cet équilibre nous avons proposé une technique de tri sans intervention humaine en utilisant la tendance des technologies « l'intelligence artificielle »

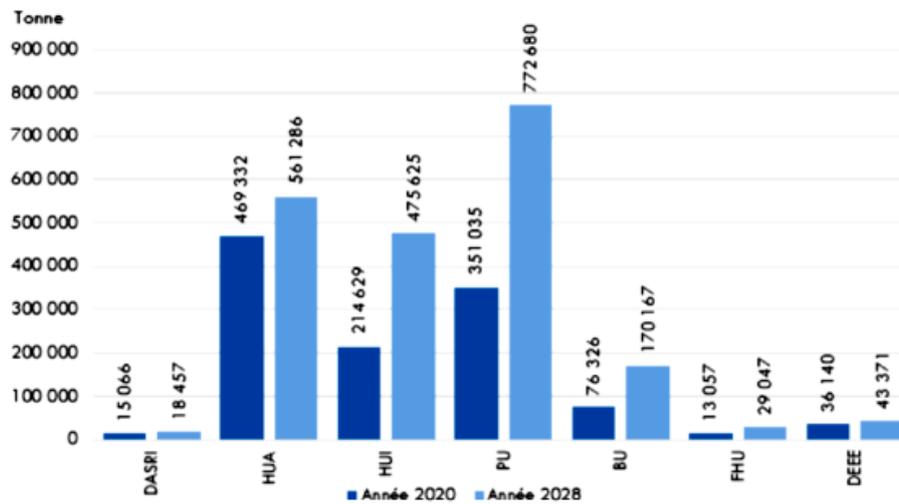


Figure 6: quantité de quelque déchets spéciaux et dangereux (AND) (L'absence d'approche économique hypothèque la durabilité de la gestion des déchets, 2021)

Ou {

- DARSI : déchets d'activités de soin à risque infectueux
- HUA: huile usagé alimentaire
- HMU: huile moteur usagé
- HUI: huile usagé industriel
- PU: pneus usagés
- BU: batteries usagé
- FHU: filtre à huile usagé
- DEEE: dechet équipement électrique et électronique

1.10 Technique de collecte et de tri

Le processus de recyclage se compose de plusieurs étapes qui varie selon le type de déchets, il commence par la collecte et le tri puis recycler (re-manufacturing, maintenance...Etc.) et enfin distribuer le produit final.

Le tri des déchets est l'étape goulot parce qu'elle prend de l'énergie et du temps et afin d'assurer la fluidité de processus l'AND (agence nationale de déchet) a créé un projet de collectivité locale initié par le ministre de l'environnement. Il consiste à introduire la collecte des déchets ménagers sélective en Algérie à travers un tri multi matériaux sèche et humide. Un bac jaune pour les déchets sec et recyclable (Plastique, carton, métal...etc.) et un bac vert pour le reste (Les épluchures de fruit, des légumes...etc.). Le but de cette initiative est de sensibilisation de la population au tri sélectif.

Conclusion

Vu la consommation massive et dynamique des individus, le ratio des déchets se cesse à augmenter et devient de plus en plus difficile à gérer. Et les techniques de tri classiques ne servent pas à traiter ces déchets de la même manière qu'auparavant ce qui impose a renforcée le système de tri par des technologies avancée et innovante.

L'objectif de cette recherche est d'établir une approche capable de trier les déchets en utilisant des approches modernes inspiré des évolutions informatique. (IA, Deep Learning qui sera expliqué et détaille dans le chapitre 2).

Chapitre I I

*Intelligence artificielle et outils de
classification*

2. Introduction

La classification des déchets était toujours un problème critique car les solutions proposées a été soit cher en termes de cout soit était non faisable, en réalité les déchets peut être classé en cinq principales catégories (carton, papier, plastiques, bois, métal) et les techniques de tri classique (Tri mécanique comme le tombons, tri magnétique... Etc.) Sont lourd en implémentation et l'avancement de l'outil informatique nous a aider pour proposer une méthode de classification des déchets en utilisant le Deep Learning pour la reconnaissance et le traitement des déchets ensuite la détection de la classe du déchet ce qui sera expliquer dans ce chapitre.

2.1 Intelligence artificielle

L'Intelligence Artificielle (IA) est la nouvelle technologie qui a pour le but d'apprendre une machine a décider et faire les taches humaine par son propre intelligence. La terminologie d'intelligence artificielle désigne le traitement d'information autonome par des méthodes précise. (ISASH, 1999/2000.)

On voit l'intelligence artificielle dans plusieurs domaines dont lequel on va citer quelques une :

- Les systèmes experts comme médecine, analyse financière, configuration d'appareils, diagnostics ou dépannage d'installation industriel.
- Compréhension du langage et traduction automatique
- Reconnaissance des formes comme reconnaissance faciale, reconnaissance d'écriture
- Apprentissage c.à.d. la machine qui décide au lieu d'un être humain
- La détection des émotions...etc.

2.1.1 Machine Learning

C'est une branche de l'intelligence artificielle appeler aussi l'apprentissage automatique en français, il a commencé d'émerger a partir des années 1980 et elle permet d'entraîner une machine afin qu'elle apprenne à décider toute seul. Cette approches est basé sur l'apprentissage automatique qui sert à établir des algorithmes capable de recevoir des données traiter et prédire les résultats, en mettent a jour le reçoit de la base de données.

Dans l'apprentissage automatique on donnent a notre algorithme des données d'entraînement, ce qui va permettent ensuite de décider sur la nouvelle base de données et relèvent le problème a résoudre. Plus on nourrit notre algorithme de données pour s'entraîner plus il va traiter la nouvelle information avec précision. (Dallaire-Nicholas, 8 février 2021.)

On peut citer trois types populaires de Machine Learning :

L'apprentissage avec supervision

Ce type aide à construire des modèles prédictifs en utilisant les données d'entrées (Input) et les données de sortie (Output). Donc dans cette algorithmique on entraîne notre réseau en lui donnant la base de données et les résultats qu'on souhaite avoir au final, l'apprentissage par supervision peut se trouver en deux formes connus : la première est la classification lorsque la variable de sortie est une catégorie et la deuxième est la régression. Lorsque la valeur de sortie est une valeur numérique. (Dallaire-Nicholas, 8 février 2021)

L'apprentissage sans supervision

Contrairement au précédent cette méthode aide à réaliser un modèle prédictif en n'utilisant que les données d'entrée. Donc le système va apprendre à une structure à travers de ces données sans intervention humaine, les techniques utilisées dans l'apprentissage sans supervision sont basées sur « clustering analysis » (l'analyse par regroupement), un exemple qu'on peut rencontrer souvent est le signalement de transaction inhabituelle sur une carte de crédit, la détection d'anomalies c'est l'apprentissage automatique sans supervision (Dallaire-Nicholas, 8 février 2021.)

L'apprentissage semi-supervisé

C'est un type intermédiaire entre les deux types cités précédemment, en effet une partie des données d'entrées sont associées aux données de sortie. (Dallaire-Nicholas, 8 février 2021)

L'apprentissage par renforcement

C'est la méthode qui a pour but d'optimiser les résultats pour prendre des décisions en utilisant l'essai-erreur en maximisant les récompenses et minimisant les risques. Par contre la prise de décision par l'apprentissage supervisé est sur la base de données, l'apprentissage par renforcement consiste à prendre une série de décisions en appuyant sur les décisions précédentes afin d'arriver à une décision optimale en fonction d'une situation donnée. (Dallaire-Nicholas, 8 février 2021)

2.1.2 Deep Learning

Le Deep Learning est un type de méthode de calcul. Il est composé de plusieurs multiples couches de traitement qui apprennent et représentent la caractéristique et la distribution de données d'entrée avec plusieurs niveaux d'abstraction (c'est-à-dire différentes profondeurs de carte de caractéristiques).

Aujourd'hui, le succès de l'apprentissage profond peut être attribué à deux branches de réseaux neuronaux bien conçus : les réseaux neuronaux convolutifs (CNN ou ConvNets) et les réseaux neuronaux récurrents (RNN).

Les ConvNets sont en effet des extracteurs de caractéristiques. Ils sont excellents pour traiter des réseaux 2D structurés dans des domaines tels que le traitement des images. Les ConvNets ont atteint une performance de pointe sur la classification d'images, la segmentation d'images et la détection d'objets. Les RNN sont excellents dans le traitement de séquences (CNN) et (RNN). (Kai Yi, 22 Jun 2018)

L'apprentissage profond peut être réalisé comme un apprentissage supervisé ou non supervisé. La percée dans la représentation distribuée des mots en utilisant Deep Learning renforce la base de l'analyse sémantique.

De nombreuses méthodes d'apprentissage non supervisé différentes, qui génèrent des incorporations de mots à partir de données non structurées, permettent aux futurs modèles d'analyse sémantiques de haut niveau d'obtenir des résultats de pointe. Atteignant les résultats les plus avancés. L'apprentissage profond est en train de s'implanter dans tous les domaines possibles. Le domaine juridique bénéficie également des avantages susmentionnés. Un avocat doit passer des heures et des heures à rechercher des documents pertinents et à préparer des arguments à l'aide de précédents pertinents. L'intelligence artificielle permet à l'avocat humain de travailler plus vite et de disposer de plus de données. Cela nous montre que la coopération entre l'homme et l'IA est importante. Elle vise à fournir aux avocats davantage de conseils et à les débarrasser des tâches fatigantes.

Cette revue couvre exclusivement les travaux récents employant des modèles d'apprentissage profond pour le domaine juridique et suggère des directions de recherche futures. Domaine juridique et suggère des directions de recherche futures. (Neha Bansal, 24 Oct 2019.)

En résumé le Deep Learning est une approche d'apprentissage automatique qui permet d'améliorer le réseau d'information en lui fournissant des outils et des données. L'apprentissage profond est l'approche la plus puissante car elle aide à créer un système intelligent apte à gérer la situation même si elle est complexe en raison de sa flexibilité.

2.1.3 Pourquoi le deep Learning ?

L'une des principales différences entre les algorithmes de deep learning et machine learning est que plus la base de données fournies est importante plus les performances de l'algorithme deep learning augmente, par contre les algorithmes de machine learning classique ont une limite supérieure de quantité de données qu'ils peuvent recevoir, ils sont appelés « plateaux de performance », en effet les algorithmes d'apprentissage profonds n'ont pas de limite. (ISHAK, 2018/2019)

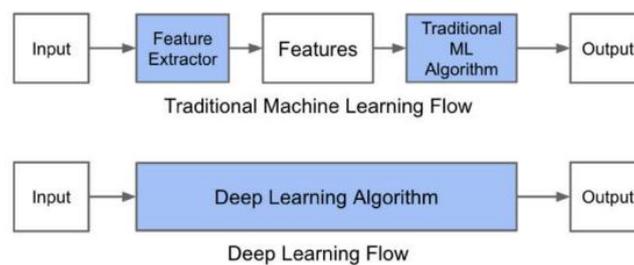


Figure 7: Le procédé du ML classique comparé à celui du Deep Learning

Le Deep Learning est un domaine vaste qui peut résoudre plusieurs problèmes dans plusieurs secteurs, le plus connu est le traitement des images.

2.2 Le deep Learning pour le traitement des images

Le traitement des images est un domaine qui se situe dans l'intersection des deux domaines informatique et mathématique. Appliquer qui sert à lire les images numériques et leurs transformations dans le but d'extraire des informations des images. La segmentation d'image est une étape primordiale dans le processus de traitement et d'analyse qui vise à diviser une image en des parties homogènes et regrouper les pixels aux propriétés communes. La segmentation d'image sert à déterminer la qualité des mesures ultérieures (ALKAMA 27 septembre 2018)

Pour cela, on utilise un système de vision pour nous aider à récupérer des images qui vont être notre point de départ afin de les traiter par le Deep Learning.

2.3 Le système de vision industriel

Dans un processus de recyclage, un bac de déchets va suivre une succession de tri avant le recyclage qui est l'étape délicate de ce processus. Les déchets qui avaient passé par le tri sélectif.

Vont être mis dans un convoyeur et traverse un autre tri industriel a l'aide des capteurs numérique dans des camera et des scanner qui permettent l'acquisition des images ce qui appelle un système de vision industriel et le choix de système de ce dernier dans un centre de recyclage influence le traitement et la classification des images.

2.3.1 Définition de la vision industrielle (machine vision)

La vision industrielle désigne la tâche de traitement des images numérique, cette discipline utilise des moyens électronique afin de donner aux machines des capacités sensorielles similaires a la vision humaine. En d'autre terme il utilise la camera comme un capteur pour détecter les objets mal manufacturés ensuite trier, classer et mesurer ces pièces. Cependant, les êtres humains qui peuvent rechercher les exploits de vision humains, la structure spatiale environnante et les objets complexes et variés connus ou inconnus en 2D ou 3D et reconnaître les fonctions appropriées. Vous devez imaginer que la similitude avec l'exploit visuel est trop profonde. (TALEB-AHMED, 2005)

On distingue deux parties essentielles de détection : la segmentation et la reconnaissance

La segmentation d'image est une étape de traitement qui vise à regrouper les pixels selon des critères prédéfinis. Ensuite les pixels seront regroupés en zones qui vont former un pavage ou partitionnement d'image (comme la séparation d'objet de l'arrière plan) (Benjamin, 2011-2012.)

Il existe plusieurs techniques de segmentation avec neuf algorithmes testés dans cette étude : Image segmentation algorithms applied to wood defect detection (J.WFunck, 2003)

Pour pouvoir intégrer notre solution dans l'industrie de recyclage, nous étions inspirées d'un centre de tri français qui avait une chaîne de tri semi-automatique, et dans cette chaîne ils ont utilisé plusieurs méthodes d'imagerie et nous allons citer quelque méthode

2.4 La segmentation par seuillage

La segmentation par seuillage sert a extraire les zones intéressantes ensuite procéder la détection des anomalies, cette technique présente une originalité car elle simple et parmi les premiers technique utilisée dans la segmentation (Cyril MAZAUD, 2006.)

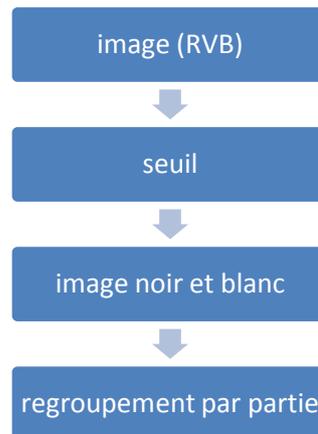


Figure 8: la segmentation par seuillage (Benjamin, (2011-2012))

2.5 La reconnaissance en utilisant une base de données

La deuxième méthode consiste à créer une base de données puis la classifiées, cette méthode nécessite un tant d'images pour chaque catégorie. Plus il ya d'image plus la détection est efficace. (Benjamin et Marc 2011-2012)

Voici les étapes à suivre pour le traitement

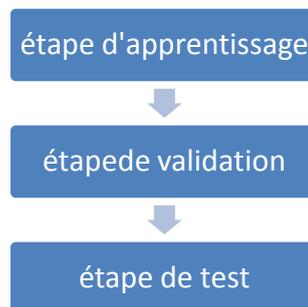


Figure 9: la reconnaissance en utilisant une base de données (Benjamin, et al., 2011-2012)

Le plus compliqué dans cette méthode est de créer les algorithmes permettant de faire le rapprochement entre une image appartenant à la base de données et de l'image de test. Le temps de traitement dépend directement de ces algorithmes.

2.6 Quelques méthodes d'imagerie utilisées dans l'industrie

Il existe plusieurs méthodes d'imagerie industrielle, surtout avec les avancements technologiques (l'intelligence artificielle, l'industrie 4.0...Etc.) par lesquels on va citer les méthodes plus fréquemment utilisées avec le deep Learning dans l'industrie.

