

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE MINISTERE DE
L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE MATHÉMATIQUES ET INFORMATIQUE

DEPARTEMENT INFORMATIQUE

N° :



DOMAINE : Mathématiques Et Informatique

FILIERE : Informatique

OPTION : Informatique Décisionnelle Et
Optimisation

Mémoire présenté pour
l'obtention Du diplôme de
Master Académique

Par: Bouafia Nadjat

Intitulé

**Classification efficace des vêtements de
mode basée sur les approches :
apprentissage automatique ML et
apprentissage profond DL**

Soutenu devant le jury composé de :

Mme.HALASSA Madiha

Université de M'sila

Président

Dr .KADRI Said

Université de M'sila

Rapporteur

Dr. Mohamed Benouis

Université de M'sila

Examineur

Année universitaire : 2019 /2020

Dédicaces

A mes très chers parents.

Remerciements

Nous remercions Allah qui nous a aidés à réaliser ce travail Nous remercions également notre encadreur Saïd KADRI pour l'aide et les conseils concernant ce travail Nous tenons aussi à remercier les membres du jury pour avoir accepté d'examiner et d'évaluer ce travail.

Table des matières

INTRODUCTION GENERALE..... ERROR! BOOKMARK NOT DEFINED.

CHAPITRE 01 RECONNAISSANCE D'IMAGE

Intrduction	5
Aperçu sur mode (fashion)	5
Définition d'image.....	6
Caractéristiques d'une image	6
Pixel.....	6
Résolution	6
Types d'images.....	6
Image binaire.....	6
Image couleur RGB.....	7
Image en niveau de gris	7
L'image matricielle (ou bitmap):.....	7
L'image vectorielle.....	7
La reconnaissance d'image	7
Comment fonctionne la reconnaissance d'image ?.....	8
Méthode de reconnaissance d'image.....	8
Classification.....	8
Approches de la classification	8
Détection d'objet.....	9
Application.....	9
Conclusion.....	10

CHAPITRE 02 :APPRENTISSAGE AUTOMATIQUE(ML) ET APPRENTISSAGE PROFOND(DL)

Introduction	12
Machine Learning ML:.....	12
Type d'apprentissage automatique.....	12

Apprentissage supervisée (Supervised learning)	13
Apprentissage non-supervisée (Unsupervised learning).....	14
Apprentissage semi-supervisée (semi-supervised learning):	14
Apprentissage par renforcement (Reinforcement learning):.....	15
Algorithmes de Machine Learning	15
Machines à Vecteurs de Support SVM.....	15
Régression linéaire.....	16
Régression logistique.....	16
Arbres de décision : (Decision Trees).....	17
K-NN(K Nearest Neighbours)	17
Naïve Bayes Classifier	18
Les réseaux de neurones.....	19
Apprentissage profond et CNN.....	19
Aperçu de l'apprentissage profond	19
Définition DL	22
Réseaux de neurones convolutionnels (CNN).....	23
Conclusion.....	29

CHAPITRE 03 OUTILS ET ENVIRONNEMENT DE DEVLOPEMENT

Introduction	31
Outils et environnement de développement.....	31
	Python 31
Anaconda	33
	Keras 33
TensorFlow	35
Scikit-learn.....	36
	Numpy 36
	Pandas37
Matplotlib	37
Conclusion.....	37

CHAPITRE 04 :IMPLEMENTATION ET RESULTATS

Le modèle CNN proposé	39
Expérimentation et résultats obtenus	40
Dataset utilisée.....	40
Évaluation.....	42
Illustration des résultats obtenus	43

Discussion	47
Interface	47
Conclusion	50
CONCLUSION GENERALE	51
LES NOTIFICATIONS D'ACCEPTATION DES PAPIERS DANS LES CONFERENCES:	58

Liste des Figures

Figure 2.1 l'algorithme ML fonctionne à partir de training data	12
Figure 2.2 Apprentissage supervisée.....	13
Figure 2.3 Classification et régression	14
Figure 2.4 Machines à Vecteurs de Support SVM.....	16
Figure 2.5 Régression linéaire	16
Figure 2.6 régression logistique.....	17
Figure 2.7 Decision Trees.....	17
Figure 2.8 K-NN.....	18
Figure 2.9 Les réseaux de neurones	19
Figure 2.10 Exemple sur un réseau de neuranes convolutif	24
Figure 2.11 Schéma du parcours de la fenêtre de filtre sur l'image.....	25
Figure 2.12 Application de la convolution sur un image.....	26
Figure 2.13 illustration de la methode maxpolling pour un pooling 2*2et stride2	27
Figure 2.14 illustration de la méthode averagepooling por un pooling de 2*2 et stride 2	27
Figure 2.15 Représentation graphique de fonction ReLU	28
Figure 2.16 Application de ReLU à un matrice et à une image	28
Figure 2.17 Exemple des couches entièrement connectées	29
Figure 3.1 Logo de Python	32
Figure 3.2 Logo Anaconda	33
Figure 3.3 Logo de Keras	34
Figure 3.4 Hiérarchie de Keras	34
Figure 3.5 Logo de tensorFlow	35
Figure 4.1 Processus de Classification des vêtement	39
Figure 4.2 Architecture de modelé CNN proposé.....	40
Figure 4.3 Ligne50 :Image en niveaux de gris representant une Sneaker	42
Figure 4.4 Ligne 100 :Image en niveaux de gris representant un T-shirt	42
Figure 4.5 Trining loss Vs Validation Loss du modèle CNN.....	46
Figure 4.6 Trining accuracy VS Validation accuracy du modèle CNN	46
Figure 4.7 Illustration de fenêtre principale de l'application.....	48
Figure 4.8 illustration de reconnaissance d'image.....	48
Figure 4.9 illustration la reconnaissance d'image de niveaux gris	49
Figure 4.10 illustration Accuracy de deferents algorithme ML	49
Figure 4.11 Illustration accuracy et Loss valuer de model CNN	50

Liste des Tables

- Tableau 4-1** Labls attribuées a chaque occurrence dans database Fashion Mnist..... 41
- Tableau 4-2** Description du model CNN proposé..... 45
- Tableau 4-3** Précision (Accuracy) après application de differents algorithmes ML 45
- Tableau 4-4** Loss Value et valeur de précision obtenus lors de l'application du modèle propose46

INTRODUCTION GENERAL



Nous vivons dans un monde numérique, où les informations sont stockées, traitées, indexées et recherchées par des systèmes informatiques, ce qui rend leur récupération une tâche rapide et pas cher. Au cours des dernières années, des progrès considérables sont été réalisés dans le domaine de reconnaissance d'image et classification d'image Ce progrès est dû à la disponibilité de bases de données internationales ainsi qu'à l'évolution de l'intelligence artificielle dans de nombreux magazines, y compris la mode.

La mode est la façon dont nous nous présentons au monde et est devenue l'une des plus grandes industries du monde. La mode, principalement véhiculée par la vision, a ainsi attiré beaucoup d'attention de la part des chercheurs en vision par ordinateur ces dernières années.

Compte tenu du développement rapide, L'apprentissage automatique et l'apprentissage profond ont été utilisés pour reconnaître les vêtements figurant sur des photos. Qu'est-ce que l'apprentissage automatique (machine learning) et l'apprentissage profond (deep learning) ? et Comment les images sont-elles reconnues ?

En 1959, IBM a publié un article dans le IBM Journal of Research and Development avec un titre obscur et curieux. Rédigé par Arthur Samuel d'IBM, le document a investi l'utilisation de l'apprentissage machine dans le jeu des dames « pour vérifier le fait qu'un ordinateur peut être programmé afin qu'il apprenne à jouer un meilleur jeu de dames que celui que peut jouer la personne qui a écrit le programme ». Bien qu'il ne s'agisse pas de la première publication à utiliser le terme « apprentissage automatique ». Arthur Samuel est largement considéré comme la première personne à avoir utilisé et défini l'apprentissage automatique sous la forme que nous connaissons aujourd'hui. Arthur Samuel propose la définition suivante :

“champ d'étude qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmés”.

Arthur Samuel introduit l'apprentissage automatique dans son document comme un sous-domaine de l'informatique qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmé. L'apprentissage automatique est le concept de l'auto-apprentissage. Il s'agit de l'application de la modélisation statistique pour détecter les tendances et améliorer les performances basées sur des données et des informations empiriques, le tout sans commandes de programmation directe. C'est ce qu'Arthur Samuel a décrit comme la capacité d'apprendre sans être explicitement programmé. Mais il ne laisse pas entendre que les machines prennent des décisions sans programmation préalable. Au contraire, l'apprentissage automatique dépend fortement de la programmation informatique. Au lieu de cela, Samuel a observé que les machines n'ont pas besoin d'une commande d'entrée directe pour effectuer une tâche définie, mais plutôt des données d'entrée.

Le Deep Learning est un nouveau domaine de recherche en Machine Learning, qui a été introduit dans le but de rapprocher le Machine Learning de l'un de ses objectifs originaux : l'Intelligence Artificielle. Le Deep Learning est un élément important de la science des données, qui comprend les statistiques et la modélisation prédictive. Il est extrêmement utile aux scientifiques chargés de collecter, d'analyser et d'interpréter de grandes quantités de données ; Le Deep Learning rend ce processus plus rapide et plus facile.

Dans la fin des années 80 Yan le Cun a développé un type de réseau particuliers qui s'appellent les réseaux de neurone convolutionnel, ces réseaux sont une forme particulière de réseau neuronal multicouche dont l'architecture des connexions est inspirée de celle du cortex visuel des mammifères. Sur la base de cette idée, CNN a été développé pour la reconnaissance d'image et vidéo. Alors, Dans ce projet, nous allons concentrer sur le réseau neuronal convolutionnel CNN pour reconnaître les vêtements figurant sur des photos.

Pour ce faire, nous avons structuré notre mémoire en quatre chapitres :

- Dans le premier chapitre, on commence par une vue d'ensemble sur la reconnaissance d'image, son fonctionnement ainsi que ses différents usages.
- Le deuxième chapitre est consacré à l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning).
- Le chapitre trois, nous allons présenter les Outils et environnement de développement utilisés pour la réalisation de notre projet.
- Dans le quatrième chapitre, on va montrer la partie expérimentale de notre travail et on discute les différents résultats obtenus.
- Enfin, on termine notre travail par une conclusion générale.

L'objectif principale de notre travail est développé un classifieur automatique qui permet de classer un grand nombre d'articles vestimentaires selon l'approche ML et l'approche DL.