2.6.1 La radiographie industrielle

La radiographie industrielle est une méthode d'imagerie qui existe depuis des années et qui a pour le but d'inspecter les objets afin de détecter des anomalies cachées en utilisant les rayons X, rayons GAMMA et des neutrons à pénétrer divers matériaux.

La première utilisation de la radiographie X pour l'observation de la solidification des métaux a été effectuée par Forsten et Miekkoja (Forsten and Miekkoja, 1967). Miller et Beech ont ensuite amélioré la résolution et acquièrent en continue les phénomènes au cours de la solidification d'un alliage Al-Cu et Al-Sn par l'utilisation de la méthode de microradiographie (Miller and Beech, 1972)(SOLTANI 2020)

Les limites de cette méthode

Les limites de cette méthode sont liées a au coût des installations et de consommation ainsi que les rayonnements X ce qui imposent des réglementations et des consignes stricte.

2.6.2 La camera industriel

Les cameras industriel sont des outils qui sert a prendre ou capturer des images d'un objet ou d'un emplacement, ils s'interface avec des lentilles d'imagerie. La camera contient des capteurs conçus pour capturer la lumière a l'aide des lentilles d'imagerie, on trouve souvent cette méthode dans le contrôle de production. (direct industry by virtualexpo group s.d.)



Figure 10: Caméra intelligente In-Sight ViDi D900 avec logiciel intégré d'apprentissage profond

2.6.3 La tomographie industrielle

La tomographie permet sans contact et sans destruction, de visualiser l'intérieur de la matière, l'invisible caché par l'enveloppe extérieure ou la peau on trouve cette méthode dans le domaine mécanique car elle permet d'analyser l'objet en microstructure sans être destructif. la tomographie donne l'image en format 3D a travers un série de radiographie.(ROUX 17/12/2014)

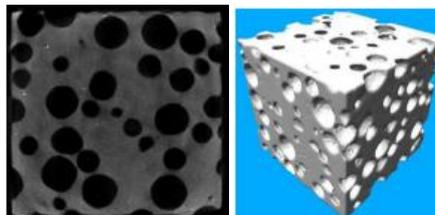


Figure 11: à gauche coupe issue de la tomographie adroite reconstruction 3D d'une microstructure

Les limites de cette méthode

L'acquisition d'une image dans de bonnes conditions nécessite un rayonnement fixe dans sa direction et son positionnement par rapport à l'objet étudié. Le tomographe en fonctionnement dégage de la chaleur. Il nécessite une mise en chauffe (de 1 à 2 heures) afin de stabiliser les déplacements et déformations de ses différents éléments au moment de l'acquisition. La phase d'acquisition des images 2D prend en général 1 heure ; ce temps peut être plus ou moins court, voire ultracourt, en fonction des besoins et du matériel disponible. Le temps de traitements des images et de reconstruction du volume prend de quelques minutes à une dizaine de minutes. C'est un temps relativement négligeable et qui tend à diminuer compte tenu des progrès réalisés sur les cartes GPU (Graphics Processing Unit ou processeur graphique) massivement utilisées dans ces opérations de reconstruction.(ROUX 17/12/2014)

2.7 Etat de l'art

2.7.1 (D. Hua 2020)

Cette étude propose un modèle de classification en utilisant l'intelligence artificielle pour détecter les déchets dangereux (D. Hua 2020), ils ont utilisé keras pour créer un réseau convolutifs et Open CV pour créer des vidéos en temps réel qui identifiait les déchets dangereux des autres matériaux recyclable. Le modèle est capable de classer les différents matériaux recyclables avec une précision d'environ 90 %. Les objets dans la vidéo reçoivent une prédiction pour 3 classifications qui incluent les piles, les seringues et les déchets non-dangereux. Ensuite, la catégorie la plus élevée est celle dans laquelle le réseau va le classer.

En conclusion, le modèle est capable d'identifier les objets dangereux et les articles recyclables dans un tas d'ordures pour aider à protéger tous les individus. (Dorothy Hua, 2020)

2.7.2 (C. Bircanoğlu 2018)

Cette étude l'un des premiers travaux démontrant l'efficacité des dernières approches intelligentes. Afin de fournir l'approche la plus efficace, nous avons expérimenté des architectures de réseaux neuronaux convolutifs profonds bien connues. Pour l'apprentissage sans poids pré-entraînés, Inception-Resnet, Inception-v4 ont surpassé tous les autres avec une précision de test de 90%. Pour l'apprentissage par transfert et le réglage fin des paramètres de poids en utilisant ImageNet, DenseNet121 a donné le meilleur résultat avec une précision de test de 95 %. Ces réseaux présentent toutefois l'inconvénient d'être légèrement plus lents en termes de temps de prédiction. Pour améliorer les performances de prédiction des modèles. (C. Bircanoğlu, 2018)

2.7.3 (Lee, 2021)

L'objectif de ce projet est de classer correctement les déchets grâce à l'utilisation de modèles d'apprentissage profond avec réglage fin. En faisant cela, ils se conforment à leur obligation légale de diligence. Dans l'ensemble, après le processus de classification, l'Inception_resnet_V2 a été séparé et classé en trois classes différentes : plastique, carton et ordures. VGG19, VGG16, Inception_v3, Xception et MobileNet ont également été utilisé

Pour la classification. Les principaux résultats de notre recherche ont conclu qu'il n'y avait que des différences nominales dans la précision par rapport aux travaux connexes, qui ont effectué une classification binaire. De plus, pour l'optimiseur, Nadam a obtenu le plus haut degré de précision, et était le plus élevé lorsque le taux d'apprentissage était de 0,01. Comme le modèle CNN+Autoencoder et le modèle VGG16 présentaient une différence de 35% en termes de précision, nous avons pu déterminer l'importance des modèles pré-entraînés. (Lee, 2021)

2.7.4 (Olugboja Adedeji, 2019)

Cette étude propose un système intelligent de classification des déchets, développé à l'aide d'un modèle de réseau neuronal convolutifs à 50 couches (ResNet-50), qui est un outil d'apprentissage automatique et sert d'extracteur, et d'une machine à vecteurs de support (SVM) utilisée pour classer les déchets en différents groupes/types tels que le verre, le métal, le papier, le plastique, etc. Le système proposé a été testé sur le jeu de données d'images de déchets développé par Gary Thung et Mindy Yang, et a atteint une précision de 87 % sur ce jeu de données. Le processus de séparation des déchets sera plus rapide et intelligent grâce au système de classification des déchets proposé, sans intervention humaine ou en la réduisant. (Olugboja Adedeji, 2019)

2.7.5 (Victoria Ruiz, 10 may 2019)

Dans ce travail, ils ont utilisé le jeu de données TrashNet pour entraîner et comparer différentes architectures d'apprentissage profond pour la classification automatique des types de déchets. En particulier, plusieurs architectures de réseaux de neurones convolutifs (CNN)

Ont été comparées : VGG, Inception et ResNet. Les meilleurs résultats de classification ont été obtenus en utilisant un modèle combiné Inception-ResNet qui a atteint 88,6 % de précision. Ce sont les meilleurs résultats obtenus avec le jeu de données considéré. (Victoria Ruiz, 10 may 2019)

2.7.6 (Yinghao Chu, 2018)

Cette étude propose un système d'apprentissage profond hybride multicouche (MHS) pour trier automatiquement les déchets jetés par les individus dans l'espace public urbain. Ce système déploie une caméra haute résolution pour capturer l'image des déchets et des capteurs pour détecter d'autres informations utiles. Le MHS utilise un algorithme CNN afin d'obtenir les caractéristiques de l'image et une méthode de perceptrons multicouches (MLP) pour consolider les caractéristiques de l'image et d'autres informations afin de classer les déchets comme recyclables ou autres. Le MHS est entraîné et validé par rapport à des articles étiquetés manuellement. Il atteint une précision de classification globale supérieure à 90 % dans deux scénarios de test différents, ce qui surpasse de manière significative une méthode de référence basée sur un CNN et reposant sur des entrées d'images uniquement. (Yinghao Chu, 2018)

2.7.7 (Janusz Bobulski, 2021)

Dans cette recherche, ils ont proposé des méthodes de traitement d'image et d'intelligence artificielle, notamment l'apprentissage profond, pour améliorer le processus de recyclage. Les techniques et procédures de tri des déchets sont appliquées aux principaux groupes de matériaux. Cependant, le plus grand défi consiste à séparer les différents types de matériaux d'un groupe, par exemple en triant différentes couleurs de verre ou de plastique. La question des déchets plastiques est importante en raison de la possibilité de ne recycler que certains types de plastique (le PET peut être transformé en polyester.). Il faut donc chercher des moyens de trier ces déchets. L'une des possibilités est l'utilisation de l'apprentissage profond et du réseau neuronal convolutifs. Dans les déchets ménagers, les composants plastiques sont les plus problématiques, et les principaux types sont le polyéthylène, le polypropylène et le polystyrène. Le principal problème abordé dans cet article est la création d'une méthode de séparation automatique des déchets plastiques, qui peut séparer les ordures en quatre catégories mentionnées, PS, PP, PE-HD et PET, et qui pourrait être appliquée dans un centre de tri ou à domicile par les citoyens. Nous avons proposé une technique qui peut être appliquée dans des dispositifs portables de reconnaissance des déchets, ce qui serait utile pour résoudre les problèmes de déchets urbains. (Janusz Bobulski, 2021)

2.7.8 (Chen, 3 decembre 2021)

Dans cet article, la technique de l'algorithme de reconnaissance d'image est utilisée pour réaliser une étude et une analyse approfondies du système intelligent de classification et de recyclage des déchets solides et pour optimiser la conception de son système. La structure du réseau et le principe de détection de l'algorithme de détection de cible basé sur des réseaux neuronaux convolutifs sont analysés, des images de déchets solides de construction sont collectées comme une base de données, et l'ensemble de données d'image est étendu en

Utilisant des techniques d'amélioration des données, et les objets cible dans l'ensemble de données sont étiquetés et utilisés pour former leurs propres modèles de détection. Pour faciliter le test des images et pour concevoir un système de détection de cibles de déchets solides de construction. En utilisant le système de détection pour la reconnaissance des déchets solides de construction. La reconnaissance d'images est une technique permettant de reconnaître des images en capturant des images réelle par le biais de dispositifs et en effectuant une extraction de caractéristiques, et cette technique a été largement utilisée depuis sa création. L'algorithme de classification des déchets solides recyclables basé sur l'apprentissage profond étudié dans cet article peut classer les déchets solides de manière efficace et précise, résolvant ainsi le problème des personnes qui ne savent pas comment classer les déchets solides dans la vie quotidienne. La couche convolution elle, la couche de pooling et la couche fully connected d'un réseau neuronal convolution el sont responsables de l'extraction des caractéristiques, de la réduction du nombre de paramètres, de l'intégration des caractéristiques dans des caractéristiques de haut niveau, et enfin de leur classification par le classificateur Soft Max à tour de rôle. Cependant, la situation réelle est complexe et souvent le résultat n'est pas obtenu comme prévu, et l'utilisation de l'apprentissage par migration peut

Être un bon moyen d'améliorer le phénomène de sur ajustement. Dans cet article, la combinaison de l'optimiseur paresseux et du lookahead peut améliorer la capacité de généralisation et la vitesse d'ajustement, ainsi que la précision et la stabilité. Les résultats expérimentaux sont testés, et il s'avère que la précision de la classification des déchets solides peut atteindre 95 % lorsque le modèle VGG19 est sélectionné et que l'optimiseur est combiné. (Chen, 3 décembre 2021)

2.7.9 (Charlotte Chapman-Wardy, 2021)

L'étude a été faite pour le pays Ghana, la gestion des déchets effectuée par les autorités métropolitaines ne semblent pas efficace de la situation des déchets, et il n'est donc pas rare de voir des déchets boucher les canalisations et joncher les rues de la capitale, Accra. On ne saurait trop insister sur l'impact de la quantité massive des déchets sur l'environnement, et sur la santé. Le rapport du Programme de surveillance en 2015 a classé le Ghana comme le septième pays le plus sale du monde. L'absence de planification efficace de la gestion des déchets est évidente dans la grande quantité de déchets déversés dans les zones ouvertes et les caniveaux qui ne sont toujours pas collectés. La planification de management de déchets solides nécessite des données fiables concernant la production de déchets, les facteurs d'influence sur la production de déchets et une prévision fiable des quantités de déchets. Cette étude a utilisé deux algorithmes, à savoir Levenberg-Marquardt et la régularisation bayésienne, pour estimer les paramètres d'un modèle de réseau neuronal artificiel adapté pour prédire la moyenne mensuelle des déchets produits et évaluer de manière critique les facteurs influencent la production de déchets solides dans certains districts sélectionnés de la région du Grand Accra. L'étude a révélé que l'algorithme de régularisation bayésienne était approprié, avec une erreur quadratique moyenne minimale de 104,78559 sur les données de formation et de 217,12465 sur les données de test, et des coefficients de corrélation plus élevés (0,99801 sur les données de formation, 0,99570 sur les données de test et 0,99767 sur les données globales) entre les variables cibles (déchets mensuels moyens générés) et les

Résultats prédits. La taille de la maison, les districts, la catégorie d'emploi, la religion dominante et le type de maison, avec une importance respective de 0,56, 0,172, 0,061, 0,027 et 0,026, se sont avérés être les cinq principales variables d'entrée nécessaires à la prévision

Des déchets ménagers. Il est recommandé que les efforts du gouvernement et de ses parties prenantes pour réduire la quantité de déchets ménagers soient orientés vers la fourniture de poubelles, et la gestion des activités économiques dans les cinq premiers districts sélectionnés (Ledzekuku Krowor, Tema West, Asheidu Keteke, Ashaiman, et Ayawaso West), (Charlotte Chapman-Wardy, 2021)

2.7.10 (Rijwan Khan, 2021)

Cet article propose une solution efficace de gestion intelligente et efficace des déchets utilisant l'apprentissage automatique (ML) et l'Internet des objets (IoT) est proposé dans cet

Article. Dans la solution proposée, les auteurs ont utilisé le traitement d'image, ou on peut mesurer l'indice de déchets d'une décharge particulière. Un prototype matériel est également développé pour le cadre proposé. Ainsi, la solution présentée pour la gestion efficace des déchets permet d'atteindre l'objectif de créer des villes propres et sans pollution. (Rijwan Khan, 2021)

2.7.11 (J. Sousa, 2019)

Cet article propose une approche Deep Learning hiérarchique pour la classification des déchets dans les plateaux alimentaires. L'approche en deux étapes proposée conserve les avantages des détecteurs d'objets récents (comme Faster R-CNN) et permet de prendre en charge la tâche de classification dans des boîtes de délimitation à plus haute résolution. En outre, nous collectons, annotons et mettons à la disposition de la communauté scientifique un nouveau jeu de données, appelé Labeled Waste in the Wild, à des fins de recherche et de comparaison. Dans la comparaison expérimentale avec les approches d'apprentissage profond standard, le modèle hiérarchique proposé présente de meilleures performances de détection et de classification. (J. Sousa, 2019)

2.7.12 (S. Sudha, 2016)

L'article propose un système de reconnaissance automatique utilisant l'algorithme d'apprentissage profond de l'intelligence artificielle pour classer les objets comme biodégradables et non-biodégradables, où le système, une fois entraîné avec un ensemble de données initial, peut identifier les objets en temps réel et les classer de manière presque précise. Les déchets biodégradables sont utilisés pour produire de l'énergie, enrichir les sols et servir de nourriture aux animaux. Ce processus ne nuit pas à la terre, ce qui le rend précieux, écologiquement sûr et nous aide à protéger notre environnement, notre riche écosystème et nos habitants à l'avenir. (S. Sudha, 2016)

2.7.13 (Mittal, 2016)

Cet article présente une nouvelle application pour Smartphone, appelée SpotGarbage, qui détecte et segmente grossièrement les zones de déchets dans une image géo-taguée cliquée par l'utilisateur. L'application utilise l'architecture profonde proposée de réseaux entièrement convolutifs pour détecter les déchets dans les images. L'entraînement du modèle a été faite avec une autre base de données Garbage In Images (GINI) et a atteint une précision moyenne de 87,69 %. L'article propose également des optimisations dans l'architecture du réseau, ce qui permet de réduire de 87,9 % l'utilisation de la mémoire et de 96,8 % le temps de prédiction, sans perte de précision, facilitant ainsi son utilisation dans les Smartphones à ressources limitées. (Mittal, 2016)

2.7.14 (Mittal, 2016)

La base de cette étude est d'installer un système de surveillance automatisé et intelligent des poubelles basé sur l'IdO est proposé. De plus, un modèle d'apprentissage profond a été utilisé pour prévoir les futurs niveaux de déchets à travers les données collectées. Le modèle de réseau neuronal proposé a pu prédire les niveaux de déchets avec une précision de 80,33 %. Les résultats vérifient la précision du pronostic des niveaux de déchets. En outre, l'analyse des données était avec le diagramme à barres. L'amalgame de l'IdO et de l'apprentissage profond peut apporter un changement révolutionnaire dans la technologie et être appliqué à la gestion des déchets. Par conséquent, la prédiction et l'examen des niveaux de déchets peuvent aider les autorités municipales à intégrer un système de gestion des déchets efficace et à réduire le débordement des poubelles. (P. P. Rao, 2020)

2.7.15 (S. Chepa, 2021)

Auparavant, au lieu d'utiliser différentes méthodologies pour le tri et la gestion des déchets, les gens utilisaient des méthodes similaires pour les différents types de déchets produits dans diverses catégories. Mais ces dernières années, les techniques de séparation des déchets et d'élimination appropriée ont fait un bond en avant. Les deux principales technologies qui ont été développées pour éliminer les complications dans le secteurs de la gestion des déchets sont l' IoT (Internet des objets) et l'apprentissage profond. Outre la ségrégation et la gestion des déchets, la collecte des ordures est également une tâche importante. Lorsque les ordures ne sont pas collectées à intervalles réguliers, cela affecte la santé des citoyens résidant dans la zone environnante. Les deux technologies ont fait un excellent travail en éliminant ce fossé de communication et en veillant à ce que la ségrégation des déchets se fasse de manière appropriée, en ne négligeant aucun détail. Ce document d'étude traite des différentes stratégies de tri et de gestion des déchets. (S. Chepa, 2021)

2.7.16 (S. K. Behera, 2020)

Cet article présente une nouvelle technique de classification des déchets à l'aide de Open CV et de deep Learning afin d'améliorer la performance de classification des déchets et des SVM (support vector machine). dans cet étude ils ont travaillé sur la ségrégation des déchets solides municipaux, ils ont utilisé YOLO (You Only Look Once) comme approche algorithmique

Cette algorithmme est couramment utiliser afin de détecter des objets et extraire les caractéristiques du donnée d'image.ils ont proposé une méthode de classification des déchets biodégradable. (S. K. Behera, 2020)

2.7.17 (al, 2021)

Cet article se concentre sur une nouvelle solution pour la ségrégation des déchets solides en utilisant les concepts de vision artificielle et d'apprentissage profond. Le concept proposé est testé pour la ségrégation des déchets solides secs, en particulier les bouteilles de plastique

Les canettes et les tetra packs. Le système prototype développé pour les ségrégations fonctionne à grande vitesse et avec précision. Le système prototype trie 250 objets par minute avec une précision moyenne de 96%. L'idée novatrice proposée peut être étendue et mise en œuvre pour d'autres types de tri des déchets et peut inclure d'autres catégories de déchets solides et secs. Le système apporte une solution au problème de la gestion des déchets municipaux, qui constitue un défi permanent. (al, 2021)

2.7.18 (al., 2020)

L'objectif de cette recherche est de créer un système intelligent de gestion des déchets en utilisant le protocole de communication LoRa et un modèle d'apprentissage profond basé sur TensorFlow. LoRa envoie les données du capteur et Tensorflow effectue la détection et la classification des objets en temps réel. La poubelle se compose de plusieurs compartiments pour séparer les déchets, notamment le métal, le plastique, le papier et le compartiment des déchets généraux, qui sont contrôlés par les servomoteurs. La détection des objets et la classification des déchets sont effectuées dans le cadre de TensorFlow avec un modèle de détection d'objets pré-entraîné. Ce modèle de détection d'objet est entraîné avec des images de déchets pour générer un graphe d'inférence gelé utilisé pour la détection d'objet qui est faite par une caméra connectée au Raspberry Pi 3 Modèle B+ comme unité de traitement principale. Un capteur à ultrasons est intégré dans chaque compartiment de déchets pour surveiller le niveau de remplissage des déchets. Un module GPS est intégré pour surveiller l'emplacement et le temps réel de la poubelle. Le protocole de communication LoRa est utilisé pour transmettre des données sur l'emplacement, le temps réel et le niveau de remplissage de la poubelle. (al., 2020)

2.7.19 (Hain, 2020)

Cet article propose une nouvelle architecture pour un système de gestion des déchets intelligent monté sur des techniques d'intelligence artificielle et se concentre sur l'utilisation combinée de l'Internet des objets (IoT) et des systèmes de surveillance comme technologie d'assistance pour une haute qualité de service (QoS) dans la collecte des déchets. L'intégration

de techniques d'apprentissage profond dans ce secteur afin de réaliser d'importantes réductions de coûts tout en maintenant des performances optimales. (Hain, 2020)

2.7.20 (C. Sirawattananon, 2021)

Cette étude propose un système d'automatisation robotique basé sur des techniques d'apprentissage profond pour aider à assurer un tri correct des déchets dans les catégories de recyclage. Le modèle ResNet-50 a été utilisé pour classifier les déchets. L'entraînement de modèle est fait sur un jeu de données TrashNet et une collection d'images locales contenant environ 5 326 images de quatre catégories différentes de déchets. La précision expérimentale était de 98,81 %. Nous avons développé une poubelle intelligente avec la vision par ordinateur et l'IoT qui peut séparer les déchets automatiquement. La caméra Pi capture plusieurs images des déchets lorsque le capteur de mouvement est déclenché, puis envoie les images au modèle Deep Learning, qui renvoie ensuite la sortie (PET, plastique, métal et déchets) au Raspberry Pi. En fonction de la sortie générée, les déchets sont automatiquement déplacés vers leur poubelle respective à l'aide d'un plateau coulissant motorisé vers le conteneur approprié. Une entreprise sociale universitaire intelligente incite les étudiants à

Gagner des points en triant la quantité de déchets à utiliser pour le rachat de l'université. (C. Sirawattananon, 2021)

Conclusion

Ce chapitre a été une récapitulation terminologique de l'intelligence artificielle, Machine Learning et Deep learning et ces applications dans la chaîne logistique inverse. Cette technologies est devenu la tendance dans le secteur industriel plus spécifiquement dans la chaîne logistique et la nécessité d'informatiser ce processus nous a permis d'utiliser la technologie de Deep Learning ce qui va être expliqué dans le chapitre 3.

Chapitre I I I

Programmation et implémentation du cadre d'étude

3. Introduction

Dans le chapitre précédent ont vu les techniques d'imagerie appliquer dans le secteur industriel afin d'assurer une bonne détection des objets on réfèrent au deep Learning.

L'un des secteurs le plus visés de nos jours est le recyclage vu la consommation massive des individus ce qui entraîne un déséquilibre de la balance et l'obligation de traiter ce problème nous a poussé de proposer d'utiliser le deep Learning pour résoudre cette préoccupation.

Nous avons utilisé la technique de classification (citer précédemment) et puisque la quantité de données fournie est grande donc le deep Learning est le meilleur choix.

3.1 Positionnement du problème

La gestion des déchets est l'un des problèmes critiques aujourd'hui, l'augmentation de la population, des constructions, des industries...etc. Crée une quantité de déchets massive qui seront déversés dans les décharges. Pour résoudre ce problème des divers systèmes sont proposés (Trieur mécanique, trieur optique...etc.), ce qui nous a poussé de proposer cette solution de vision artificielle et de deep Learning afin de séparer les plastiques des cannettes des plastiques...etc. En visant une précision élevée de détection.

3.2 Deep Learning

Les Deep Learning est un ensemble de technique d'apprentissage qui sert a crée un model avec des données en utilisant des architecture neuronales complexes.

La combinaison des buildings blocks d'un réseau de neurone compose le réseau de neurones profonds ce qui a pousser le champ technologique a progresser(reconnaissance faciale, parole, computer vision...etc.)

3.3 Réseau de neurones

Les réseaux de neurones illustre le fonctionnement des neurones du cerveau humain, cette imitation simple aide a trouver la solution a des problèmes complexe grâce au calcule mathématiques. Comme on peut le voir ci dessous

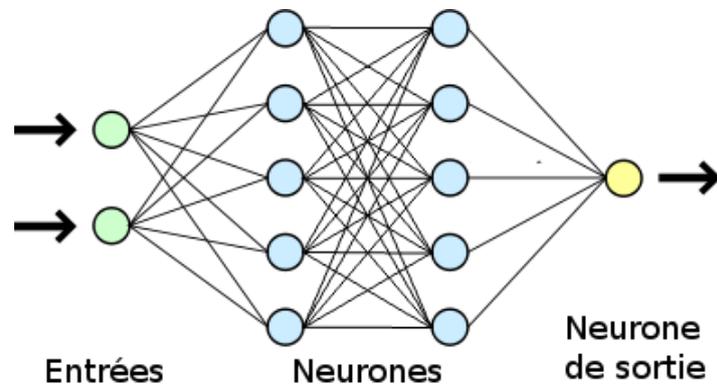


Figure 12:réseau de neurones (Belhaouci)

3.4 Fonctionnement du réseau de neurones (backpropagation algorithm)

L’algorithme backpropagation a été introduit dans les années 1970, mais son importance a été appréciée après la publication d’un article célèbre en 1986 par *David Rumelhart, Geoffrey Hinton et Ronald Williams*. Cet article décrit les réseaux neuronaux où le backpropagation fonctionne plus rapidement que les approches d’apprentissage classiques.

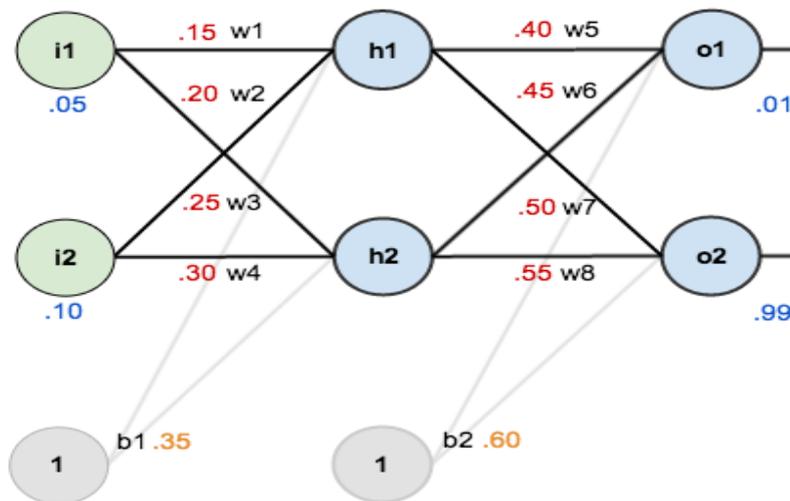


Figure 13: réseau de neurones back propagation (mazur, 2015)

Ou $w_1, w_2 \dots w_8$ sont les poids des neurones
 on initialise notre réseau aléatoirement $i_1 = 0.05$ et $i_2 = 0.10$
 en résultat on doit avoir soit $o_1 \approx 0$ ou bien $o_2 \approx 1$
 les biais se sont l'écart d'erreur

La back propagation c'est une technique qui sert à calculer le gradient d'une fonction afin d'entraîner le réseau de neurones, se calcule est fait pour évaluer le gradient.

L'algorithme de back propagation se déroule de la manière suivante :

- a) On applique l'algorithme pour calculer la valeur de la fonction d'activation de chaque nœud (seulement la valeur et non pas le gradient).
- b) Ensuite on recalcule dans le sens inverse, mais cette fois les dérivées partielles de f par rapport au poids des nœuds w

I. La première phase est de calculer la propagation en avant.

1. On cherche à trouver la valeur de chaque neurone. On calcule les valeurs de **h1**, **h2**, **o1**, **o2** en utilisant les deux entrées dans la figure précédente.

Où le total net est la valeur de neurone dans le réseau

Par exemple:

$$h1 = i1 * w1 + i2 * w2 + b1 \tag{1.1}$$

$$h2 = i1 * w3 + i2 * w4 + b1 \tag{1.2}$$

2. Ensuite, la fonction d'activation (sigmoïde) est la valeur qui va circuler dans le réseau.

Par exemple :

$$f(h1) = \frac{1}{1 + e^{-h1}} \tag{1.3}$$

En utilisant cette fonction on calcul o1 et ainsi de suite

	Total net (Net)	Fonction d'activation (f)
h1	0.3775	0.5932699
h2	0.3925	0.5968843
o1	1.1059	0.7513
o2	1.1951	0.7729

Tableau 1: le calcul des valeurs du réseau de neurone

II. La deuxième phase consiste à calculer l'erreur totale.

$$E_{total} = \sum \frac{1}{2} (la\ cible - resultat)^2$$

(1.4)

Ou $\left\{ \begin{array}{l} la\ cible\ est\ la\ valeur\ qu'on\ veut\ atteindre \\ resultat\ est\ la\ valeur\ qu'on\ eu\ apres\ le\ calcul \end{array} \right.$

3. On calcul l'erreur de chaque sommet en revenant en arriere de o1 et o2 (a partir des valeurs citer dans le graphe précédent) ainsi l'équation est donné par la formule suivant

$$E_{o1} = \sum \frac{1}{2} (0.01 - 0.7513)^2$$

(1.5)

$$E_{o1} = 0.2748$$

Et la même chose pour o2

$$E_{o1} = \sum \frac{1}{2} (0.99 - 0.7729)^2$$

(1.6)

$$E_{o1} = 0.0235$$

4. L'erreur totale :

$$E_{total} = E_{o1} + E_{o2}$$

(1.7)

$$E_{total} = 0.2748 + 0.0235$$

$$E_{total} = 0.2983$$

III. Propagation en arriere

On cherche à mesurer l'impact de chaque poids des neurones sur l'erreur total donc on calcul l'ajustement de chaque poids par le dérivé partiel de l'erreur total par apport au poids des neurones \mathbf{W} .

$$\frac{\partial E_{total}}{\partial w} \tag{1.8}$$

On prend un exemple d'o1 :

$$\frac{\partial E_{total}}{\partial w} = \frac{\partial E_{total}}{\partial f(o1)} * \frac{\partial f(o1)}{\partial net\ o1} * \frac{\partial net\ o1}{\partial w5} \tag{1.9}$$

On peut la visualiser le calcul dans ce graphe.