CHAPITRE01 : RECONNAISSANCE D'IMAGE

Intrduction :

Lorsqu'il s'agit d'identifier des images, nous, les humains, pouvons clairement reconnaître et distinguer les différentes caractéristiques des objets. C'est parce que nos cerveaux ont été entraînés inconsciemment avec le même ensemble d'images qui a abouti au développement de capacités à différencier les choses sans effort .

Contrairement aux cerveaux humains, l'ordinateur considère les visuels comme un tableau de valeurs numériques et recherche des motifs dans l'image numérique, qu'il s'agisse d'une image fixe, vidéo, graphique, pour reconnaître et distinguer les caractéristiques clés de l'image.

Compte tenu du potentiel croissant de la vision par ordinateur, de nombreuses organisations investissent dans la reconnaissance de l'images pour interpréter et analyser des données.

Dans ce chapitre, nous allons présenter tout d'abord un aperçu sur la mode (fashion). Ensuite, nous essayons d'expliquer en quelques mots ce qu'est une image ? et ce qu'est la reconnaissance d'image, son fonctionnement, ainsi que ses différents usages.

Aperçu sur mode (fashion) :

La mode est un style ou une pratique populaire, en particulier dans les vêtements, les chaussures, les accessoires, le maquillage. La mode est une tendance distinctive et souvent habituelle dans le style dans lequel une personne s'habille.

D'une certaine manière, la mode nous aide à montrer qui nous sommes et à décrire notre personnalité en termes d'informations visuelles. Dans la façon dont nous choisissons les vêtements, nous montrons notre attitude envers le monde et les autres. C'est aussi une sorte de communication.

La mode joue un rôle important dans le mode de vie quotidien, mais la compréhension de la mode reste une tâche très compliquée pour la vision par ordinateur.

Définition d'image :

Une image est la représentation d'un être ou d'une chose obtenue par exemple par la photographie, la vidéo ou l'utilisation d'un logiciel spécialisé.

On peut définir une image comme un tableau bidimensionnel dont chaque élément (pixel) représente une surface élémentaire de l'image. La disposition de ces pixels est généralement en ligne et en colonne. Mathématiquement, Une image est la projection sur un plan d'une scène 3D, Elle peut être définie comme une fonction à deux variables $f(x, y)$ où (x, y) est la position d'un point de l'espace sur le plan de projection et $f(x, y)$ est l'intensité (ou brillance) au point de coordonnées (x, y) [16] .

Caractéristiques d'une image :

Pixel :

Le mot pixel provient d'une abréviation de l'expression britannique (Picture élément), il représente l'unité de base d'une image. L'ensemble de ces pixels est contenu dans un tableau de deux dimensions constituent l'image finalement obtenue. Chaque pixel est associé à un niveau de gris n ou des niveaux de composantes couleur codé sur N bits et représentent respectivement le niveau de luminosité ou de couleur de la zone correspondante dans la scène observée. Chaque pixel est localisé par ses coordonnées x et y [16].

Résolution

La résolution d'une image est le nombre de pixels contenus dans l'image par unité de longueur, elle s'exprime le plus souvent en PPP (Point Par Pouce) ou en DPI (Dot Per Inch), et parfois en point.

Types d'images :

Image binaire :

Une image binaire est une image pour laquelle chaque pixel ne peut avoir pour valeur que 0 ou 1, elle peut être représentée par une matrice booléenne dont chaque élément signifie Vrai (1 = blanc) ou Faux (0 = noir).

Image couleur RGB :

Chaque pixel possède une couleur décrite par la quantité de rouge (R), vert (G) et bleu (B). Chacune de ces trois composantes est codée sur l'intervalle [0, 255], ce qui donne $256^3 = 16\,777\,216$ couleurs possibles [16].

Image en niveau de gris :

Une image en niveaux de gris est un tableau de valeurs. Chaque case de ce tableau stocke une valeur, ces valeurs sont enregistrées dans l'ordinateur sous forme de nombres entiers entre 0 et 255, la valeur 0 correspond au noir, et la valeur 255 correspond au blanc. Les valeurs intermédiaires correspondent à des niveaux de gris allant du noir au blanc .

L'image matricielle (ou bitmap):

Elle est composée de petits points appelés « pixels » que l'on ne voit pas à l'œil nu. Lors de l'agrandissement d'une image matricielle, cette dernière devient floue car les pixels ressortent, ce sont les carrés qui apparaissent sur l'écran.

L'image vectorielle :

Elle est composée de lignes de segments qui sont liés entre eux par des formules mathématiques. Il s'agit d'un système de proportionnalité et de coordonnées. Grâce à la vectorisation, chaque élément a une place bien définie ce qui empêche la déformation de l'image. [16].

La reconnaissance d'image :

La reconnaissance d'image est un domaine scientifique interdisciplinaire qui traite de la façon dont les ordinateurs peuvent être utilisés pour analyser des images numériques ou des vidéos. En général, La reconnaissance d'image est un sous-catégorie de la computer vision et de l'intelligence Artificielle.

La reconnaissance d'images consiste à créer un réseau neuronal qui va traiter tous les pixels contenus dans une image. Par exemple, on montre des centaines d'images de chaussures à une intelligence artificielle (IA). Au bout d'un certain temps, l'IA saura à quoi doit ressembler une image de chaussures. Si vous lui montrez l'image d'un MANTEAU, l'IA va comparer tous les pixels contenus dans l'image de MANTEAU avec toutes les images de chaussures déjà traitées. Ne trouvant pas ou peu de correspondances, l'IA interprétera cette image comme étant celle d'un MANTEAU.

Comment fonctionne la reconnaissance d'image ?

Le fonctionnement de la technologie de reconnaissance visuelle est très simple :

1. On scanne l'image à reconnaître à l'aide d'une application embarquant la technologie.
2. Après traitement, l'application reconnaît l'image en l'identifiant dans sa banque d'images.
3. Elle déclenche l'action qui lui est associée dans sa banque de données.

Méthode de reconnaissance d'image :

Il existe deux méthodes pour la reconnaissance d'images :

Classification :

La classification est le processus d'assignation de classes spectrales en classes d'information. Les classes spectrales sont des groupes de pixels qui sont uniformes par rapport à leurs valeurs de luminosité dans les différents canaux spectraux de données. Les classes d'information sont des catégories d'intérêt qu'un analyste tente d'identifier dans l'image sur la base de ses connaissances et de son expérience du domaine.

Pour faire simple, Il s'agit de l'identification de la classe, autrement dit la catégorie, à laquelle une image appartient. Une image ne peut avoir qu'une seule classe. L'objectif de la classification d'images est d'élaborer un système capable d'affecter une classe automatiquement à une image.

Approches de la classification :

Il existe deux approches générales de la classification des images :

- Classification supervisée.
- Classification non supervisée.

(Voire chapitre 2)

Détection d'objet :

Cela est nécessaire lorsque l'on souhaite situer un objet dans une image. Cette méthode, elle peut détecter plusieurs objets dans la même image. Il marque également les objets et montre leur emplacement dans l'image.

Application :

La Reconnaissances d'image dans le domaine médical :

Permet le repérage des cellules ou d'événements anormaux (tumeurs,...) dans des images et signaux médicaux.

La Reconnaissances d'image dans la biométrie :

- La reconnaissance d'écriture.
- Reconnaissances des empreintes digitales,
- Reconnaissances de signature
- Reconnaissances de Iris.
- Reconnaissances de visage.

Reconnaissance d'image dans le domaine de fabrication :

- Inspection de l'emballage : Des photos sont prises de tablettes et transférées vers un PC dédié où les images sont analysées à l'aide d'un logiciel pour vérifier si les tablettes sont correctes en couleur, longueur, largeur et ensemble. [47]
- Lecture des codes-barres.
- Améliorer la sécurité : L'idée est appliquer l'intelligence artificielle basée sur l'apprentissage en profondeur pour suivre les personnes et prédire le mouvement des équipements afin d'éviter les interactions dangereuses, améliorant ainsi la sécurité.
- Reconnaissance d'image dans la surveillance : Il s'agit de la technologie vidéo de pointe qui enregistre les activités criminelles dans les maisons, les entreprises et les municipalités en fonction des préférences de l'utilisateur.

Aussi, La Reconnaissances d'image Un outil indispensable pour les journalistes. La reconnaissance d'images fait également figure d'allié incontournable pour les médias dans leur lutte contre la désinformation (« fake news ») [48].

Conclusion :

Si la reconnaissance d'image joue ce rôle de premier plan aujourd'hui, c'est grâce à la rupture apportée par l'apprentissage automatique et l'apprentissage profond. Dans le deuxième chapitre, on va bien détailler l'apprentissage automatique et l'apprentissage profond.

CHAPITRE 02 : APPRENTISSAGE AUTOMATIQUE (ML) ET APPRENTISSAGE PROFOND (DL)

Introduction :

Dans ce chapitre, nous allons présenter tout d'abord les notions en relation avec l'apprentissage automatique, ensuite nous allons présenter l'apprentissage profond Deep Learning. Le Deep Learning est un nouveau domaine de recherche du ML, qui a été introduit dans le but de rapprocher le ML de son objectif principal : l'intelligence artificielle. Enfin dans la dernière section on va clôturer ce chapitre en expliquant le principe des réseaux neuronaux convolutionnels, et voir comment ils fonctionnent.

Machine Learning ML:

Machine Learning (ML se traduit par l'apprentissage automatique) est une technologie de l'intelligence artificielle (IA) qui se concentre sur la conception de systèmes qui apprennent ou améliorent le rendement en fonction des données qu'il consomment. En outre, il s'agit d'une sorte de programme permettant à un ordinateur ou à une machine un apprentissage automatisé, de façon à pouvoir réaliser un certain nombre d'opérations très complexes. [10]

Nous pouvons également le définir en deux étapes :

1. Collecte de données (dataset).
2. Modélisation (Construction d'un modèle statistique pour cet ensemble de données (dataset))

La fonction principale de l'apprentissage automatique est de créer à partir des données des modèles prédictifs qui apprennent par eux-mêmes.




Figure 2.1 l'algorithme ML fonctionne à partir de training data

Type d'apprentissage automatique :

Il existe différents types d'apprentissage automatique [3]:

Apprentissage supervisée (Supervised learning):

Tout simplement, cet apprentissage représente un ensemble des variable d'entrée(X :input), une variable de sortie (Y :output), et un algorithmme (F :modèle) utilisé pour prédire le résultat Y en se basant sur des donnes X [14]. (figure2.2)




Figure 2.2 Apprentissage supervisée

D'une manière générale, une machine peut apprendre une **relation** $f : x \rightarrow y$ qui relie x à y en ayant **analysé** des millions d'exemples d'associations $x \rightarrow y$.

L'objectif de l'apprentissage supervisé est de développer un modèle (classifieur) capable de classer de nouvelles instances (ne faisant pas partie de X) avec un minimum d'erreur. [8]

Deux types de tâches peuvent être envisagés ici, la classification et la régression.

- **Classifications:** Lorsque le résultat attendu est une classe (groupe). . **Par exemple :** Classifier un animal comme: chat, chien, vache ou autre en se basant sur le poids, la longueur et le type de nourriture.
- **Régression :** Lorsque le résultat attendu est une valeur. **Par exemple:** Estimer le prix d'une maison à partir de sa surface, nombre de chambre et l'emplacement.




Figure 2.3 Classification et régression

Apprentissage non-supervisée (Unsupervised learning) :

Consiste à ne disposer que de données d'entrée X et pas de variable de sortie correspondant. L'apprentissage non supervisé vise à caractériser la distribution des données, et les relations entre les variables, sans discriminer entre les variables observées et les variables à prédire.

Il existe de nombreuses classes d'algorithmes dans l'apprentissage non supervisé, les plus utilisées sont [14]:

- L'algorithme de clustering (regroupement)
- L'algorithme de réduction de dimension
- L'algorithme d'association.

Apprentissage semi-supervisée (semi-supervised learning):

L'apprentissage semi-supervisé est un mélange entre l'apprentissage non-supervisée et supervisée : où nous commençons par l'apprentissage non supervisé, puis nous poursuivons avec l'apprentissage supervisé. Aussi, l'apprentissage semi-supervisée utilise un ensemble de données étiquetées et non- étiquetées.

Apprentissage par renforcement (Reinforcement learning):

Est une méthode d'apprentissage pour le modèle de ML. Cette méthode consiste à mettre en place un système de “récompenses” et de “punitions” à travers lequel l’algorithme va apprendre de ses propres erreurs, par expériences successives pour prendre les bonnes décisions.

Pour simplifier les choses on peut dire le suivant : La machine se retrouve directement confrontée à des choix. Si elle se trompe, elle est pénalisée. Au contraire, si elle prend la bonne décision, elle est récompensée. Afin d’obtenir toujours plus de récompenses, la machine va donc faire de son mieux pour optimiser sa prise de décisions. [15]

Algorithmes de Machine Learning :

Le domaine du Machine Learning regorge plusieurs algorithmes pour répondre à différents besoins. Dans ce projet nous avons utilisé les algorithmes d'apprentissage supervisé suivant [6]:

Machines à Vecteurs de Support SVM :

Les SVMs (Support Vector Machine ou Machine à vecteurs de support) sont une famille d’algorithmes d’apprentissage automatique qui permettent de résoudre des problèmes tant de classification que de régression ou de détection d’anomalie. _

Les SVMs ont été développés dans les années 1990, leur principe est simple : il ont pour but de séparer les données en classes à l’aide d’une frontière aussi « simple » que possible, de telle façon que la distance entre les différents groupes de données et la frontière qui les sépare soit maximale. Cette distance est aussi appelée « marge » et les SVMs sont ainsi qualifiés de « séparateurs à vaste marge », les « vecteurs de support » étant les données les plus proches de la frontière [6].[23]

De façon plus générale, le but de SVM, est d’apprendre à bien placer la frontière entre les catégories.




Figure 2.4 Machines à Vecteurs de Support SVM

Régression linéaire :

Les algorithmes de régression linéaire modélisent la relation entre des variables prédictives et une variable cible. Autrement dit, décrire la relation entre une variable dépendante (Y) et une ou plusieurs variables indépendantes (Xi).

L'objectif de cet algorithme est de comprendre les relations qui existent entre la variable à expliquer (Y) et les variables explicatives (Xi), aussi prédire les valeurs que peut prendre la variable de réponse (Y) à partir des valeurs prises par les variables prédictives (Xi).




Figure 2.5 Régression linéaire

Régression logistique :

La régression logistique est une technique prédictive qui vise à expliquer une variable d'intérêt binaire (c'est-à-dire de type « oui / non » ou « vrai / faux »). Les variables explicatives qui seront introduites dans le modèle peuvent être quantitatives ou qualitatives.




Figure 2.6 régression logistique

Arbres de décision : (Decision Trees) :

L'arbre de décision est un algorithme qui se base sur un modèle de graphe (les arbres) pour définir la décision finale. Son but est de créer un modèle qui prédit la valeur d'une variable-cible depuis la valeur de plusieurs variables d'entrée.

Un arbre de décision commence généralement par un nœud d'où découlent plusieurs résultats possibles. Chacun de ces résultats mène à d'autres nœuds, d'où émanent d'autres possibilités.

Les algorithmes les plus connus et le plus utilisés dans l'apprentissage automatique est l'algorithme CART (Classification And Regression Trees) parce qu' il supporte la régression.




Figure 2.7 Decision Trees

K-NN(K Nearest Neighbours) :

L'algorithme des k plus proches voisins est un algorithme d'apprentissage supervisé, il est fondé sur l'analogie suivant : "Dis-moi qui sont tes amis, et je te dirais qui tu es".

La méthode des k-plus proches voisins (K-ppv, k-NN) se base sur une comparaison directe entre le vecteur caractéristique de l'instance à classer et les vecteurs des instances de la base d'apprentissage. La comparaison consiste en un calcul de distances entre ces instances. Puis à classer est assigner la classe majoritaire parmi les classes des k instances les plus proches à cette instance. [16].




Figure 2.8 K-NN

Naïve Bayes Classifier :

Est une technique de classification basées sur le théorème de Bays [8] de probabilité conditionnelles. qui peut être écrite mathématiquement comme suit:

$$P\left(\frac{A}{B}\right) = \frac{P\left(\frac{B}{A}\right) \cdot P(A)}{p(B)}$$

avec: A et B sont les événements et P(B) supérieure strict à 0.

Cet algorithme de classification reposant sur le principe commun selon lequel la valeur d'une fonctionnalité spécifique est indépendante de la valeur de toute autre fonctionnalité. Ils nous permettent de prédire la probabilité qu'un événement se produise en fonction des conditions que nous connaissons pour les événements en question.[22]

Les réseaux de neurones :

Sous-ensemble de technologies de l'intelligence artificielle, les réseaux de neurones sont des programmes informatiques dont l'architecture s'inspire de celle des neurones biologiques. Ces neurones artificiels, reliés entre eux et organisés en couches successives, apprennent à reconnaître des données à partir d'exemples et peuvent généraliser cet apprentissage afin d'aider à la prise de décision.




Figure 2.9 Les réseaux de neurones

Apprentissage profond et CNN :

Aperçu de l'apprentissage profond :

Au cours de la dernière décennie, Deep Learning DL devient l'un des sous-domaines les plus populaires de l'IA et du ML, en particulier dans la reconnaissance vocale, la vision par ordinateur et d'autres sujets intéressants. Son succès est motivé par trois facteurs : l'augmentation de la quantité de données disponibles, l'amélioration et le coût le plus bas du matériel (hardware) et des logiciels (software)[24 ,25,26,27 ;28], l'augmentation des capacités de traitement des puces (p. ex., unités GPU) [29]. Le DL est basé essentiellement sur l'utilisation de ANNs avec deux couches ou de nombreuses couches cachées. Nous distinguons de nombreux types de ANN.

Tout d'abord, un réseau d'alimentation où les données d'entrée se propagent à travers le réseau dans une passe directe, et chaque couche cachée reçoit son entrée de la sortie de la couche précédente afin de produire une sortie finale qui dépend de : la fonction d'activation et les paramètres de poids. Après cela, une descente de gradient est utilisée pour ajuster les poids du réseau afin de minimiser la fonction de perte représentant l'erreur entre la sortie attendue et la sortie calculée.

Deuxièmement, un perceptron multicouche MLP qui est un réseau neuronal d'alimentation entièrement connecté qui contient au moins une couche cachée. Ce type d'ANN est considéré comme le modèle de DL le plus simple en termes de mise en œuvre.

Troisièmement, le réseau neuronal convolutionnel CNN, c'est un réseau neuronal feedforward spécialisé qui a été développé pour traiter des données multidimensionnelles, telles que l'image. Ses origines se réfèrent à la néo-cognition proposée par Fukushima en 1980 [30].

Un CNN se compose essentiellement de trois couches : couche convolutionnelle, couche d'échantonnage (pooling layer) et couche entièrement connectée. Le premier modèle de CNN a été proposé par LeCUN et al., [31] en 1998 dans le domaine de la reconnaissance du caractère. De plus, de nombreuses architectures ANN alternatives ont été développées au fil des ans, y compris les réseaux neuronaux récurrents RNNs, les autoencodeurs et les réseaux stochastiques [32,33,34] qui présentent également une méthode d'optimisation avancée qui améliore le temps d'entraînement et les performances. L'apprentissage profond renvoie également à une solution efficace au problème de la représentation des données d'entrée qui est une phase critique de la ML, en particulier pour les problèmes complexes tels que la reconnaissance d'image et de la parole [35] où il est difficile de déterminer les meilleures fonctionnalités à traiter.

Les DNNs sont capables d'apprendre des représentations de haut niveau des entrées à travers leurs multiples couches cachées. Les premiers DNNs étaient apparus dans les années 1960, mais abandonnés, après cela depuis longtemps en faveur de l'approche ML, en raison de ses exigences élevées en termes de difficultés de formation et de performances inadéquates [36].

En 1986, RumelHart et coll., [37] ont proposé la méthode de rétropropagation pour mettre à jour efficacement les poids du réseau neural en utilisant le gradient de la fonction de perte à travers plusieurs couches. Malgré les résultats prometteurs donnés par les DNN à la fin des années 1980 [38] et 1990 [31], ils ont été abandonnés dans la pratique et la recherche en raison de nombreux problèmes.

En 2006, les recherches sur le DL ont été relancées, en particulier lorsque de nouvelles méthodes d'initialisation de la sensibilité des poids du DNN à l'aide d'une procédure supervisée de préformation par couche ont été mises au point par des chercheurs [39,40].

En 2012, Krizhevsky et al., [29] ont proposé un CNN profond pour le défi de reconnaissance visuelle à grande échelle (LSVRC) [41] réduisant le taux d'erreur de 26 % l'année précédente à 16 %. Ce CNN a été mis en œuvre sur plusieurs unités de traitement graphique GPU pour la première fois, cette technique importante est depuis devenue une pratique courante dans le travail de DL qui permet la formation de grands ensembles de données et augmente considérablement la vitesse de traitement et la productivité de la recherche.