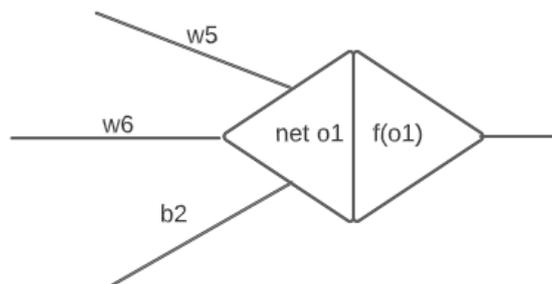


Figure 14: explication de calcul backpropagation

1. Premièrement, on cherche à connaître l'impact total sur le résultat.

$$E_{total} = \frac{1}{2} (cible_{o1} - f_{o1})^2 + \frac{1}{2} (cible_{o2} - f_{o2})^2 \tag{1.10}$$

$$\frac{\partial E_{total}}{\partial f_{o1}} = 2 * \frac{1}{2} (cible_{o1} - f_{o1})^{2-1} * (-1) + 0 \tag{1.11}$$

$$\frac{\partial E_{total}}{\partial f_{o1}} = -(cible_{o1} - f_{o1}) = -(0.01 - 0.7513) = 0.7413 \tag{1.12}$$

2. Ensuite on calcul l'impact de f_{o1} sur l'entrée net

$$f_{o1} = \frac{1}{1 + e^{-net_{o1}}} \quad (1.13)$$

$$\frac{\partial f_{o1}}{\partial net_{o1}} = f_{o1}(1 - f_{o1}) \quad (1.14)$$

$$\frac{\partial f_{o1}}{\partial net_{o1}} = 0.7513(1 - 0.7513) \approx 0.1868$$

3. Enfin on calcul l'impact du total net de o1 sur w5

$$net_{o1} = w5 * f_{h1} + w6 * f_{h2} + b2 * 1 \quad (1.15)$$

$$\frac{\partial net_{o1}}{\partial w5} = 1 * f_{h1} * w5^{1-1} + 0 + 0 = f_{h1} = 0.5932$$

Alors :

$$\frac{\partial E_{total}}{\partial w5} = \frac{\partial E_{total}}{\partial f_{o1}} * \frac{\partial f_{o1}}{\partial net_{o1}} * \frac{\partial net_{o1}}{\partial w5} \quad (1.16)$$

$$\frac{\partial E_{total}}{\partial w5} = 0.7413 * 0.1868 * 0.5932 = 0.0821$$

4. Pour diminuer l'erreur, on soustrait cette valeur du poids actuel.

$$w5^+ = w5 - \mu * \frac{\partial E_{total}}{\partial w5} \quad (1.17)$$

Ou $\mu = 0.5$ par défaut

$$w5^+ = 0.4 - 0.5 * 0.0821 \approx 0.35891$$

5. On répète cette opération avec w6, w7 et w8 :

$$w6^+ \approx 0.40866$$

$$w7^+ \approx 05113$$

$$w6^+ \approx 0.5613$$

6. Et on remplace les poids originaux par ces valeurs actuels.

IV. On passe après à la deuxième couche et on calcul $w1$, $w2$, $w3$ et $w4$; on doit trouver la valeur de :

$$\frac{\partial E_{total}}{\partial w1} = \frac{\partial E_{total}}{\partial f_{h1}} * \frac{\partial f_{h1}}{\partial net_{h1}} * \frac{\partial net_{h1}}{\partial w1} \quad (1.18)$$

1. On va faire le même processus que la couche précédente, on calcul : $\frac{\partial E_{total}}{\partial f_{h1}}$

$$\frac{\partial E_{total}}{\partial f_{h1}} = \frac{\partial E_{o1}}{\partial f_{h1}} + \frac{\partial E_{o2}}{\partial f_{h1}} \quad (1.19)$$

$$\left\{ \begin{array}{l} \frac{\partial E_{o1}}{\partial f_{h1}} = \frac{\partial E_{o1}}{\partial net_{o1}} * \frac{\partial net_{o1}}{\partial f_{h1}} \\ \frac{\partial net_{o1}}{\partial f_{h1}} = w5 = 0.40 \\ \frac{\partial E_{o1}}{\partial f_{h1}} = \frac{\partial E_{o1}}{\partial net_{o1}} * \frac{\partial net_{o1}}{\partial f_{h1}} = 0.1384 * 0.40 = 0.0553 \end{array} \right. \quad (1.20)$$

2. On suit les mêmes procédures pour $\frac{\partial E_{o2}}{\partial f_{h1}}$ on obtient : $\frac{\partial E_{o2}}{\partial f_{h1}} = -0.019$

$$\text{Alors : } \frac{\partial E_{total}}{\partial f_{h1}} = \frac{\partial E_{o1}}{\partial f_{h1}} + \frac{\partial E_{o2}}{\partial f_{h1}} = 0.0553 + (-0.019) = 0.0363$$

En utilisant $\frac{\partial E_{total}}{\partial f_{h1}}$, $\frac{\partial f_{h1}}{\partial net_{h1}}$ et $\frac{\partial net_{h1}}{\partial w}$ on calcule pour chaque poids :

$$f_{h1} = \frac{1}{1+e^{-net_{h1}}} \quad (1.21)$$

$$\frac{\partial f_{h1}}{\partial net_{h1}} = f_{h1}(1 - f_{h1}) \quad (1.22)$$

$$\frac{\partial f_{h1}}{\partial net_{h1}} = 0.5932 * (1 - 0.5932) = 0.2413$$

On calcule la dérivée partielle de l'entrée totale de h1 par apport au w1 comme le calcul précédent.

$$net_{h1} = w1 * i1 + w3 * i2 + b1 * 1 \quad (1.23)$$

$$\frac{\partial net_{h1}}{\partial w1} = i1 = 0.05$$

Mettre toute en place :

$$\frac{\partial E_{total}}{\partial w1} = \frac{\partial E_{total}}{\partial f_{h1}} * \frac{\partial f_{h1}}{\partial net_{h1}} * \frac{\partial net_{h1}}{\partial w1} \quad (1.24)$$

$$\frac{\partial E_{total}}{\partial w1} = 0.0363 * 0.2413 * 0.05 \approx 0.0004$$

Donc on peut actualiser la valeur de w1 :

$$w1^+ = w1 - \mu * \frac{\partial E_{total}}{\partial w1} = 0.15 - 0.5 * 0.0004 \approx 0.14978$$

On répète les mêmes procédures pour w_2 , w_3 et w_4 :

$$w_2^+ \approx 0.1995$$

$$w_3^+ \approx 0.2497$$

$$w_4^+ \approx 0.2995$$

Finalement, nous avons trouvé tous les nouveaux poids, lorsque nous avons transmis les entrées 0.05 et 0.1 à l'origine, l'erreur du réseau était de 0.2983. Après ce premier tour de back propagation, l'erreur totale maintenant est réduite jusqu'à 0.2910, cela peut sembler peu, mais après avoir répéter ce processus 10 000 fois par exemple, l'erreur peut tomber à 0.000035.

À ce stade, lorsqu'on transmet 0.05 et 0.1, les deux neurones de sortie génère 0.015 (par apport a la cible 0.01) et 0.984 (par apport à la cible 0.99).

3.5 Les types d'architectures des réseaux de neurones

Il existe plusieurs types d'architecture pour les réseaux de neurones :

- Les perceptrons multicouches qui sont les plus anciens et les plus simples
- Les réseaux de neurones convolutifs (CNN) particulièrement adaptés au traitement des images
- Le réseau de neurones récurrents, utilisés pour les données séquentielles telles que les textes ou les séries chronologiques

3.5.1 Le perceptron multicouches

Le perceptron multicouche est un réseau orienté de neurones artificiels organise en couches et ou l'information voyage dans un seul sens, de la couche d'entrée vers la couche de sortie.(Parizeau 2004)

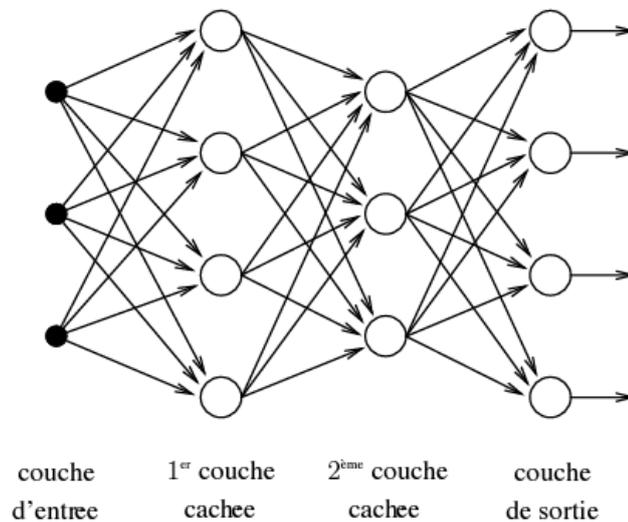


Figure 15:Exemple d'un réseau de type perceptron multicouche

Cette figure illustre les couches d'un réseau de neurone contenant une couche d'entrée, deux couches cachées et une couche de sortie. la couche d'entrée représente la couche virtuelle de l'entrée du système (elle ne contient aucun neurone), dans le cas général un perceptron multicouche possède un nombre de couche aléatoire. (Parizeau 2004)

Les relations entre les neurones sont avec un arc pondérer. Le fonctionnement du réseau neuronal est dirigé par ces poids.

3.5.2 Le réseau de neurones récurrent (RNN)

Un réseau de neurone récurrent est constitué d'un cycle de graphe neuronal, le principe de ce type d'architecture est de pouvoir manipuler des séquences de vecteurs d'entrée, chaque séquence représente un événement temporel et pas seulement de données discrètes. Ce type de réseau peut être classifié comme une séquence temporaire de réseaux MLP (perceptron multicouches) qui sont en contact avec leurs couches cachées respectives. (BOUAZIZ, 2017)

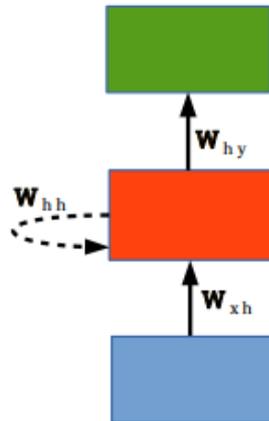


Figure 16:représentation compact des RNN (Bouaziz., 2017)

Suivant cette modélisation, un RNN prend :

$$\begin{cases} x = (x_1, x_2, \dots, x_T) \text{ comme entrée ces séquences d'événements} \\ h = (h_1, h_2, \dots, h_T) \text{ séquence d'états cachés} \\ y = (y_1, y_2, \dots, y_T) \text{ en itérant de } t = 1 \text{ à } T \text{ produit en sortie} \end{cases}$$

Et pour calculer les poids de neurone, on suit ces formules :

$$\begin{cases} ht = H(Wxh * xt + Whh * ht - 1 + bh) \\ yt = Why * ht + by \end{cases}$$

CITATION Moh17 \l 1036 (BOUAZIZ 2017)

$$\text{ou } \left\{ \begin{array}{l} T \text{ est le nombre total de vecteurs d'entrée} \\ W \text{ est la matrice de poids entre les couches} \\ bh \text{ est le vecteur de biais de la séquence d'état caché} \\ \text{La fonction } H \text{ utilisée dans le cas des RNN est généralement la tangente} \\ \text{hyperbolique (tanh)} \end{array} \right.$$

3.5.3 Le réseau de neurone convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) sont originellement venus de la nature, en particulier de la structure du cortex visuel (Dean 2014), ils constituent un réseau de neurones multicouches puissant.

Une image en niveaux de gris, par exemple, est une matrice en 2D. L'introduire dans un réseau entièrement connecté conduira à une explosion du nombre de connexions et de poids du réseau. (D. C. Cireşan 2011), Les réseaux de neurones convolutionnels (CNN) abordent ce problème de calcul en utilisant une sorte de méthode de base appliquée dans une couche supérieure. En fait, contrairement aux réseaux à connexions multiples où chaque neurone est

Connecté à tous ses prédécesseurs, chaque neurone des réseaux de neurones convolutifs est connecté à une sous-division locale des neurones de la couche inférieure. La taille de la région formée par ce sous-ensemble de neurones est un hyper paramètre CNN.(J. Snoek 2012)

Un autre avantage des CNN est leur capacité à introduire un certain degré d'invariance de décalage, d'échelle et de distorsion dans le processus d'apprentissage.(Y. LeCun 2001)

En fait, dans le cas d'une tâche de classification d'images par exemple, et puisque les images sont des structures 2D, la position des objets classifiés dans l'image peut varier considérablement. L'entraînement d'un réseau typique entièrement connecté pour reconnaître les configurations spatiales des objets conduira à un nombre croissant de paramètres et d'instances d'entraînement. En raison de la répétition des paramètres et puisque nous devons couvrir toutes les combinaisons et variations possibles des positions des objets pendant le processus d'apprentissage.(Y. LeCun 2001)

Les CNN résolvent ce problème en forçant l'extraction de caractéristiques locales en limitant le champ réceptif de l'unité cachée à des caractéristiques locales.(Y. LeCun 2001)

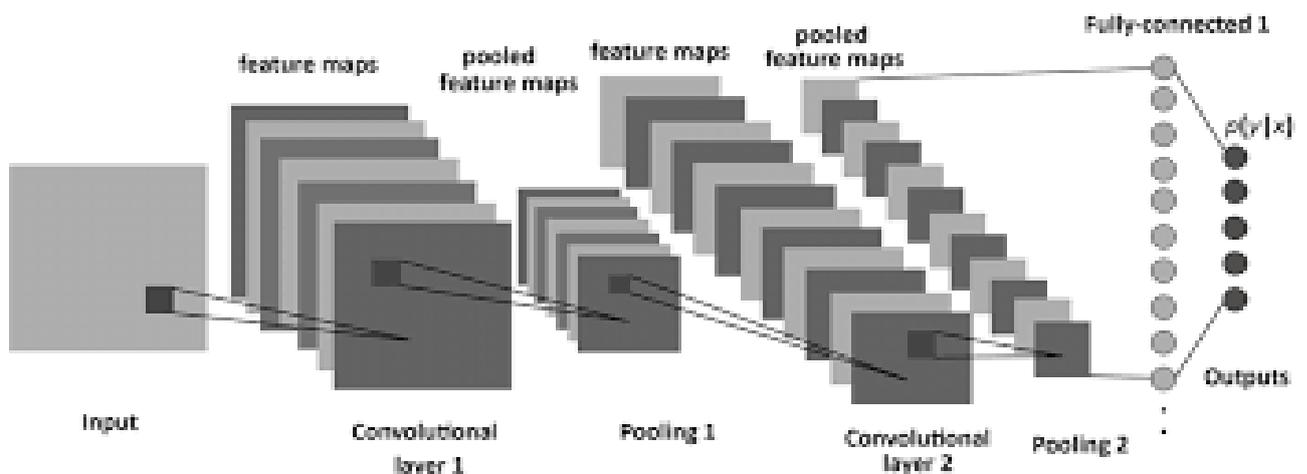


Figure 17: réseau de neurones convolutifs (blanc-durand, 2018)

3.6 Pourquoi choisir CNN ?

Un réseau CNN est composées de couches dédiés a extraire les caractéristiques directement de la base de données. Son architecture est adaptées au traitement et classification des images ; les réseaux de neurones légitimes éliminent l'exploration manuelle des caractéristiques qui est souvent une étape fastidieuse.les fonctionnalités utilisées ne sont pas pré-entraînées (c.à.d que le réseau les traite tout seul en s'entraînant sur l'image). (Houacine Noura 27/09/2018)

Cette fonctionnalité automatique prouve que les CNN sont le meilleur choix pour une classification de performances élevées.

3.7 L'architecture d'un réseau de convolution

Le réseau de neurones convolutifs s'appuie sur la notion de perceptron multicouche. Cette architecture a été inspirée du cortex visuel des vertébrés (une partie du cerveau), bien que le perceptron multicouche soit efficace pour le traitement d'image, il est difficile de traiter un grand nombre d'images car le nombre de liaisons augmente par une fonction exponentielle selon la taille d'image. (IMENE 2018/2019).