En outre, l'utilisation d'une nouvelle fonction d'activation RELU (Rectified Linear Unit) a mis fin au problème de gradient et a permis une formation plus rapide des données. La technique Dropout est également utilisée comme méthode de régularisation pour diminuer le débordement dans les grands réseaux avec de nombreuses couches. Toutes ces améliorations intéressantes et l'internet croissant dans DL ont permis aux principales compagnies techniques d'augmenter les efforts de recherche, produisant de nombreux autres progrès dans le domaine. De nombreux cadres de DL ont un calcul tenseur [25,26,27,28] et des bibliothèques [29] ont été développées et mises à la disposition des chercheurs via des logiciels libres [42] et des services cloud [43,44] .

D'autre part, de nombreuses entreprises ont relevé les défis des big data lorsqu'elles ont exploré de grandes quantités de données pour prévoir les décisions de valeur [45].

Le concept de big data renvoie à des données qui dépassent la capacité des systèmes de stockage et de traitement de données standard [46]. Ce nouveau besoin en données oblige les chercheurs et les praticiens à adopter de nouvelles techniques pour stocker, manipuler et analyser les données. Ce grand volume de données nécessite également du matériel performant et des outils d'analyse très efficaces. D'autres défis ML sont apparus avec le Big Data : dimensionnalité élevée, infrastructures distribuées, exigences en temps réel, ingénierie des fonctionnalités [46]. Najafabadi et al., [46] discutent de l'utilisation de la DL pour résoudre les problèmes de données massives. La capacité des BND à extraire des caractéristiques significatives de grands ensembles de données non étiquetées est extrêmement importante, car elle est couramment rencontrée dans l'analyse des données massives.

L'extraction automatique de caractéristiques à partir de données non structurées et hétérogènes, par exemple, texte d'image, audio est très utile et difficile. Mais cette tâche devient facile avec l'utilisation de méthodes DL et un modèle linéaire simple peut être utilisé pour poursuivre les tâches ML plus efficacement.

D'autres tâches, y compris : des systèmes avancés de recherche d'information basés sur la sémantique comme l'indexation et le hachage sémantiques sont également devenus possibles avec ces caractéristiques de haut niveau, en outre, Le DL est également utilisé pour étiqueter les flux de données entrants, ce qui permet de classer et d'organiser les données en mouvement rapide.

En général, les DNN de grandes capacités sont adaptés pour apprendre des volumes importants de données émises par les sources de mégadonnées. En conclusion, nous pouvons dire que DL est actuellement en croissance plus rapide plus qu'avant.

Définition DL :

L'apprentissage profond « deep learning » est un ensemble de techniques d'apprentissage automatique, qui a la particularité d'être en mesure d'apprendre par lui-même.

Selon les fondateurs Yann LeCun, Yoshua Bengio et Geoffrey Hinton dans [12] :

"L'apprentissage profond permet aux modèles informatiques composés de plusieurs couches de traitement d'apprendre des représentations de données avec plusieurs niveaux d'abstraction."

Autre définition par les auteurs dans [13] :

"L'apprentissage profond est une classe de techniques d'apprentissage machine, où l'information est traitée en couches hiérarchiques pour comprendre les représentations et les caractéristiques des données dans des niveaux de complexité croissante."

L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités (les neurones) qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de « neurones » servent d'entrée aux calculs d'une deuxième couche et ainsi de suite.

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« big data »).[11]

Réseaux de neurones convolutionnels (CNN) :

Les réseaux de neurones convolutionnels (en anglais *Convolutional neural networks*), aussi connus sous le nom de CNNs est un atype d'apprentissage profond utilisé dans la reconnaissance et le traitement des images, et spécialement conçu pour l'analyse des pixels.[4]

Architecture d'un réseau CNN :

Un réseau de neurone convolutionnel se compose de plusieurs couches [2][5] comme le montre la figure2.10




Figure 2.10 Exemple sur un réseau de neurone convolutionnel

La couche de convolution (CONV)(convolution layer) :

Ces couches basent sur l'opération convolution pour le traitement et la reconnaissance d'images.[49], ce qui explique que les réseaux de neurones à convolution soient particulièrement bien adaptés à la reconnaissance d'image. Les couches convolutives se composent d'une grille rectangulaire de neurones ayant un petit champ réceptif étendu à travers toute la profondeur du volume d'entrée.[9]

Le terme "convolution" vient du fait que les réseaux CNN utilisent des opérations de convolution comme dans le traitement du signal ou d'images. Dans la couche de convolution, on applique un produit de convolution entre l'image originale ou celle obtenue dans la couche précédente avec un filtre dont des coefficients sont assimilés à des poids synaptiques. Le produit de convolution d'une image I avec un filtre F de taille $(s*s)$ est:

$$I_F(x, y) = \sum_{i=-s/2}^{s/2} \sum_{j=-s/2}^{s/2} I(x+i, y+j) F(i + \frac{s}{2}, j + \frac{s}{2})$$

La convolution agit comme un filtrage. Pour effectuer cette opération sur toute l'image, on définit une fenêtre de voisinage de taille (s*s) qui va se déplacer à travers toute l'image. Au tout début de la **convolution**, la fenêtre sera positionnée tout en haut à gauche de l'image puis elle va se décaler d'un certain nombre de cases (on appelle le **pas**) vers la droite et lorsqu'elle arrivera au bout de l'image, elle se décalera d'un **pas** vers le bas ainsi de suite jusqu'à ce que le **filtre** parcourt la totalité de l'image (Figure2.11)

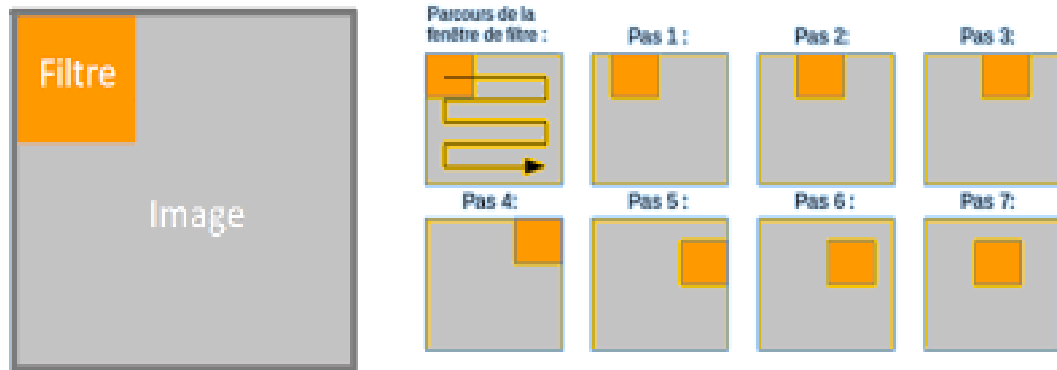


Figure 2.11 Schéma du parcours de la fenêtre de filtre sur l'image

Le but est de se servir des **valeurs** présentes dans le **filtre** à chaque pas. Par exemple si l'on définit une fenêtre 3 par 3, cela représentera 9 cases du tableau (c'est à dire 9 **pixels**). La **convolution** va effectuer une opération avec ces 9 **pixels**. (Figure2.12) illustre le principe du calcul la produit convolution .

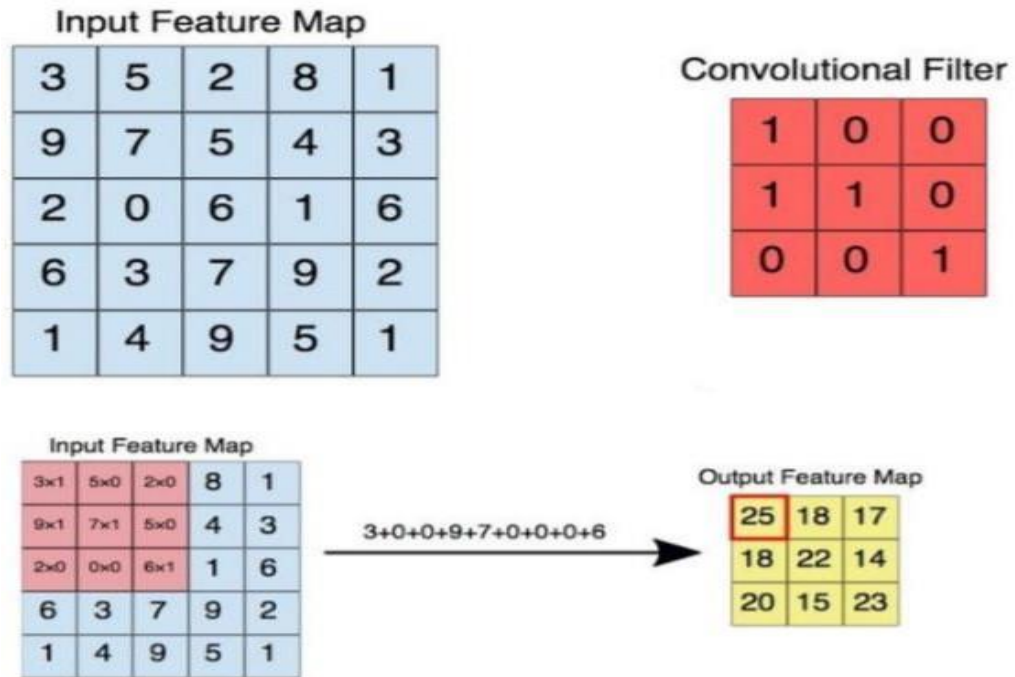


Figure 2.12 Application de la convolution sur un image

L'opération de convolution produit, en sortie une image appelée "carte de caractéristiques" ou "featuremaps".

Couche de pooling (POOL) :

Le pooling est une opération simple qui consiste à remplacer un carré de pixels par une valeur unique. De cette manière, l'image diminue en taille et se retrouve simplifiée. cette opération est appliquée après une couche convolutionnelle.

Pour appliquer le pooling, on commence par sélectionner un carré de pixels de taille $t*t$ (pour un pooling de $t*t$), puis on calcule la valeur qui va venir remplacer ce carré . Ensuite, on décale ce carré vers la droite de case n (stride = n). Une fois arrivé au bout à droite on recommence tout à gauche en décalant n fois vers le bas et en allant de nouveau vers la droite .

Il existe plusieurs manières pour réaliser le pooling .

➤ Le “**max pooling**”, qui revient à prendre la valeur maximale de la sélection. C’est le type le plus utilisé car il est rapide à calculer (immédiat), et permet de simplifier efficacement l’image. (figure2.13) illustre cette technique:




Figure 2.13 illustration de la methode maxpolling pour un pooling 2*2et stride2

➤ Le “mean pooling” (ou average pooling), soit la moyenne des pixels de la sélection : on calcule la somme de toutes les valeurs et on divise par le nombre de valeurs. On obtient ainsi une valeur intermédiaire pour représenter ce lot de pixels. (figure2.14) illustre cette technique:




Figure 2.14 illustration de la méthode averagepooling por un pooling de 2*2 et stride 2

Couche de correction Relu (Unités Rectifié Linéaire):

Après les couches des convolutions et pooling, nous allons appliquer la fonction **Relu** pour force les neurones à retourne des valeurs positif. Cette fonction (figure 2.15) est appelée aussi « fonction d'activation non saturante » est une fonction réelle non-linéaire définie par :

$$F(x) = \max (0, x)$$




Figure 2.15 Représentation graphique de fonction ReLU

En simple terme, la couche ReLU remplace tous les nombres négatifs par la valeur 0, (le noir , négatif) , et supprime donc l'écart entre blanc et gris et il n'y a plus de transition (gradient linéaire d'une couleur à l'autre) .[7]. (figure2.16) illustre cette fonction :




Figure 2.16 Application de ReLU à un matrice et à une image

Le résultat d'une couche ReLU est de la même taille que ce qui lui est passé en entrée, avec simplement toutes les valeurs négatives éliminées...

Couche entièrement connectée (FC)

Enfin, Après plusieurs couches de convolution et de max-pooling, nous allons expliquer la couche fully-connected (**Couche entièrement connectée**), **cette couche** constitue toujours la dernière couche d'un réseau de neurones. Elle est utilisée pour associer les différents motifs afin d'en déduire la classe.[7]

Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée.

La couche fully-connected permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille N , où N est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe.




Figure 2.17 Exemple des couches entièrement connectées

Conclusion :

Dans ce chapitre on a présenté les notions importantes qui sont en relation avec l'apprentissage automatique (définition, type, ...etc). Aussi qu'une vision générale sur l'apprentissage profond, tout en donnant en détail la méthode choisie dans notre travail de recherche qui est le CNNs. Le prochain chapitre, traite les outils utilisés pour la réalisation de notre projet.

CHAPITRE 03 OUTILS ET ENVIRONNEMENT DE DEVLOPEMENT

Introduction :

Dans notre projet, nous avons utilisé de nombreux outils, frameworks, bibliothèques et logiciels pour construire des modèles machine Learning et deep Learning. Nous allons mentionner tous ces outils et bibliothèques au long de ce chapitre .

Outils et environnement de développement

Avant de parler de l'implémentation de notre application, nous allons tout d'abord spécifier les outils utilisés que nous pouvons considérer un bon choix vu les avantages qu'ils offrent.

Python

Python est un langage de programmation, dont la première version est sortie en 1991. Créé par Guido van Rossum, il a voyagé du Macintosh de son créateur, qui travaillait à cette époque au Centrum voor Wiskunde en Informatica aux Pays-Bas, jusqu'à se voir associer une organisation à but non lucratif particulièrement dévouée, la Python Software Foundation, créée en 2001. Ce langage a été baptisé ainsi en hommage à la troupe de comiques les « Monty Python ».

Python est un langage de programmation de haut niveau et de licence libre (open source), il intègre le concept de classe ou d'objet c'est à dire est un langage qui permet la programmation orientée objet .

Le langage python n'est pas un langage compilé, mais un langage interprété, car il est directement exécuté sans passer par une phase de compilation qui permet de traduire le programme en langage machine, comme c'est le cas pour le langage C . aussi, python est un langage multiplateforme .C'est-à-dire, il fonctionne sur de nombreux systèmes d'exploitation : Windows, Mac OS X, Linux. [1]

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



Figure 3.1 Logo de Python

Python est récemment devenu le langage de programmation le plus utilisé dans les projets de machine learning et deep learning, science de données (data science), et l'intelligence artificielle.

Python dispose plusieurs bibliothèques et chaque bibliothèque a un travail spécifique, ce que fait langage très riche et plus utilisé. Les bibliothèques utilisées en machine learning est : Scikitlearn, Tensorflow, Pytorch, et libraires comme Numpy, Pandas, rdkit.

Interfaces graphiques

Python possède plusieurs modules disponibles pour la création de logiciels avec une interface graphique. Le plus répandu est Tkinter. Ce module convient à beaucoup d'applications et peut être considéré comme suffisant dans la plupart des cas. Néanmoins, d'autres modules ont été créés pour pouvoir lier Python à d'autres bibliothèques logicielles (« toolkit »), pour davantage de fonctionnalités, pour une meilleure intégration avec le système d'exploitation utilisé, ou simplement pour pouvoir utiliser Python avec sa bibliothèque préférée. En effet, certains programmeurs trouvent l'utilisation de Tkinter plus pénible que d'autres bibliothèques.

Les principaux modules donnant accès aux bibliothèques d'interface graphique sont Tkinter et Pmw (Python megawidgets)⁴⁴ pour Tk, wxPython pour wxWidgets, PyGTK pour GTK+, PyQt et PySide pour Qt, et enfin FxPy pour le FOX Toolkit. Il existe aussi une adaptation de la bibliothèque SDL Pygame, un binding de la SFML PySFML, ainsi qu'une bibliothèque écrite spécialement pour Python Pyglet .

Anaconda :

Anaconda est une distribution libre et open source des langages de programmation Python et R appliqué au développement d'applications dédiées à la science des données et à l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement. Les versions de paquetages sont gérées par le système de gestion de paquets conda.

La distribution Anaconda est utilisée par plus de 6 millions d'utilisateurs et comprend plus de 250 paquets populaires en science des données adaptés pour Windows, Linux et MacOS. [50]



Figure 3.2 Logo Anaconda

Keras :

keras est une API (application programming interface) réservée pour les réseaux neuronaux de haut niveau pour un développement et une expérimentation rapide . Il fonctionne au-dessus de TensorFlow, CNTK, ou Theano.[20]

Keras est l'outil le plus utilisé en deep learning et en reconnaissance d'image .Cette librairie open-source, créée par François Chollet permet de créer facilement et rapidement des réseaux neurones, en se basant sur les principaux frameworks (tensorflow).



Figure 3.3 Logo de Keras

Keras est l'API officielle de haut niveau de tensorflow, il se caractérise par :

- Permet le prototypage rapide et facile (par sa convivialité, sa modularité et son extensibilité).
- met l'accent sur l'expérience utilisateur .
- Production facile des modèles.
- Supporte à la fois les réseaux convolutifs et les réseaux récurrents ainsi que la combinaison des deux.
- Fonctionne de façon transparente sur CPU et GPU.
- Multi-backend (keras, theano, CNTK, ...)et multi-Platform (Unix, Windows,).

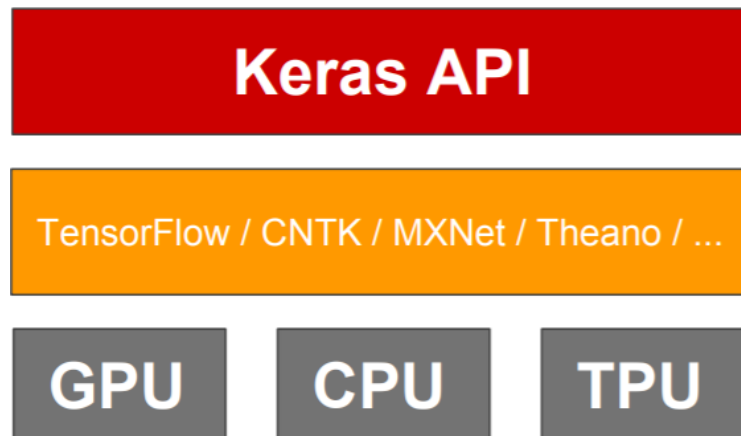


Figure 3.4 Hiérarchie de Keras

TensorFlow :

Tensorflow est une plateforme (Framework) open source de machine Learning créée par Google, permettant de développer et d'exécuter des applications de Machine Learning et de Deep Learning . Il s'agit d'une boîte à outils permettant de résoudre facilement des problèmes mathématiques extrêmement complexes . il permet aux chercheurs de développer des architectures d'apprentissage expérimentales et de les transformer en logiciels.[21]



Figure 3.5 Logo de tensorflow

Cette bibliothèque open-source est utilisée pour concevoir et former un modèle de deep learning comme CNN ou RNN ou ANN. Aussi, il permet aux développeurs de **créer** des graphiques de dataflow (dataflow graphs).[19]

Tensorflow permet notamment d'entraîner et d'exécuter des réseaux de neurones pour la classification de chiffres écrits à la main, la reconnaissance d'image, les plongements de mots, les réseaux de neurones récurrents, les modèles sequence-to-sequence pour la traduction automatique, ou encore le traitement naturel du langage.

Les application tensorflow peuvent s'exécuter sur CPU, GPU ou TPU .[21]

Tensorflow fonctionne en 3 phases :

1. Prétraitement des données .
2. Construction du modèle .
3. Apprentissage et test du modèle.

Pourquoi TensorFlow ?

Que vous soyez expert ou débutant, TensorFlow est une plate-forme de bout en bout qui facilite la création et le déploiement de modèles ML. TensorFlow offre plusieurs niveaux d'abstraction afin que vous puissiez choisir celui qui convient le mieux à vos besoins. Créez et entraînez des modèles à l'aide de l'API Keras de haut niveau, ce qui facilite la mise en route de TensorFlow et l'apprentissage automatique. Si vous avez besoin de plus de flexibilité, une exécution rapide permet une itération immédiate et un débogage intuitif. Pour les tâches de formation de grande taille, utilisez l'API de stratégie de distribution pour une formation distribuée sur différentes configurations matérielles sans modifier la définition du modèle. [50]

Scikit-learn

Scikit-learn est une bibliothèque open source polyvalente pour l'analyse de données écrite en python. Elle est développée par de nombreux contributeurs notamment dans le monde académique par des instituts français d'enseignement supérieur et de recherche comme Inria et Télécom ParisTech.

Cette bibliothèque permet aux utilisateurs d'effectuer diverses tâches d'apprentissage automatique. Elle comprend notamment des fonctions pour estimer des forêts aléatoires, des régressions logistiques, des algorithmes de classification, et les machines à vecteurs de support. Elle est conçue pour s'harmoniser avec des autres bibliothèques libre Python, notamment NumPy et SciPy.