L'architecture d'un réseau neuronal convolutif peut différer selon les types et le nombre de couches incluses. Dans une architecture CNN classique, plusieurs couches sont empilées un nombre spécifique de fois. (Guedria. 2020)

3.7.1 Les couches d'un réseau convolutionnel

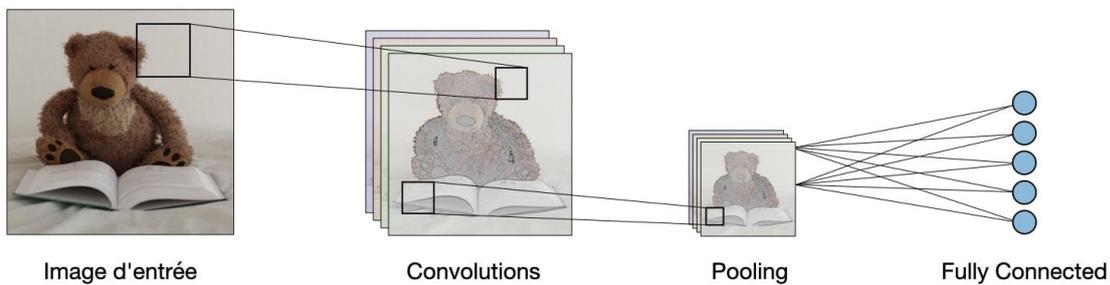


Figure 18: les couches d'un réseau de neurones convolutionnel (Amidi)

La couche d'entrée (Input layer : en anglais)

Dans les CNN, la couche d'entrée initiale a la taille des images brutes et retient leurs valeurs en pixels. (Hertz 1992) ; il a les dimensions suivantes : largeur (w), hauteur (h) et profondeur (d). La profondeur de l'animation est le nombre de ses canaux de couleur. (Guedria. 2020)

La couche de convolution

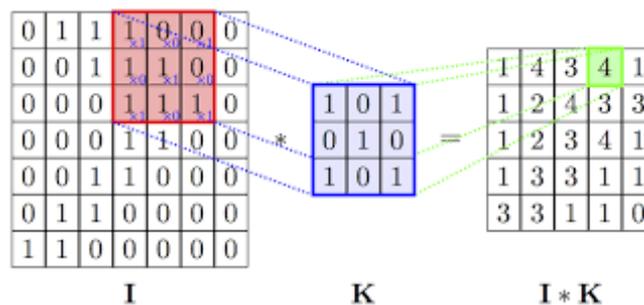


Figure 19: l'opération de convolution

Par exemple, le 4 est obtenu de cette manière.

$$(1) * (1) + (0) * (0) + (0) * (1) + (1) * (0) + (1) * (1) + (0) * (0) + (1) * (1) + (1) * (0) + (1) * (1) = 4$$

Et ainsi de suite pour les autres éléments de notre image.

La couche convolutionnelle est le principal élément constitutif d'un CNN qui effectue la plus lourde charge de travail de calcul (R. Adorf 2016). En fait, elle s'appuie sur l'opération mathématique de convolution, qui est une procédure intensive en termes de calcul, prenant deux fonctions d'entrée, $f()$ et $g()$ par exemple, et en renvoyant une troisième (par exemple h).

L'opération de convolution exprime l'étendue du chevauchement entre la première fonction (f) lorsqu'elle est glissée sur la seconde (g). (H. Wang 2017)

Une couche d'involution comporte plusieurs filtres (ou noyaux) de taille égale. Les filtres ont des dimensions plus petites que les images d'entrée. L'opération de convolution dans les CNN consiste à aligner ces filtres et les patches d'images d'entrée correspondants (ou champ réceptif par le pixel de filtre correspondant). Ensuite, le filtre glisse (ou convoluté) dans les directions de l'image d'entrée (verticalement et horizontalement) En calculant le produit scalaire. La taille du pas avec lequel il avance est un hyper paramètre connu sous le nom de stéride. Ce processus est répété avec tous les filtres pour toutes les images d'entrée, et les volumes de sortie produits par les opérations de convolution sont connus comme les cartes de caractéristiques. L'objectif principal de l'opération de convolution dans les CNN est d'extraire les caractéristiques visuelles du volume d'entrée. En fait, la convolution vise à rechercher toutes les correspondances possibles entre les filtres et les champs réceptifs. Ce processus permettra au CNN d'apprendre à reconnaître certains modèles locaux dans les images d'entrée lorsque les filtres sont activés chaque fois qu'ils identifient un type de caractéristique visuelle comme des bords orientés. Ceci explique également la raison de l'utilisation de filtres multiple. En fait, par différents choix de noyaux, différentes caractéristiques visuelles peuvent être identifiées. Enfin, les cartes de caractéristiques sont empilées dans la dimension de la profondeur pour générer le volume de sortie qui constitue l'entrée de la couche suivante dans l'architecture CNN. Réceptifs). L'étape suivante consiste à multiplier chaque pixel du champ. (Y. LeCun 2001)(LeCun and Y. Bengio 1998)(Bengio 2009)(Y. B. Y. LeCun 2015)(S. Lawrence 1997)

La couche de mise en commun (pooling layer)

Au rôle principal est de réduire progressivement les dimensions spatiales des cartes de caractéristiques d'entrée. Cela permet donc de diminuer la quantité de paramètres du réseau, ce qui réduit le temps d'apprentissage et permet de contrôler l'overfitting. L'opération de dés échantillonnage est effectuée en utilisant la couche de mise en commun sur chaque carte de caractéristiques séparément. Elle réduit leur hauteur et leur largeur sans affecter la profondeur. Différentes fonctions de mise en commun peuvent être utilisées dans la couche de pooling, telles que la maxpooling et average pooling. Cependant, l'opération la plus populaire est le maxpooling, comme on peut voir dans la figure ci-dessous le sous-échantillonnage est effectué avec un filtre de taille 2x2 appliqué avec un stéride de 2. Avec le filtre de mise en commun maximale, la couche de mise en commun conserve les pixels ayant les valeurs maximales dans chaque volume d'entrée. Alors qu'avec le

Filtre de mise en commun moyenne, elle calcule la moyenne de chaque volume d'entrée.(A. Krizhevsky 2012)(L. B. Y. LeCun 2001)(LeCunandY.Bengio 1998)

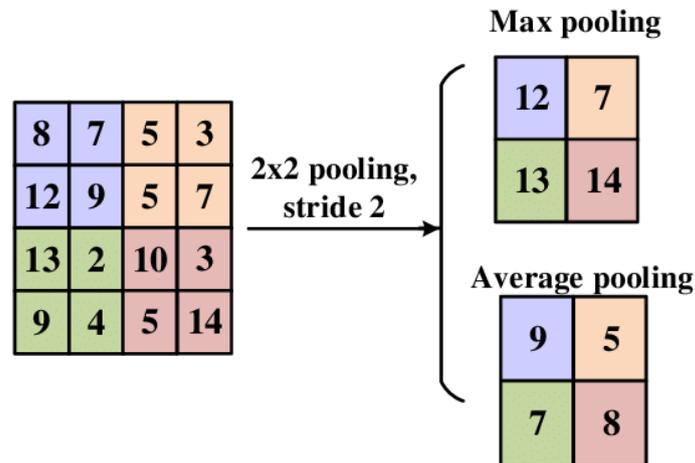


Figure 20:l'opération de la mise en commun (Shafique, 2020)

La couche entièrement connectée (fully connected layer)

Les neurones de la couche entièrement connectée sont connectés à tous les neurones de la couche précédente. La couche entièrement connectée est généralement la couche finale utilisée pour effectuer des tâches de classification avec un CNN. En fait, la valeur de chaque neurone dans la couche entièrement connectée indique un score de classification pour une classe spécifique.(A. Krizhevsky 2012)(L. B. Y. LeCun 2001)

3.8 Les architecture classique du CNN

Dans la section précédente, on a cité brièvement les architectures des CNN, et la plupart de ces architectures partagent la même directive de conception les principes fondamentaux de l'empilement répété presque les même composant des couches ; on commence par une couche convolutive à l'entrée (Input layer) brute pour extraire les caractéristiques suivies d'une couche de pooling qui sert à réduire l'étendue dimensionnelle des cartes de caractéristique d'entrée. Les principales architectures influentes sont devenues notoires en remportant la compétition de détection des objets à grande échelle ImageNet.

3.8.1 LeNet

C'est l'architecture pionnière des réseaux de neurones convolutifs qui a été introduite par Yann Lecun en 1998. Ce premier CNN a été utilisé avec succès pour reconnaître et classer les chiffres de la base de données MNIST.(LeCunandC.Cortes. 2010)

Il a été conçu spécifiquement pour les services postaux afin de pouvoir lire les codes postaux écrits à la main.

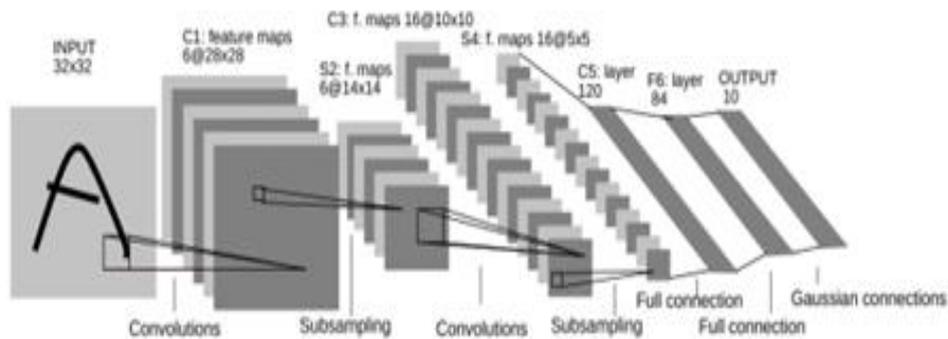


Figure 21: Le-Net architecture (MuhammadRizwan, 2018)

Comme on peut le voir sur cette figure, LeNet-5 prend une image d'entrée à canal unique de taille 32 x 32, effectue une convolution avec six noyaux 5 x 5 avec un stérade de un, puis applique une couche de sous-échantillonnage 2 x 2 max poolings. Cette séquence convolution-sous-échantillonnage est répétée une autre fois avant de se terminer par deux couches entièrement connectées et une couche finale de classification soft max entièrement connectée de taille 10 pour produire le résultat. LeNet-5 a un total de 60 850 paramètres.(L. B. Y. LeCun 2001)

3.8.2 Alex-Net

Alex-Net a été introduit par Alex Krizhevsky et al. En 2012 et représente l'une des principales architectures contribuant au développement récent des CNN. Cette architecture a remporté la compétition ImageNet(O. Russakovsky Dec. 2015)

De 2012 en dominant largement les autres approches traditionnelles de vision par ordinateur (une erreur dans le top 5 de 15,3 % avec 10,8 points d'avance sur le second). Cette percée majeure a être populaire sur l'aspect puissant des CNN, et a donc contribué au développement d'une meilleure architecture CNN à l'avenir. En fait, comme l'illustre la figure ci dessous, l'architecture d'Alex-Net est assez similaire à celle de LeNet-5. Bien qu'il s'agisse d'un réseau plus profond avec 5 couches convolution elles, des couches de sous-échantillonnage, des couches d'exclusion et 3 couches entièrement connectées. De plus, la méthode ReLU.(Hinton 2010)

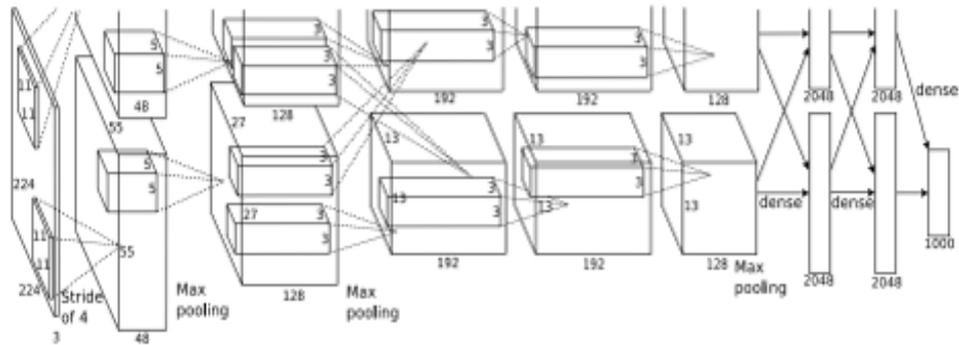


Figure 22: Alex-Net architecture (Noël De Palma, 11/2020)

La fonction d'activation a été appliquée pour introduire la non-linéarité et le décrochage. (N. Srivastava 2014) Une technique de régularisation a été appliquée pour éviter les sur ajustements. La taille de l'ensemble de données a été augmentée par la technique d'augmentation des données (Wang 2017), Comme AlexNet est un CNN plus profond avec 60 millions de paramètres, la formation a été divisée en deux flux et a été effectuée en utilisant deux GPU GTX580 afin de réduire le temps d'exécution du processus de formation coûteux en calcul. (Guedria. 2020)

3.8.3 GoogleNet

A été développé par Szegedy et al. En 2014. Ce CNN introduit par les chercheurs (Guedria. 2020) Chez Google s'est essentiellement inspiré d'Alex-Net et a remporté les défis de classification et de détection de l'ILSVRC 2014 avec un taux d'erreur de 6,7 % dans le top 5. GoogLeNet possède 22 couches et a introduit un nouveau concept connu sous le nom de module d'initiation qui a diminué la quantité de paramètres dans le réseau (4 millions de paramètres, soit 12 fois moins de paramètres qu'AlexNet).

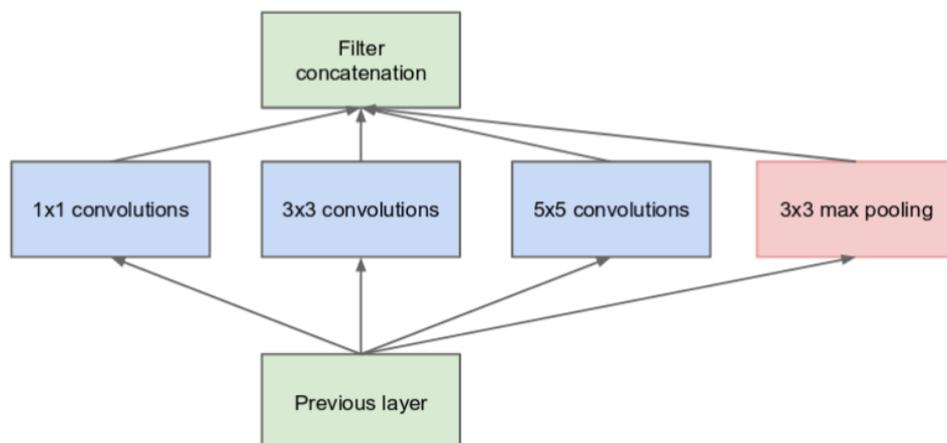


Figure 23: Inception module (Alto, 2020)

Les modules de démarrage sont inspirés de l'architecture Network-in-Network (M.Lin 2013) et sont empilés plusieurs fois les uns sur les autres dans le réseau. Le module de démarrage consiste à appliquer une séquence parallèle multi-échelle de convolutions avant d'agréger les résultats à la fin. En fait, l'application de convolutions à différentes échelles permet à GoogLeNet d'extraire également des caractéristiques multi-échelles. Le module d'initialisation contient également des convolutions 1x1 qui sont exécutées afin de réduire la profondeur du canal du module d'initialisation et d'économiser les calculs. Il existe plusieurs versions de suivi du module d'Inception (C. Szegedy CoRR, abs/1602.07261, 2016.)[C. Szegedy 2015.)

3.8.4 Res-Net

Le réseau Deep Residual Network (ResNet) est un CNN qui a été introduit par KaimingHeetal.(K. He 2015.)De Microsoft Research en 2015. ResNet est un CNN ultra profond (152 couches). En fait, augmenter la profondeur du réseau en ajoutant naïvement plus de couches conduit à de moins bons résultats. Elle s'appelle le problème de dégradation. L'architecture ResNet a repoussé les limites de profondeur des CNN précédemment introduits sept fois plus loin en introduisant un bloc résiduel qui résout le problème de dégradation (K. He 2015.)