Numpy :

Numpy est la bibliothèque de base pour l'informatique scientifique en Python. Il contient des tableaux multidimensionnels et des structures de données matricielles. Elle peut être utilisée pour effectuer un certain nombre d'opérations mathématiques sur des tableaux tels que des routines trigonométriques, statistiques et algébriques. Par conséquent, la bibliothèque contient un grand nombre de fonctions mathématiques, algébriques et de transformation.

Pandas :

Pandas est un outil de manipulation de données de haut niveau développé par Wes McKinney. Il est construit sur le package Numpy et sa structure de données clés est appelée DataFrame. Les DataFrames vous permettent de stocker et de manipuler des données tabulaires dans des lignes d'observations et des colonnes de variables.[18]

Matplotlib

Matplotlib est une bibliothèque python pour le traçage 2D, utilisée pour produire des figures de haute qualité, nous pouvons l'utiliser dans tous les environnements Python de développement, ces figures peuvent être enregistrées dans différents formats pour en faciliter l'utilisation pour les publications scientifiques [17].

Conclusion :

Ce chapitre nous a permis d'acquérir une bonne base de connaissance sur python, tensorflow et keras. Le prochain chapitre, traite les détails de la conception, ainsi que la méthode et les outils utilisés pour la réalisation de notre projet.

CHAPITRE 04

:IMPLEMENTATION ET RESULTATS

Le modèle CNN proposé

Dans le présent travail, nous avons développé un classificateur automatique qui permet de classer un grand nombre de vêtements de mode en dix (10) classes données basées sur deux approches : l'approche ML classique et l'approche DL.

Initialement, nous avons procédé à la tâche de classification en utilisant de nombreux algorithmes de ML, notamment : LR, LDA, KNN, CART, NB et SVM. Nous avons ensuite proposé un modèle CNN composé de nombreuses couches convolutionnelles, une couche MaxPooling et une couche entièrement connectée.

Enfin, nous avons établi une comparaison entre les différents algorithmes. Comme outils de programmation, nous avons utilisé Python, Tensorflow et Keras qui sont les plus utilisés dans ce domaine. La figure 4.1, résume la tâche de classification en fonction des deux approches, tandis que la figure 4.2 présente un diagramme détaillé du modèle CNN proposé afin d'améliorer le rendement de la tâche de classification.

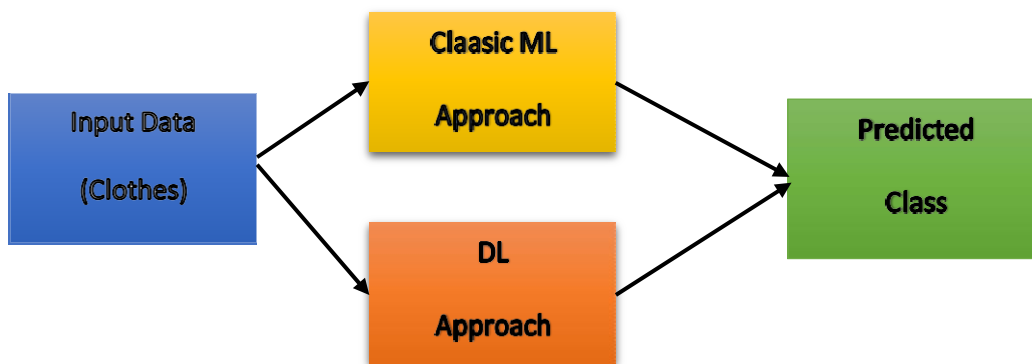


Figure 4.1 Processus de Classification des vêtements




Figure 4.2 Architecture de modelé CNN proposé

Expérimentation et résultats obtenus :

Dataset utilisée :

Dans nos expériences, nous avons utilisé le dataset Fashion Mnist qui remplace le dataset Digits Mnist classique contenant beaucoup de chiffres manuscrits. Nous notons que les membres de la communauté de l'IA, du ML et de la science des données (data) préfèrent

travailler sur dataset Digits Mnist et l'utiliser comme référence pour valider leurs algorithmes. En fait, Digits Mnist est souvent le premier dataset utilisé par les chercheurs dans le domaine de ML, car la règle d'or pour eux est « si ne fonctionne pas sur Mnist, il ne fonctionnera pas du tout

». Ainsi, Fashion Mnist Dataset est la meilleure évolution de Digits Mnist dataset. Il contient

images en niveaux de gris (grayscale) distribuées sur 10 catégories. Chaque image représente un vêtement individuel à basse résolution (28x28 pixels).

Notre dataset peut être divisé en deux sous-ensembles : le sous-ensemble de training contenant 60000 images pour construire et apprendre le modèle de prévision, et le sous-ensemble de test contenant 10000 images pour évaluer la performance de chaque algorithme utilisé.

Fashion Mnist Dataset est souvent privilégié par les chercheurs pour de nombreuses raisons :

1. Digits Mnist dataset est trop facile : offre une précision qui peut atteindre 99,7% sur les digits , donc les algorithmes ML classiques peuvent aussi atteindre 97% facilement.

2. Digits Mnist est surutilisé : le chercheur en recherche sur le cerveau de Google et l'expert en apprentissage profond Ian GoodFellow appelle pour s'éloigner de Digits Mnist.

3. Les digits de Mnist représentent les tâches de CV modernes, comme l'a noté en 2017 l'expert en apprentissage profond et l'auteur de Keras, François Chollet In Fashion Mnist.

Les exemples sont attribués à l'une des dix (10) étiquettes décrites dans le.

Lable	Discription	Nb.Exemples
0	T-Shirt/Top	6.000
1	Trouser	6.000
2	Pullover	6.000
3	Robe	6.000
4	Coat	6.000
5	Sandal	6.000
6	Shirt	6.000
7	Sneaker	6.000
8	Bag	6.000
9	Ankle boot	6.000

Tableau 4-1 Labls attribuées a chaque occurence dans database Fashion Mnist

Le dataset Fashion Mnist prend la forme d'un tableau de 60.000 x 785 pour training set et de 10.000 x 785 pour test set. Sachant que le premier nombre exprime le nombre d'exemples ou d'images, et le seconde nombre exprime le nombre d'attributs. Ainsi, chaque ligne du tableau représente l'image d'un article de vêtement tel qu'il est expliqué dans le tableau 1, la colonne 0 représente le label de l'image, les colonnes 1, ... , 784 sont les pixels composant chaque image d'article.

Par exemple, la ligne 50 représente sneaker, 100 est un T-shirt, 800 une robe, etc.




Figure 4.3Ligne50 :Image en niveaux de gris representant une Sneaker




Figure 4.4Ligne 100 :Image en niveaux de gris representant un T-shirt

Évaluation

Afin de valider les différents algorithmes de ML et d'obtenir le meilleur modèle, nous avons utilisé la méthode de validation croisée consistant à diviser notre dataset en 10 parties, à apprendre sur 9 et à tester sur 1, puis répéter pour toutes les combinaisons de segments (splits) train/test. Pour le modèle CNN, nous avons utilisé deux paramètres : loss value, et accuracy metric.

1. Accuracy metric : Il s'agit d'un rapport entre le nombre d'instances correctement prédites et le nombre total d'instances dans le dataset multiplié par 100 pour donner un pourcentage (p. ex., 90 % accurate).
2. Loss value : utilisée pour optimiser un algorithme ML ou un modèle DL. Elle doit être calculée sur des datasets d'apprentissage et de validation. Son interprétation simple est basée sur l'efficacité de l'algorithme ML ou du modèle construit par le DL dans ces deux datasets. Il donne la somme des erreurs commises pour chaque exemple dans l'ensemble d'apprentissage ou de validation.
3. Précision (Precision) : Il s'agit du nombre de résultats positifs réels et corrects divisé par le nombre total de résultats positifs prédits par le classificateur.

4. Rappel (Recall): C'est le nombre de résultats positifs réels et corrects divisé par le nombre de tous les exemples pertinents dans le dataset (tous les exemples qui auraient dû être identifiés comme positifs).
5. Score -F1 : est la moyenne harmonique entre la précision et le rappel. L'intervalle pour le score-F1 est de [0, 1]. Il vous indique à quel point votre classificateur est précis (combien d'instances sont classifiées correctement), ainsi que sa robustesse.
6. Matrice de confusion(Confusion Matrix) : La matrice de confusion est l'une des mesures les plus intuitives et les plus faciles utilisées pour trouver l'exactitude et l'exactitude du modèle. Il est utilisé pour le problème de classification où la sortie peut être de deux ou plusieurs types de classes et donner l'exactitude pour chaque classe.

Illustration des résultats obtenus

Pour construire le meilleur modèle prédictif et atteindre le taux de précision le plus élevé, nous avons effectué deux tâches :

1. Appliquer de nombreux algorithmes ML classiques, y compris : Logistic Regression LR, Linear Discriminant Analysis LDA, K-nearest Neighbours KNN, Decision Tree (variante CART), Gaussien Naïve Bayes NB, Support Vector Machine SVM. Pour ce faire, nous avons utilisé la bibliothèque scikit-learn de python contenant les algorithmes d'apprentissage les plus connus.
2. Conception d'un modèle CNN (Convolutional Neural Network) composé de plusieurs couches, comme l'explique la figure 1 :
 - Une première couche convolutionnelle Conv1 constituée de 32 filtres de taille (3x3).
 - Une seconde couche convolutionnelle Conv2 constituée de 32 filtres de taille (3x3).
 - Une couche de dropout pour éviter le débordement.
 - Un MaxPoolingMaxPool de taille (2x2) permettant de réduire les dimensions des images issues de la couche précédente après application des différents filtres de Conv1.
 - Une normalisation par lots est une technique pour améliorer la vitesse
 - Une couche de dropout pour éviter le débordement.

- Une troisième couche convolutionnelle Conv3 constituée de 64 filtres de taille (5x5).
- Une quatrième couche convolutionnelle Conv4 constituée de 64 filtres de taille (5x5).
- Une couche de dropout pour éviter le débordement.
- Un MaxPoolingMaxPool de taille (2x2) permettant de réduire les dimensions des images issues de la couche précédente après application des différents filtres de Conv1.
- Une normalisation par lots est une technique pour améliorer la vitesse
Une couche de dropout pour éviter le débordement.
- Une couche complètement connectée FC permettant de transformer la sortie de la couche précédente en vecteur mono-dimensionnel.
- Couche de sortie représentée par un vecteur mono-dimensionnel réduit ayant comme taille le nombre de classes.
- Pour tous les couches précédentes, une fonction d'activation Relu et une fonction softmax sont utilisées pour normaliser les valeurs obtenues dans chaque couche.