L'idée qui sous-tend le bloc résiduel est illustrée à la figure ci-dessous, en plus du chemin de calcul classique suivi par l'entrée d'une certaine couche, le bloc résiduel offre une connexion de saut qui permet de contourner le chemin classique et de transmettre l'information directement à la sortie.

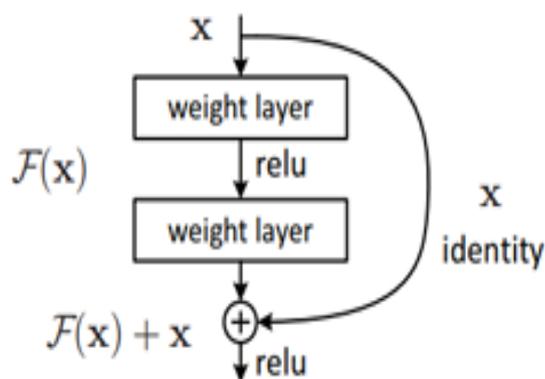


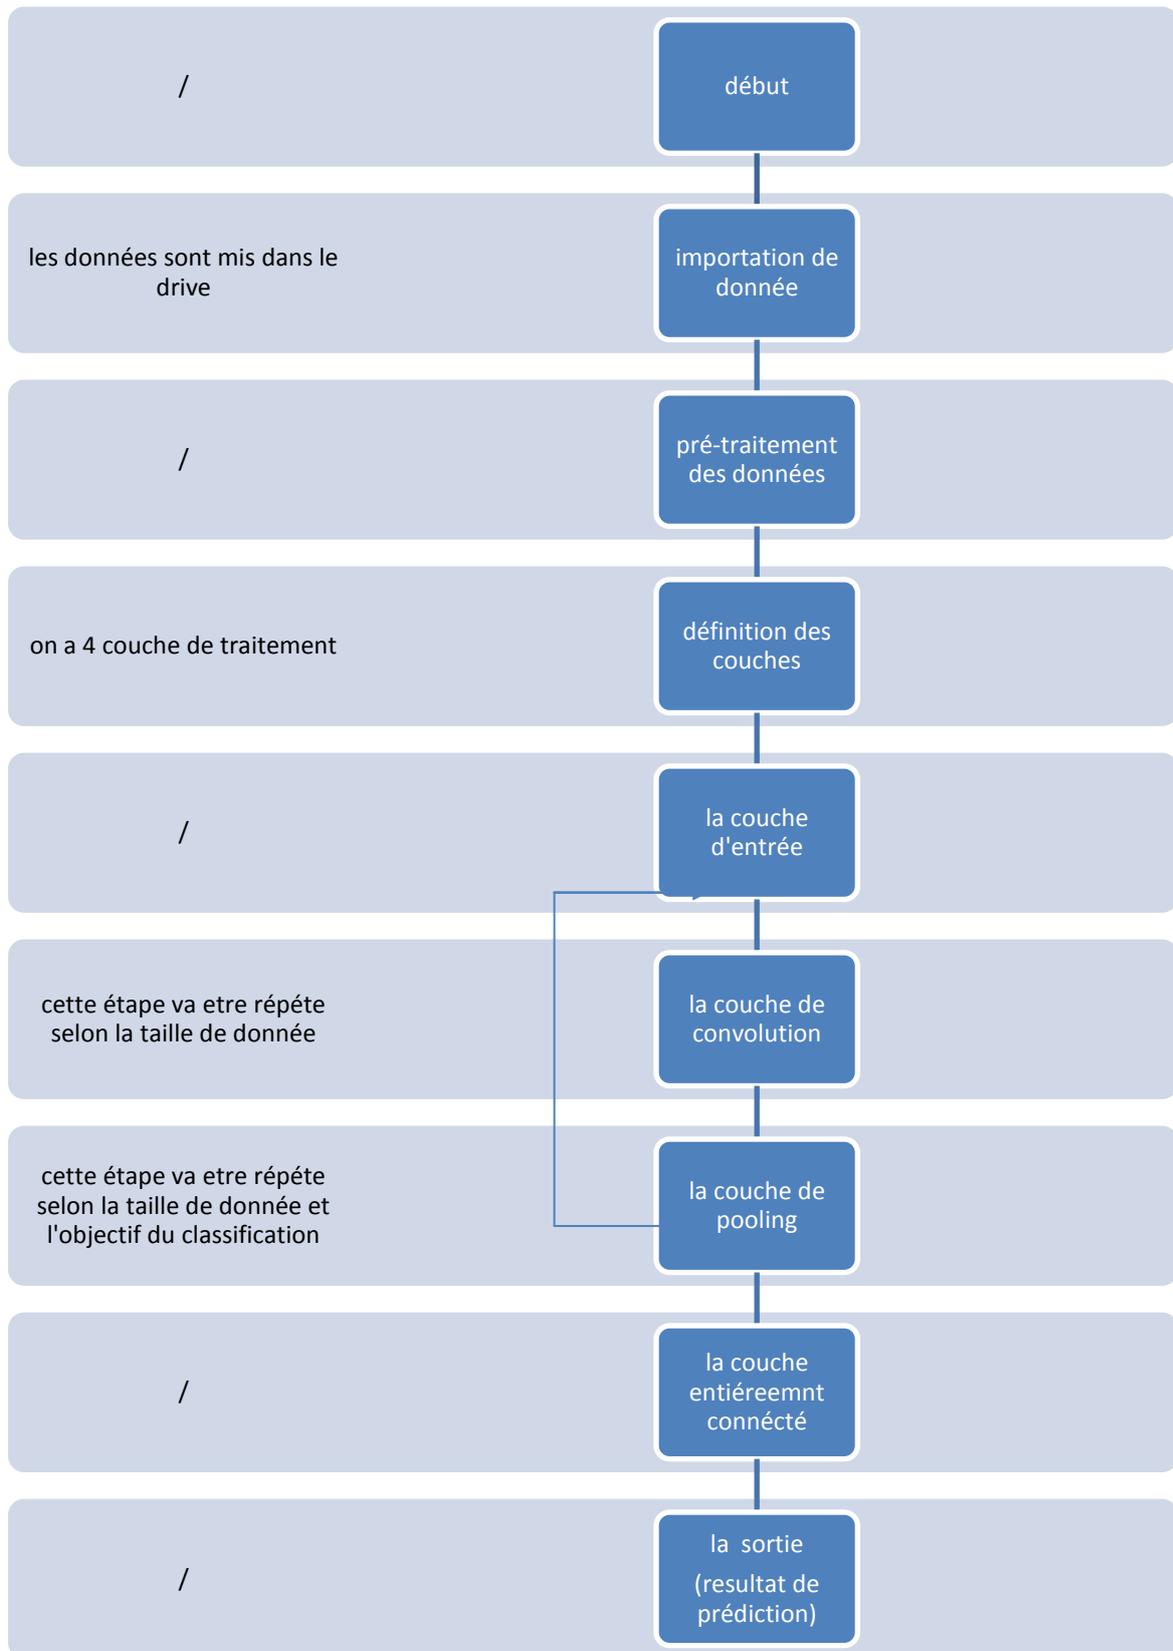
Figure 24:les blocs résiduels (pawangfg, 2020)

Ce processus réduit la perte d'information pendant les calculs du gradient et résout donc le problème du gradient évanescent. De plus, puisque l'information est conservée tout au long des calculs, les blocs résiduels offrent une résilience à la suppression des couches. (Guedria, 2020)

3.9 Organigramme de l'algorithme

Pour notre problème, on a choisi le Res-Net comme architecture, car elle permet d'assurer une fluidité de transmission d'informations d'un bloc à un autre.

Au début de notre algorithme, on va importer notre base de données à partir de Google drive pour permet les traiter ensuite, on passe à la phase de prétraitement des images le but de cette étape est de normaliser la taille des images et les batcher qui va nous permet d'accélérer le processus de classification. La phase de convolution va être définir juste après ou on crée les couches en utilisant la bibliothèque Pytorch : la couche d'entrée, la couche de pooling et la couche entièrement connecté ; et en finit par l'entraînement de notre réseau de neurones qui va sembler a un compilement ensuite prédire.



3.10 Les outils utilisés pour la programmation

Réussir un projet d'Intelligence artificielle nécessite des matériels et des outils performants ce qui nous empêche de trouver les meilleurs outils en terme de traitement des données.

3.11 Les logiciels

Nous avons choisi comme environnement de programmation le logiciel python et pour afficher le résultat Google Colab

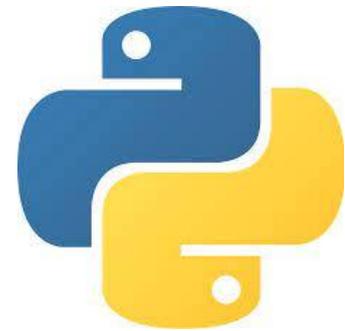
Python

Ce langage de programmation a été développé par Guidovan Rossum en 1989. Elle s'est appelée Python d'après la série télévisée « Flying Circus ».

La premier version sortie en 1991 (Poulain, 21/05/2022)

La dernière version 3.7 été en 2018.

« La Python software Foundation » est une association qui assure le développement de Python et dynamise la communauté des développeurs.



Pourquoi choisir Python ?

- Il marche sur plusieurs systèmes d'exploitation (Linux, Windows, MacOS, Android...etc.)
- Il est gratuit. Disponible sur le site officiel de python (dernière version)
- Nous n'avons pas besoin d'un compilateur car c'est un langage interpréter
- C'est un langage de haut niveau
- C'est possible de créer des entités mimant celles de monde réel avec un certain nombre de règles de fonctionnement car il est orienté objet
- simple a maitrisée
- Il est puissant
- Il contient les bibliothèques et les fonctions souvent utiliser pour facilité la programmation des grands projets (au lieu de les reprogrammer à nouveau)

Google colab

« Google colab » est un outil qui a été



Développé par Google afin d'accéder a notebook.

Notebook est une technologie intuitive.

Utilisé pour apprendre un langage de programmation, et viens du projet *jupyter-notebook* qui est aussi pour l'objectif de l'apprentissage de programmation.

Google colab permet de programmer le langage python dans le navigateur

- Il ne nécessite pas une configuration
- Facile à partager
- Donnent l'accès a des GPU de très grande capacité ce qui nous permet de d'introduire un très grand nombre de données et les exécutés en parallèles sans bloqué
- Il a été conçu pour les chercheurs d'IA

3.12 Les bibliothèques

NumPy

C'est la bibliothèque primordial de Python, elle permet de travailler avec des tableaux de grande dimension(les opérations arithmétique, les conversions...etc.).

Pandas

Cette bibliothèque permet de représenter clairement les données et les personnalisées ce qui aide et facilite accessibilité a ces données.

Matplotlib

Cette bibliothèque permet de représenter visuellement les résultat par un graphique ou un tracé...etc.

Pytorch

C'est une bibliothèque open source développé par Meta, développé en python pour les réseaux de neurones.et son infrastructure de deep Learning taillée pour déploiement et capable de manipuler les algorithmes d'apprentissage intégrant jusqu'à des dizaines de milliards de paramètre.

Cette bibliothèque sert à calculer le gradients ou à utiliser les tableaux multidimensionnels obtenus grâce a des tenseurs.

3.13 Visualisation des résultats

Dans ce programme on cherche à détecter la nature du déchets a partir d'une image (capturer précédemment) ; afin de le faire nous devons passer par les étapes suivantes :

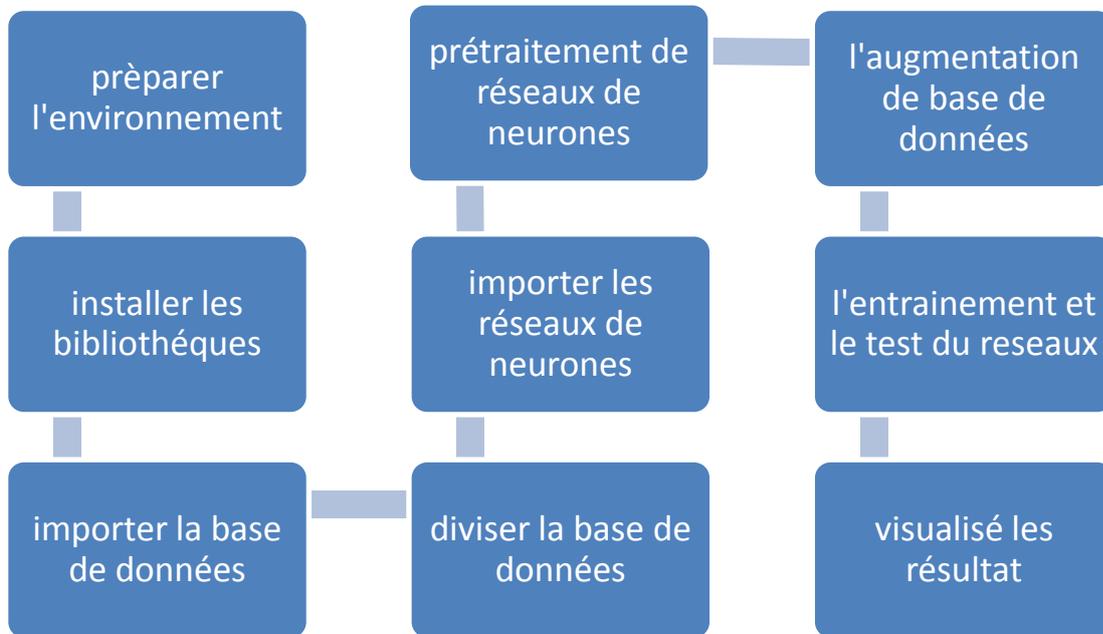


Figure 25: les étapes pour visualiser les résultats

3.13.1 Préparer l'environnement

Tout d'abord nous allons connecter à GPU comme ça :

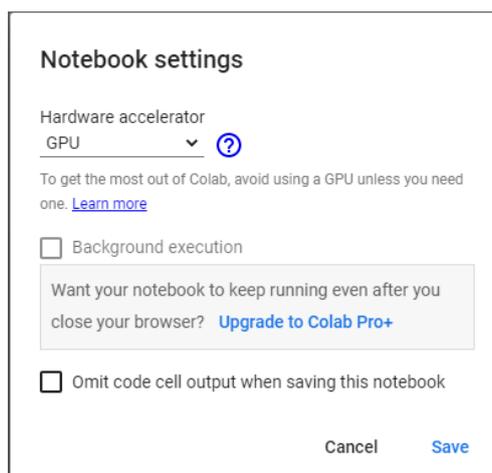


Figure 26: connecter avec GPU

Ensuite on vérifie la version de Pytorch

```
[44] import torch
      print("Using torch", torch.__version__)

Using torch 1.11.0+cu113
```

Figure 27: version de Pytorch

3.13.2 Installer les bibliothèques

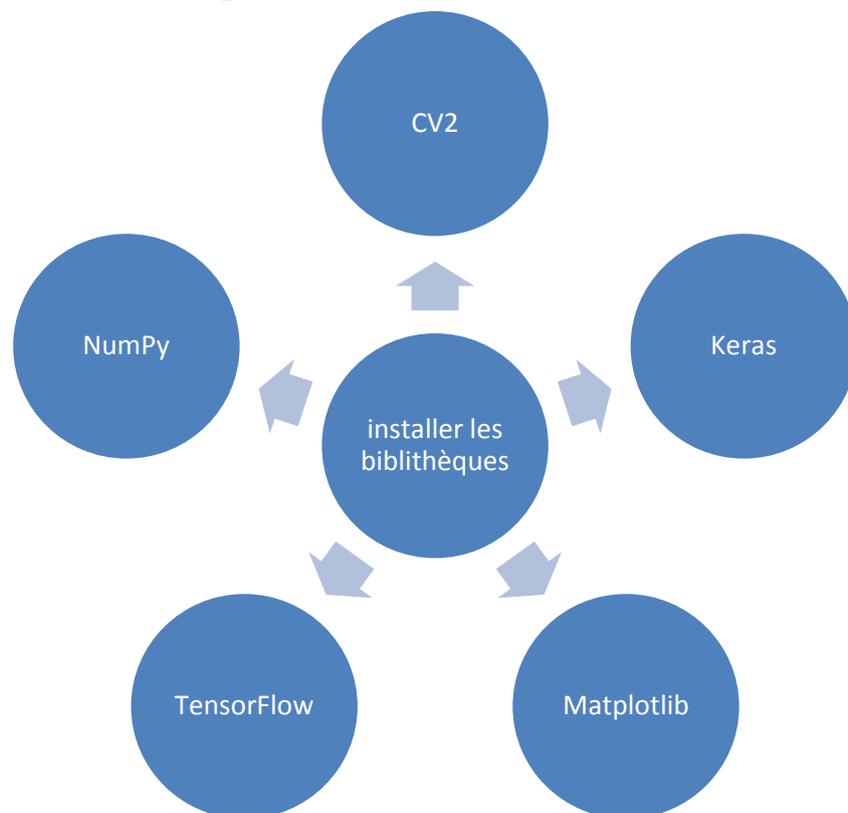


Figure 28: les bibliothèques installées

Nous allons importer les bibliothèques préinstallées sous colab par cette ligne d'instruction

```
[2] import torch
import numpy as np
%matplotlib inline
%config InlineBackend.figure_format = 'retina'

import matplotlib.pyplot as plt

import torch
from torch import nn
from torch import optim
import torch.nn.functional as F
from torchvision import datasets, transforms, models
import random,os,glob
from torch.utils.data import random_split
import torchvision
from torchvision.datasets import ImageFolder
import torchvision.transforms as transforms
```

Figure 29: importer les bibliothèques sous colab

3.13.3 Importer les données

On va importer les données depuis Google drive car il permet la fluidité de transfert sans endommager le fichier.

On utilise cette ligne de commande :

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

Mounted at /content/drive

Figure 30: connecter a drive

Après on doit décompresser le fichier (parce qu'il est en format ZIP) par cette ligne de commande :

```
[ ] import zipfile
def un_zipFiles(path):
    files=os.listdir('/content/drive/MyDrive/dataset-resized.zip')
    for file in files:
        if file.endswith('.zip'):
            filePath=path+'/'+file
            zip_file = zipfile.ZipFile(filePath)
            for names in zip_file.namelist():
                zip_file.extract('/content/drive/MyDrive/dataset-resized.zip')
            zip_file.close()
```

Figure 31: décompresser le fichier

Ensuite on voit le fichier ici :

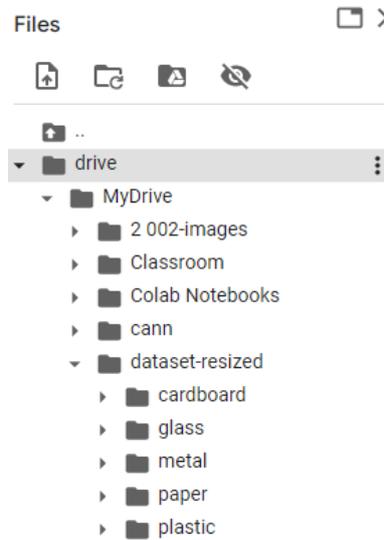


Figure 32: fichier de données

Remarque : les fichiers sont des images de déchets pris par un photographe professionnelle, nous avons les récupérer de lui.

3.13.4 Diviser la base de données

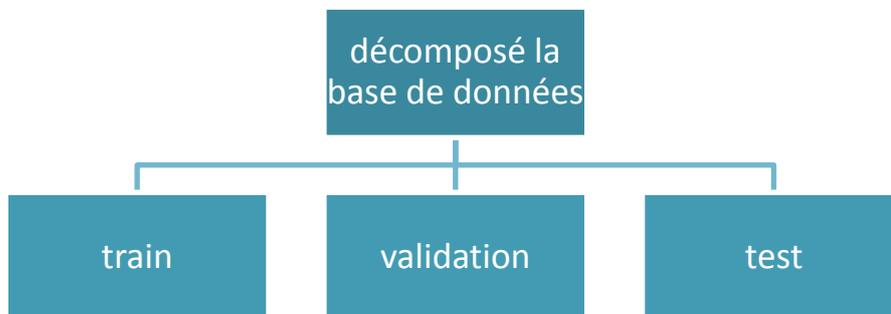


Figure 33: décomposé la base de données

La base de données sont copiées et placer dans les trois dossiers :{train ; validation ; test}

Ensuite on normalise la taille des images(255,255)([Hauteur ;Largeur])

3.13.5 Prétraitement de réseaux de neurones

Dans cette étape on va appliquer le prétraitement à la base de données qu'on va introduire à notre réseau de neurones, cette étape est nécessaire à la classification ensuite on va déplacer la base de données à un autre fichier pour définir son chemin virtuel.

3.13.6 L'augmentation de base de données

En utilisant « ImageDataGenerator » on va augmenter les données d'apprentissage automatiquement ce qui va améliorer performance de notre réseaux.

« **ImageDataGenerator** » génère des données en utilisant : le chemin du dossier de données, la taille ciblée, la couleur, la taille de l'échantillon comme paramètre.

3.13.7 Le Transfert Learning

Dans cette étape on va introduire les poids à notre réseaux de neurones, ensuite on applique le maxpooling et on ajoute une couche dense qui est une couche de prédiction.

La fonction d'activation choisie est Soft max qui va transformer un vecteur réel par un vecteur de probabilité entre [0,1].

Remarque : les poids de la première couche sont déjà pré entraînés

3.13.8 L'entraînement de réseaux de classificateur

Afin de procéder l'entraînement on choisit la configuration de la fonction d'activation Soft max et torch.optim comme optimiseur voici son fonctionnement.

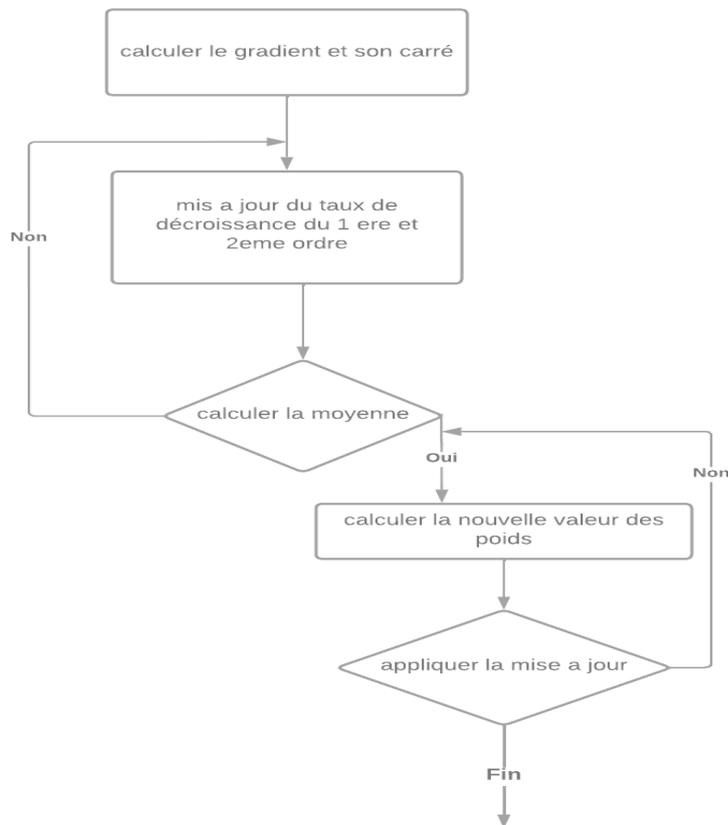


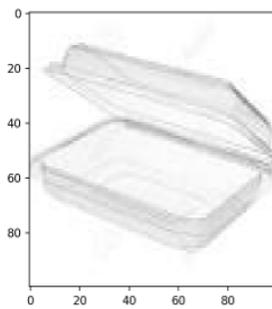
Figure 34:l'organigramme de l'optimiseur torch.optim (eyeles, et al., 2019-2020)

L'optimiseur torch.optim est un paquetage implémentant divers algorithmes d'optimisation. Il prend 3 hyper paramètres : le taux d'apprentissage (η), le taux de décroissance (decay) du moment de 1 er ordre et le taux de décroissance de 2 eme ordre.

3.13.9 Visualiser les résultats

On a arrivée à tester la performance de détection de déchets de notre programme par les 5 classes introduites {métal, plastic, carton, verre, papier} qu'on peut les voir ci-dessous :

Sélect. fichiers Aucun fichier choisi Upload widget is only available when the cell has been executed in the current browser session. Please rerun this cell to enable.
Saving images (11).jpg to images (11) (2).jpg



Clipping input data to the valid range for imshow with RGB data ([0..1] for floats or [0..255] for integers).
Label: plastic , Predicted: plastic

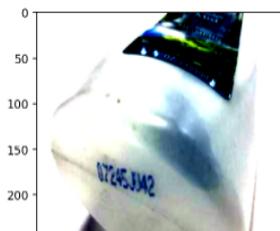


Figure 35:prédiction de nature de déchet

CONCLUSION

Dans ce chapitre nous avons présenté la partie pratique du travail, l'architecture utilisée (CNN) et son fonctionnement ainsi que l'environnement de programmation (python, Google colab) et les différentes bibliothèques afin de préparer la base de données. On a mis en valeur une partie importante qui est la normalisation « Transfer Learning » de cette base de données ; et on finit par la configuration du réseau de neurones et l'implémentation de notre modèle.

L'objectif de ce travail d'apporter une classification selon le type des déchets à travers capture d'image pour pouvoir de catégoriser le type de déchet dans sa classe le problème développé a permis de résoudre cette notion.

CONCLUSION GENERAL

Au cours de ce travail nous avons créé un système de classification et détection des images cérébrale des déchets à l'aide de Deep Learning, on a l'intention de coter les notions et les définitions de base concernant le domaine de Deep Learning. Nous avons créé un système d'apprentissage, qui se constitue d'un réseau de neurones convolutifs (CNN) ce qui nous a donné des résultats satisfaisants.

Le travail qu'on a fait a été divisé en trois chapitres ; le premier chapitre nous avons donné une brève description sur la chaîne logistique et la chaîne logistique inverse puis la définition du recyclage et les techniques de collecte et tri. Dans le deuxième chapitre nous avons parlé sur l'intelligence artificielle et ces différentes approches, le processus de classification des images, les systèmes de vision industrielle et enfin le positionnement de la problématique. Le troisième chapitre concerne la partie pratique de notre travail qui contient les algorithmes et les architectures célèbres de classification, le choix de l'architecture convenable pour cette étude, les réseaux de neurones et son fonctionnement mathématique suit d'une partie algorithmique et l'implémentation de programme.

L'implémentation de ce réseau était en Google Colab à l'aide de l'accélérateur GPU qui est puissant en termes d'exécution que CPU, on avait besoin de certains nombres de bibliothèques de Python afin d'accélérer le calcul mathématique de notre réseau de neurones. Le programme est une succession de cellules (Google Colab notebook) qui sert à classer la nature de déchet en utilisant les réseaux de neurones convolutionnels (CNN). Le CNN se constitue d'un réseau de neurones multicouche, commence par la couche de convolution et finit par la couche entièrement connectée.

L'intégration de cette solution sur terrain nécessite une modification afin qu'ils puissent traiter un grand nombre de déchets en temps réel à l'aide des caméras industrielles.

Bibliographie

A Review on the Application of Deep Learning in Legal Domain. **Neha Bansal, Arun Sharma, R. Singh.** 24 Oct 2019. 24 Oct 2019.

Agence internationale de l'énergie atomique. [En ligne] [Citation : 2022 5 4.] <https://www.iaea.org/fr/themes/radiographie-industrielle>.

al, H. Kapadia et. 2021. *Dry waste segregation using seamless integration of deep learning and industrial machine vision.* 2021. pp. 1-7.

al., T. J. Sheng et. 2020. *An Internet of Things Based Smart Waste Management System Using LoRa and Tensorflow Deep Learning Model.* 2020. pp. 148793-148811.

Alto, Valentina. 2020. Valentina Alto. *Valentina Alto.* [En ligne] 9 01 2020. [Citation : 06 06 2022.] <https://valentinaalto.medium.com/understanding-the-inception-module-in-googlenet-2e1b7c406106>.

Amidi, Afshine Amidi et Shervine. stanford edu. *stanford edu.* [En ligne] [Citation : 05 06 2022.] <https://stanford.edu/~shervine/1/fr/teaching/cs-230/pense-bete-reseaux-neurones-convolutionnels>.

An automatic classification method for environment: Friendly waste segregation using deep learning. **S. Sudha, M. Vidhyalakshmi, K. Pavithra, K. Sangeetha and V. Swaathi.** 2016. s.l. : IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR), 2016.

Analyse d'images par réseaux de neurones profonds appliquée à la détermination de la composition de granulats recyclés. **Hoong, Jean David Lau Hiu, et al.** s.l. : Université de La Rochelle, Avenue Michel Crépeau, 17000 La Rochelle, France, Laboratoire des Sciences de l'Ingénieur pour l'Environnement (LaSIE), UMR CNRS 7356.

Automation of Waste Sorting with Deep Learning. **J. Sousa, A. Rebelo and J. S. Cardoso.** 2019 . s.l. : Workshop de Visão Computacional, 2019 .

Beaulieu, M. mai 2000. « Définir et maîtriser la complexité des réseaux de logistique à rebours ». Trois-Rivières, Canada : Actes des Troisièmes Rencontres Internationales de la Recherche en Logistique, mai 2000. Vol. 20 p.

Belhaouci, Djamel. juripredis. [En ligne] [Citation : 25 05 2022.] <https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-les-reseaux-de-neurones-artificiels>.

Benjamin, T., & Marc, G. (2011-2012). *Etude et intégration du module d'acquisition d'images couleur sur la plateforme Tracilogis.* (2011-2012).

Benjamin, THABUIS et Marc, GUSMERINI. 2011-2012. *Etude et intégration du module d'acquisition d'images couleur sur la plateforme Tracilogis.* 2011-2012.

Benjamin, THABUIS, et GUSMERINI Marc. 2011-2012.. *Etude et intégration du module d'acquisition d'images couleur sur la plateforme Tracilogis.* 2011-2012.

blanc-durand, paul. 2018. research gate. [En ligne] 10 2018. [Citation : 28 05 2022.]

https://www.researchgate.net/publication/330995099_Reseaux_de_neurones_convolutifs_en_medecine_nucleaire_Applications_a_la_segmentation_automatique_des_tumeurs_gliales_et_a_la_correction_d'attenuation_en_TEPIRM/citations.

Bouaziz., Mohamed. 2017. *Réseaux de neurones récurrents pour la classification de séquences dans des flux audiovisuels parallèles. Réseau de neurones [cs.NE].* Université d'Avignon : (NNT : 2017AVIG0224). , 2017.

C. Sirawattananon, N. Muangnak and W. Pukdee. 2021. *Designing of IoT-based Smart Waste Sorting System with Image-based Deep Learning Applications.* s.l. : Computer, Telecommunications and Information Technology (ECTI-CON), 2021. pp. 383-387.

Charlotte Chapman-Wardy, Louis Asiedu , Kwabena Doku-Amponsah, and Felix O. Mettle. 2021. *Modeling the Amount of Waste Generated by Households in the Greater Accra Region Using Artificial Neural Networks.* s.l. : Department of Statistics and Actuarial Science, School of Physical and Mathematical Sciences, University of Ghana, Legon, Accra, Ghana, 2021.