Layer Type	Output Shape	Nb. parameters
conv2d_1 (Conv2D)	(None, 26, 26, 32)	320
conv2d_2 (Conv2D)	(None, 24, 24, 32)	9248
dropout_1 (Dropout)	(None, 24, 24, 32)	0
max_pooling2d_1 (MaxPooling2)	(None, 12, 12, 32)	0
batch_normalization_1 (Batch	(None, 12, 12, 32)	128
conv2d_3 (Conv2D)	(None, 8, 8, 64)	51264
conv2d_4 (Conv2D)	(None, 4, 4, 64)	102464
dropout_2 (Dropout)	(None, 4, 4, 64)	0
max_pooling2d_2 (MaxPooling2)	(None, 2, 2, 64)	0

batch_normalization_2 (Batch	(None, 2, 2, 64)	256
flatten_1 (Flatten)	(None, 256)	0
dense_1 (Dense)	(None, 128)	32896
dropout_3 (Dropout)	(None, 128)	0
batch_normalization_3 (Batch	(None)	512
dense_2 (Dense)	(None, 10)	1290
Total parameters		198.378
Trainable parameters		197.930

Tableau 4-2 Description du model CNN proposé

Tableau 4-3 ci-dessous résume les résultats obtenus après l’application des algorithmes ML.

Algorithm	Accuracy
LR	97.82%
LDA	97.62%
KNN(K=5,Matrice=minkowski)	97%
KNN(K=5,Matrice=Cosine)	97.78%
CART	97.78%
NB	00.44%
SVM	97.85%

Tableau 4-3 Précision (Accuracy) après application de differents algorithmes ML

Tableau 4-4 ci-dessous résume les résultats obtenus après l'application du modèle CNN proposé

	Loss value	Accuracy value
Training set	0.1013	0.9625
Test set	0.2407	0.9217

Tableau 4-4 Loss Value et Accuracy value du model CNN proposé

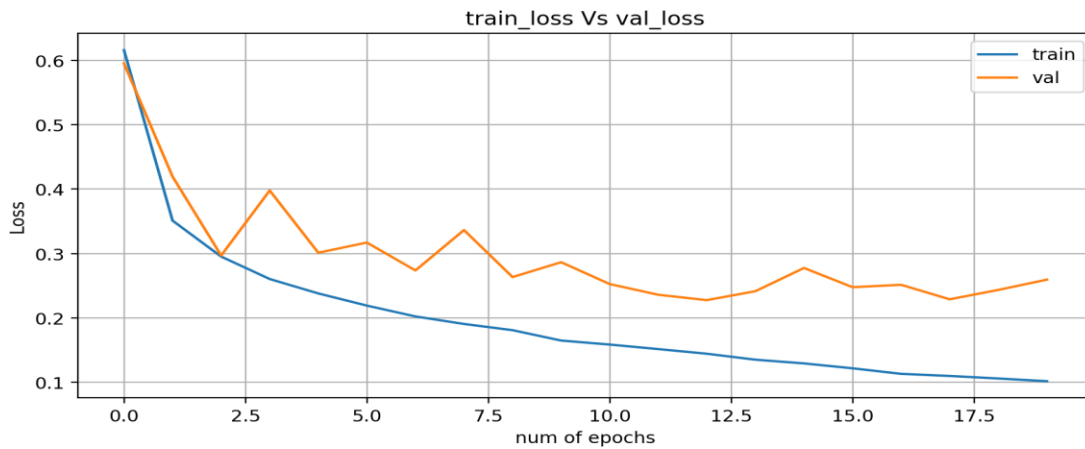


Figure 4.5 Training loss Vs Validation Loss du model CNN proposé

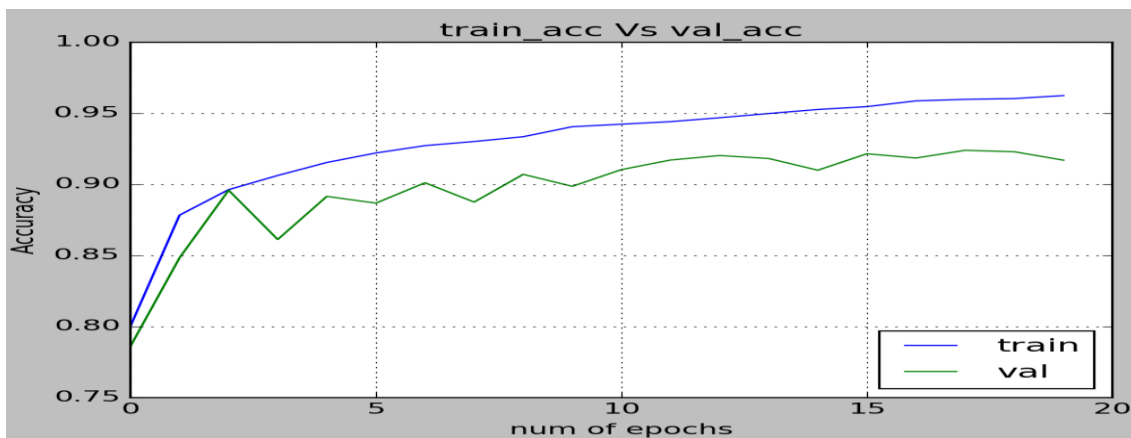


Figure 4.6 Training accuracy VS Validation accuracy du model CNN proposé

Discussion

Le tableau 4-3 résume les résultats obtenus lors de l'application des différents algorithmes de ML, notamment : LR, LDA, KNN, DT (CART), NB, SVM. Nous observons que LR, LDA, KNN et SVM donnent une précision de classification élevée (> 80%), tandis que DT (variante CART) et NB donnent une valeur de précision (accuracy) relativement faible (accuracy 80%) par rapport aux algorithmes précédents. Nous notons également que la mesure de similitude utilisée avec l'algorithme KNN influence directement les performances de l'algorithme, par exemple dans notre cas, lorsque nous avons utilisé la similitude Minkowski la précision (accuracy) était de 85,5%, mais avec la similitude cosinus la précision (accuracy) était plus élevée (86, 04%).

Le tableau 4-4 présente les résultats obtenus lors de l'application du modèle CNN proposé à training set et test set. Les mesures de performance sont considérées dans ce cas, la valeur de perte (loss value) qui calcule la somme des erreurs après la formation (training) du modèle, et la valeur de précision (accuracy value) qui donne le taux d'exactitude. Il est clair que la valeur de perte (loss value) est très faible par rapport à la précision qui est très élevée et dépend de la taille de l'ensemble utilisé. C'est la raison pour laquelle la précision de l'ensemble d'entraînement est supérieure à la précision de test set. De même, la figure 4.5 montre l'évaluation de training loss et validation loss au fil du temps et en fonction du nombre d'époques. Il commence très haut pour training loss et se termine très bas en raison du grand nombre d'échantillons, mais sa variation pour validation set n'est pas très rapide et semble relativement stable. De même, figure 4.6 illustre l'évolution de training accuracy et validation accuracy en fonction du nombre d'époques. Contrairement à loss value, la précision (accuracy) commence très bas et se termine très haut. Cette propriété est plus claire avec training set en raison de sa grande taille.

Interface :

On lançant le logiciel nous allons voir fenêtre principale suivant comme nous montre la *figure 4.8*