Chen, Haitao. 3 decembre 2021. *Optimization of an Intelligent Sorting and Recycling System for Solid Waste Based on Image Recognition Technology.* s.l. : CNPC Chuanqing Drilling Engineering , 3 decembre 2021.

Chouinard, M. 2003 . « *Système organisationnel et architecture d'un support d'information pour l'intégration des activités de logistique inversée au sein d'un centre de réadaptation* ». Québec – Canada : Université de Laval – Québec – Canada,, 2003 .

Cyril MAZAUD, et al. 2006. *Modélisation de connaissances « métier » pour le paramétrage d'un Système Flou d'identification de défauts sur des planches de bois.* nancy : CRAN, 2006.

Cyril MAZAUD, et al. 2006.. *Modélisation de connaissances « métier » pour le paramétrage d'un Système Flou d'identification de défauts sur des planches de bois.* nancy : CRAN, 2006.

D.S. Rogers, R.S. Tibben-Lembke. 2001. « *An overview of reverse logistics practices* ». s.l. : Journal of Business Logistics, 2001. Vol. 22.

Dallaire-Nicholas, Noémie. 8 février 2021.. « *L'impact de l'intelligence artificielle en droit de l'environnement .* ». s.l. : la Faculté des sciences et à la Faculté de droit de l'Université de Sherbrooke, 8 février 2021.

—. **8 février 2021.** *L'impact de l'intelligence artificielle en droit de l'environnement.* Québec : la Faculté des sciences et à la Faculté de droit de l'Université de Sherbrooke, 8 février 2021.

Deep Learning Based Smart Garbage Monitoring System. **P. P. Rao, S. P. Rao and R. Ranjan. 2020.** s.l. : Communication & Information Technology (MPCIT), 2020. Third International Conference on Multimedia Processing. pp. 77-81.

—. **P. P. Rao, S. P. Rao and R. Ranjan. 2020.** s.l. : Third International Conference on Multimedia Processing, Communication & Information Technology, 2020. 51588.2020.9350390.

Deep Learning for Plastic Waste Classification System. **Bobulski, Janusz et Kubanek, and Mariusz. 05 May 2021.** 6626948, s.l. : hindawi, 05 May 2021, Vol. 2021.

Didactique et Intelligence artificielle . **Balacheff, N. et DidaTech.** Grenoble : IMAG-CNRS et Université Joseph Fourier.

direct industry by virtualexpo group. [En ligne] [Citation : 07 05 2022.] <https://guide.directindustry.com/fr/bien-choisir-une-camera-de-vision-industrielle/>.

dunod. 2006. UVED. *UVED.* [En ligne] 2006. [Citation : 05 06 2022.] http://stockage.univ-valenciennes.fr/EcoPEM/BoiteI/co/Introduction_generale.html.

Dupont, L. 2003 . « *Logistique inverse « reverse logistics » : fondements et concepts* ». s.l. : Editions WEKA, 2003 .

DUPONT, Lionel. 6/11/2018. *logistique.* grenoble : Laboratoire GILCO Institut National Polytechnique de Grenoble, 6/11/2018.

eyeles, khermaza et abdelouahab, boutiyara. 2019-2020. *traitement des images IRm pour la detection des tuemeurs.* blida : s.n., 2019-2020.

François Fulconis, Marlène Monnet, Gilles Paché. 2009/4 . *Le prestataire de services logistiques, acteur clé du système de logistique inversée.* s.l. : s.l. : Management & Avenir, 2009/4 .

—. **2009/4 .** *Le prestataire de services logistiques, acteur clé du système de logistique inversée.* s.l. : Management & Avenir, 2009/4 .

Hain, A. Jadli and M. 2020. *oward a Deep Smart Waste Management System based on Pattern Recognition and Transfer learning.* s.l. : 3rd International Conference on Advanced Communication Technologies and Networking (CommNet), 2020. pp. 1-5.

hichem, auoug. 2020. *GESTION DE LA CHAINE LOGISTIQUE.* batna : université de batna, 2020.

Hourri, Soufiane. 26 Apr 2021. Étude des Techniques de Deep Learning en. 26
Apr 2021.

Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network. **Olugboja Adedeji, Zenghui Wang.** University of South Africa, Florida : ScienceDirect.

ISASH, Maîtrise MASS - MST. 1999/2000.. intelligence artificielle. Paris : Université Paris 5 , 1999/2000.

ISHAK, Abdelaziz HABBA et Omar. 2018/2019. *La classification des images satellitaires par l'apprentissage profond.* adrar : s.n., 2018/2019.

Ismail, Nurul Hanna. 2016. *DFR : un cadre conceptuel destiné aux concepteurs pour un remanufacturing durable. Eco-conception.* s.l. : Université Grenoble Alpes, 2016.

J. Sousa, A. Rebelo and J. S. Cardoso. 2019. *Automation of Waste Sorting with Deep Learning.* s.l. : XV Workshop de Visão Computacional (WVC), 2019.

J.WFunck, et al. 2003. *Image segmentation algorithms applied to wood defect detection.* USA : s.n., 2003.

J.WFunck, YZhong, AButlerc, CCBrunnera, et J.BForrer. 2003. *Image segmentation algorithms applied to wood defect detection.* . USA : s.n., 2003.

Janusz Bobulski, Mariusz Kubanek. 2021. *Deep Learning for Plastic Waste Classification System.* s.l. : Applied Computational Intelligence and Soft Computing, 2021.

Kai Yi, Shitao Chen, Yu Chen, Chao Xia, Nanning Zheng. 22 Jun 2018.
Cognition-Based Deep Learning: Progresses and. 22 Jun 2018.

L'absence d'approche économique hypothèque la durabilité de la gestion des déchets. **Rahmani, DJEDJIGA. 2021.** alger : ElWatan, 2021.

Lambert, Serge et Riopel, Diane. 2003. *Logistique inverse : revue de littérature.* Montréal : Lambert, Serge et Riopel, Diane. Logistiqu GERAD et Département de mathématiques et de génie industriel , 2003.

Lambert, Serge et Riopel, Diane. 2003 . *Logistique inverse : revue de littérature.* Montréal : GERAD et Département de mathématiques et de génie industriel , 2003 .

Lee, S. -W. 2021. *Novel classification method of plastic wastes with optimal hyperparameter tuning of Inception_ResnetV2.,* s.l. : 4th International Conference on Information and Communications Technology (ICOIACT), 2021.

L'INTELLIGENCE ARTIFICIELLE. **Pastre, Dominique, MASS, Maîtrise et ISASH, - MST. 1999/2000.** Paris : Université Paris 5 , 1999/2000.

Llaurens, Jérémy. 2011. *Mise en place d'un plan de maintenance préventive sur un site de production pharmaceutique.* 2011.

Logistique inverse : un maillon essentiel du développement durable. **Lionel Dupont, Matthieu Laurus. 6/11/2018.** 6/11/2018, p. 30.

M. Fleishmann, J.M. Bloemhof-Ruwaard, R.V.D. Dekker, J.A.E. Van Nunen, L.N. Van Wassenhove. 1997 . « *Quantitative models for reverse logistics: a review* ». s.l. : European Journal of Operation Research, 1997 .

M. Thierry, M. Salomon, J. Van Nunen, L.N. Van Wassenhove. 1995. « *Strategic issues in product recovery management* ». California : California Management Review, 1995. .

Machine Learning and IoT-Based Waste Management Model. **Rijwan Khan, Santosh Kumar, Akhilesh Kumar Srivastava, Niharika Dhingra, Mahima Gupta, Neha Bhati, Pallavi Kumari. 2021.** 5942574, s.l. : Computational Intelligence and Neuroscience, 2021, Vol. 2021. i.

mazur, matt. 2015. matt mazur. [En ligne] 17 03 2015. [Citation : 25 05 2022.] <https://mattmazur.com/2015/03/17/a-step-by-step-backpropagation-example/>.

Mittal, Gaurav and Yagnik, Kaushal B. and Garg, Mohit and Krishnan, Narayanan C. 2016. *SpotGarbage: Smartphone App to Detect Garbage Using Deep Learning.* SpotGarbage: Smartphone App to Detect Garbage Using Deep Learning : Association for Computing Machinery, 2016.

Moussa, Louail. 2020. *Etude de la maintenance industrielles application de dattes de Tolgade l'Université de Biskra.* 2020.

MuhammadRizwan. 2018 . datascience central . [En ligne] 06 10 2018 . [Citation : 06 06 2022.] <https://www.datasciencecentral.com/lenet-5-a-classic-cnn-architecture/>.

Multilayer Hybrid Deep-Learning Method for Waste Classification and Recycling. **Yinghao Chu, 1 Chen Huang, et al. 01 Nov 2018.** 01 Nov 2018.

Neha Bansal, Arun Sharma, R. Singh. 24 Oct 2019.. «*A Review on the Application of Deep Learning in Legal Domain.*» . 24 Oct 2019.

Noël De Palma, Nicolas Vuillerme. 11/2020. *A scalable and component-based deep learning parallelism platform : an application to convolutional neural networks for medical imaging segmentation.* 11/2020.

Olugboja Adedeji, Zenghui Wang. 2019. *Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network.* s.l. : College of Science, Engineering and Technology, University of South Africa, Florida 1710, South Africa, 2019.

Optimization of an Intelligent Sorting and Recycling System for Solid Waste Based on Image Recognition Technology. **Chen, Haitao.** 4094684, s.l. : Advances in Mathematical Physics, Vol. 2021.

pawangfg. 2020. Acervo Lima. *Acervo Lima.* [En ligne] 2020. [Citation : 06 06 2022.] <https://fr.acervolima.com/reseaux-residuels-resnet-deep-learning/>.

Poulain, Patrick Fuchs et Pierre. 2022. *Cours de Python.* paris : université de paris, 2022.

—. 21/05/2022. *PDF du cours.* s.l. : Couverture livre Dunod., 21/05/2022.

ROUX, Hélène HORSIN MOLINARO – François HILD – Stéphane. 17/12/2014 . *La tomographie en sciences et mécanique des matériaux : voyage aux centres des matériaux.* 17/12/2014 .

Roy, Jacques. 2014/4.. *La logistique .* montréal : HEC montréal, 2014/4.

—. 2014/4. *La logistique .* s.l. : HEC montréal, 2014/4.

S. Chepa, S. Singh, H. Dutt, A. Sharma, S. Naik and H. Mahajan. 2021. *A Comprehensive Study of Distinctive Methods of Waste Segregation and Management.* s.l. : hird International Sustainability and Resilience Conference: Climate Change, 2021. pp. 440-444.

S. K. Behera, A. B. S. Y, V. L, S. G, H. N. C and S. P. J. 2020. *AI Based Waste Classifier With Thermo-Rapid Composting.* 2020. pp. 1-4.

S. Sudha, M. Vidhyalakshmi, K. Pavithra, K. Sangeetha and V. Swaathi., 2016. *An automatic classification method for environment: Friendly waste segregation using deep learning.* s.l. : IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR), 2016. 10.1109/TIAR.2016.7801215.

Shafique, Maurizio Capra-Beatrice Bussolino. Alberto Marchisio Muhammad. 2020. *Hardware and Software Optimizations for Accelerating Deep Neural Networks: Survey of Current Trends, Challenges, and the Road Ahead.* 2020.

SOLTANI, Hadjer. 2020. *Analyse in situ par radiographie X du développement de grains dendritiques dans un gradient de température.* s.l. : Aix-Marseille Université ECOLE DOCTORALE 352 , 2020.

TALEB-AHMED, Abdelmalik et DUVIEUBOURG, Luc. 2005. *Cours de vision industrielle Contrôle qualité par caméra linéaire.* Calais cedex, FRANCE : s.n., 2005.

TALEB-AHMED, Abdelmalik, et Luc DUVIEUBOURG. 2005. *Cours de vision industrielle Contrôle qualité par caméra linéaire.* . s.l. : Calais cedex, FRANCE., 2005.

Victoria Ruiz, Ángel Sánchez, José F. Vélez & Bogdan Raducanu. 10 may 2019. *Automatic Image-Based Waste Classification*. s.l. : Lecture Notes in Computer Science, 10 may 2019.

Yinghao Chu, Chen Huang, Xiaodan Xie, Bohai Tan, Shyam Kamal, Xiaogang Xiong. 2018. *Multilayer Hybrid Deep-Learning Method for Waste Classification and Recycling*. s.l. : Computational Intelligence and Neuroscience, 2018.

Zarour, Hani Zerzaihi et Fouad. 2020. *Reconnaissance d images par les réseaux de neurones*. jijel : Université Mohamed Sadik Benyahia de Jijel, 2020.

RESUME

Dans ce travail nous avons proposé une technique intelligente pour le triage des déchets en utilisant l'intelligence artificielle et le Deep Learning le problème de des déchets reste parmi les problème les plus alarmant actuellement vu la quantité massive qui augmente exponentiellement chaque jour suite a la consommation des individus qui évolue de manière dynamique ou la plus part du temps la finalité de ces déchets se cumule sous forme de montagne des déchets dans la nature, c'est pour cela la notion de recyclage et réutilisation est nécessaire et doit être de première priorité pour toutes les populations afin de faciliter le travail dans les centres de traitement. La première étape critique dans ce domaine est le triage des différent déchets pour pouvoir le rapporter les transformations adéquate, bien que il existe plusieurs manière d'effectuer le triage basé principalement sur l'intervention manuelle des être humain le système écologique dans une impasse puisque la fréquence des triages des quantité quotidienne est nettement inférieure au quantité déchets émise quotidiennement c'est dance contexte ce travail a eu lieu une technique de triage qui soulagera l'humanité de ce travail fastidieux et qui contribuera a la diminution des déchets d'une manière considérable pour une planète verte qui respire.

SUMMARY

In this work we have proposed an intelligent technique for waste sorting using artificial intelligence and Deep Learning. The problem of waste remains among the alarming problems at the current time following the quantity of massive waste increases exponentially every day or the consumption of individuals evolves dynamically. This waste accumulates under the mountain of waste in the nature, that's why the notion of recycling and reutilization is necessary and must be of first priority for all populations in order to facilitate the work in the treatment centers. The first critical step in this field is the sorting of the different wastes to transform them, although there are several ways to carry out the sorting based mainly on the manual intervention of human beings. The ecological system is overwhelmed, because the frequency of sorting of the daily quantity is much lower than the quantity of waste emitted daily, so in this context a sorting technique has been developed that will relieve mankind of this tedious work and will contribute to the reduction of waste in a considerable way for a green planet that breathes.

ملخص

في هذا العمل، اقترحنا تقنية ذكية لفرز النفايات باستخدام الذكاء الاصطناعي والتعلم العميق. لا تزال مشكلة النفايات من بين المشاكل المقلقة في الوقت الحالي بعد زيادة كمية النفايات الهائلة بشكل كبير كل يوم أو يتطور استهلاك الأفراد بشكل ديناميكي. تتراكم هذه النفايات تحت جبل النفايات في الطبيعة، ولهذا السبب فإن فكرة إعادة التدوير وإعادة الاستخدام ضروري ويجب أن تكون ذات أولوية قصوى لجميع السكان من أجل تسهيل العمل في مراكز المعالجة. الخطوة الحاسمة الأولى في هذا المجال هي فرز النفايات المختلفة لتحويلها، على الرغم من وجود عدة طرق لإجراء الفرز على أساس التدخل اليدوي للبشر بشكل أساسي. النظام الإيكولوجي مرهق، لأن تواتر فرز الكمية اليومية أقل بكثير من كمية النفايات المنبعثة يوميًا، وفي هذا السياق، استحدثت تقنية فرز ستريح البشرية من هذا العمل الشاق وستسهم في الحد من النفايات بطريقة كبيرة لكوكب أخضر يتنفس.

Mot clés : collecte des déchets ; chaine logistique ; Deep Learning