Figure 4.7 Illustration de fenêtre principale de l'application

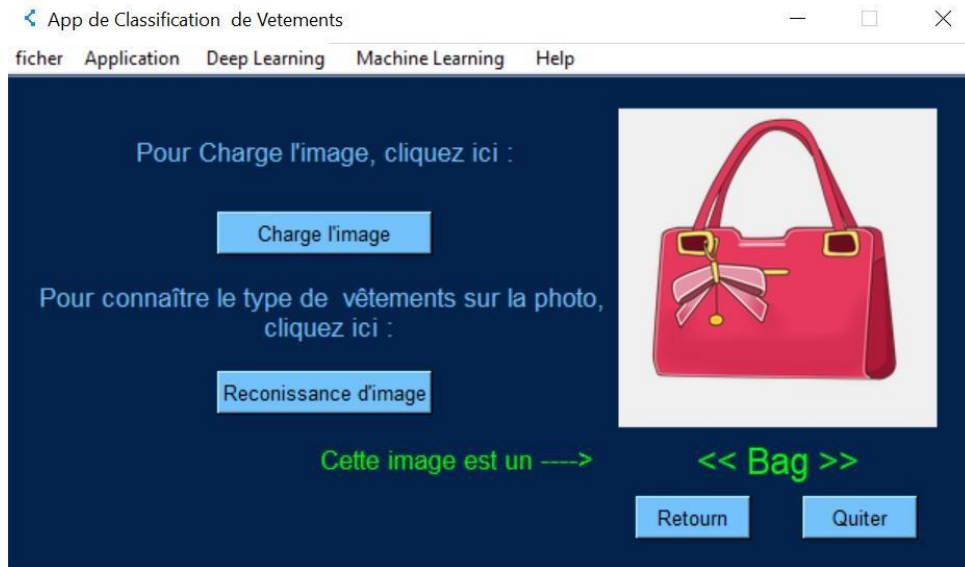


Figure 4.8 illustration de reconnaissance d'image

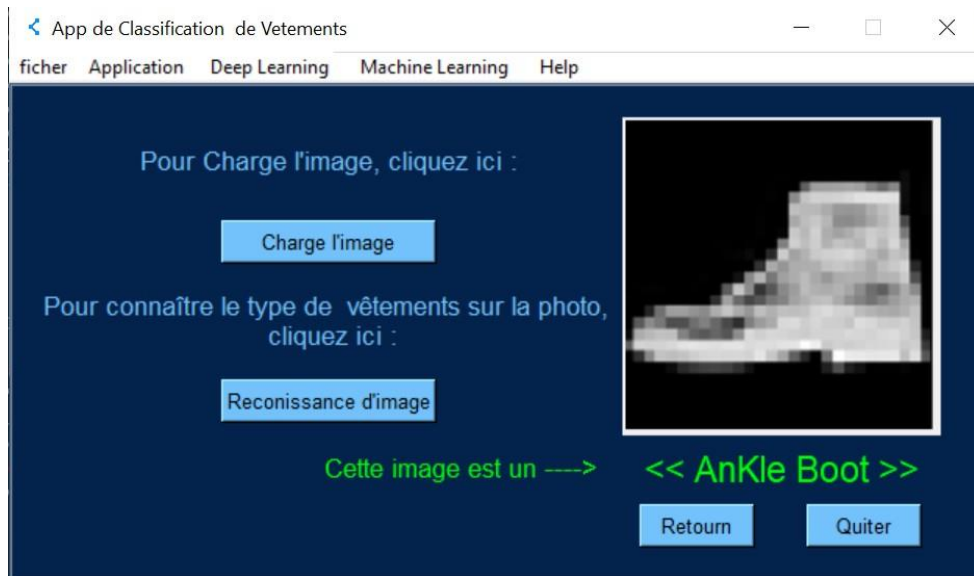


Figure 4.9 illustration la reconnaissance d'image de niveaux gris

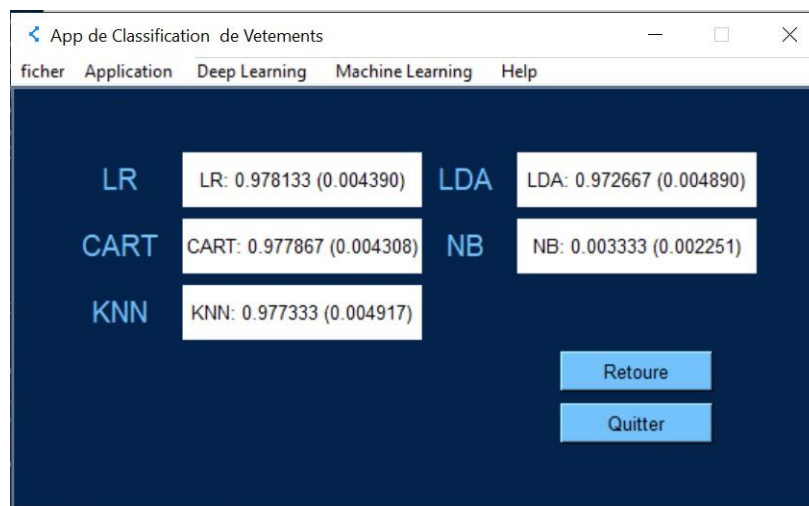


Figure 4.10 illustration Accuracy de deferents algorithmes ML

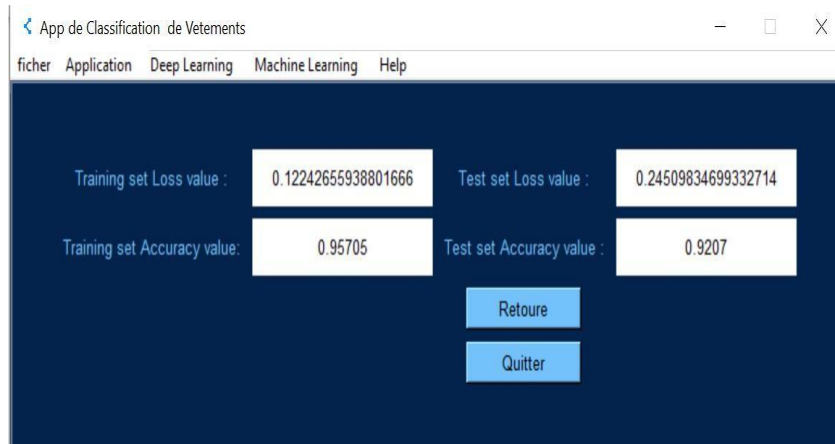


Figure 4.11 Illustration accuracy et Loss valuer de model CNN

Conclusion :

Notre société devient de plus en plus intelligente a l'heure actuelle, En particulier dans le domaine de l'intelligence artificielle et plus particulier le domaine de la reconnaissance d'image qui a connu une évolution majeure depuis l'apparition du Deep Learning , Dans ce projet nous avons proposé une approche pour classifier efficacement des vêtements de mode en se basant sur l'approche d'apprentissage profond DL. A cet effet, nous avons parlé des différents types des algorithmes du machine Learning, ainsi que les notions fondamentales des deep learning en général et des réseaux de neurones convolutionels en particulier, en présentant les différents types de couches utilisées dans la classification.

CONCLUSION GENERALE

Au cours des dernières années, la reconnaissance des objets est basée essentiellement sur l'approche ML qui donne une performance élevée. Quelques années plus tard, d'importants progrès ont été réalisés dans le domaine du ML, notamment avec l'apparition d'un nouveau sous-domaine appelé apprentissage profond. Il est principalement basé sur l'utilisation de nombreux réseaux neuronaux d'unités simples interconnectées afin d'extraire des modèles significatifs à partir d'une grande quantité de données pour résoudre un problème complexe tel que : la classification des images médicales, la détection de fraude, la reconnaissance des caractères, etc. À l'heure actuelle, nous sommes en mesure d'utiliser des ensembles de données plus vastes pour apprendre des modèles puissants et de meilleures techniques pour éviter le surapprentissage (overfitting) et le sous-apprentissage (underfitting). Jusqu'à nos jours, les résultats obtenus dans ce domaine de recherche sont très surprenants dans différents domaines. Nous parlons de valeurs de précision (accuracy) très élevées qui dépassent souvent le seuil de 90 %. Par exemple, le taux de précision (accuracy rate) sur les chiffres est supérieur à 97 %.

Dans le présent travail, nous avons effectué une tâche de classification sur un ensemble de données d'articles de vêtement de mode. Nous avons utilisé dans un premier temps de nombreux algorithmes ML dont : LR, LDA, KNN, DT (CART), NB, SVM. Nous avons obtenu de bons résultats de précision en particulier sur LR, LDA, KNN. Dans un deuxième étape, nous avons construit un modèle CNN pour effectuer la même tâche de classification. A titre de perspective, nous proposons d'améliorer ces résultats en améliorant l'architecture du modèle construit par CNN en changeant certains paramètres du modèle tels que : le nombre de filtres, le nombre de couches de convolution et de maxpooling, la taille de chaque filtre, le nombre de périodes d'apprentissage et la taille des lots de données. Une autre suggestion semble importante, est de combiner CNN avec des réseaux récurrents Resnets.

REFERENCE BIBLIOGRAPHIQUES

- [1] XAVIER DUPRÉ, PROGRAMATION AVAC LANGAGE PYTHON , ELLIPSES ÉDITION MARKETING S,A, 2009
32 ,RUE BARGUE 75740 PARIS CEDEX 15 .
- [2] SAAD ALBAWI , TAREQ ABED MOHAMMED , SAAD ALZAWI, UNDERSTANDING OF A
CONVOLUTIONAL NEURAL NETWORK , CONFERENCE: THE INTERNATIONAL CONFERENCE ON
ENGINEERING AND TECHNOLOGY 2017, AT ANTALYA, TURKEY
- [3] TAIWO AYODELE , TYPES OF MACHINE LEARNING ALGORITHMS , NEW ADVANCES IN MACHINE
LEARNING , UNIVERSITY OF PORTSMOUTH
- [4] KEIRON O'SHEA AND RYAN NASH , AN INTRODUCTION TO CONVOLUTIONAL NEURAL NETWORKS,
ARTICLE , DEPARTMENT OF COMPUTER SCIENCE, ABERYSTWYTH UNIVERSITY, CEREDIGION, SY23 3DB ,
SCHOOL OF COMPUTING AND COMMUNICATIONS, LANCASTER UNIVERSITY, LANCASHIRE, LA1
- [5] TIANYI LIU, SHUANGSANG FANG, YUEHUI ZHAO, PENG WANG, JUN ZHANG , IMPLEMENTATION OF
TRAINING CONVOLUTIONAL NEURAL NETWORKS ,ARTICLE , UNIVERSITY OF CHINESE ACADEMY OF
SCIENCES, BEIJING, CHINA
- [6] VLADIMIR NASTESKI , AN OVERVIEW OF THE SUPERVISED MACHINE LEARNING METHODS ,ARTICLE,
UNIVERSITY "ST. KLIMENT OHRIDSKI" - BITOLA
- [7] VINCENT LORRAIN , ETUDE ET CONCEPTION DE CIRCUITS INNOVANTS EXPLOITANT LES
CARACTERISTIQUES DES NOUVELLES TECHNOLOGIES MEMOIRES RESISTIVES , THESE DE DOCTORAT DE
L'UNIVERSITE PARIS-SACLAY PREPAREE A L'UNIVERSITE PARIS-SUD
- [8] ASAD ABDI, THREE TYPES OF MACHINE LEARNING ALGORITHMS , PRÉSENTATION , NOVEMBER 2016
- [9] AFSHINE AMIDI AND SHERVINE AMIDI , SUPER VIP CHEATSHEET: MACHINE LEARNING , SEPTEMBER
15, 2018
- [9] CORENTIN HARDY , CONTRIBUTION AU DEVELOPPEMENT DE L'APPRENTISSAGE PROFOND DANS LES
SYSTEMES DISTRIBUES , THÈSE DE DOCTORAT DE , L'UNIVERSITE DE RENNES 1 COMUE
UNIVERSITE BRETAGNE LOIRE , E 8 AVRIL 2019
- [10] MAIKEL MARDJAN , FREE AND OPEN MACHINE LEARNING RELEASE 1.0.1
- [11] REMY SUN , APPRENTISSAGE PROFOND ET ACQUISITION DE REPRESENTATIONS LATENTES DE
SEQUENCES PEPTIDIQUES, DEPARTEMENT INFORMATIQUE, ENS RENNES, CAMPUS DE KER LANN, BRUZ,
FRANCE SOUS LA DIRECTION DE FRANÇOIS COSTE , 28 FEVRIER 2017
- [12] DEEP LEARNING YANN LECUN, YOSHUA BENGIO GEOFFREY HINTON. 2015
- [13] 40 PYTHON DEEP LEARNING. IVAN VASILEV, DANIEL SLATER, GIANMARIO SPACAGNA, PETER
ROELANTS, VALENTINO ZOCCA. 2019

- [14] OLIVER THEOBALD , MACHINE LEARNING FOR ABSOLUTE BEGINNERS , SECOND EDITION COPYRIGHT © 2017 BY OLIVER THEOBALD
- [15] WEI-LUN CHAO , , MACHINE LEARNING TUTORIAL , FIRST EDITED IN DECEMBER, 2011 DISP LAB, GRADUATE INSTITUTE OF COMMUNICATION ENGINEERING, NATIONAL TAIWAN UNIVERSITY
- [16] GHENAM BOCHRA , LES RESEAUX DE NEURONE CONVOLUTIONEL (CNN) POUR LA CLASSIFICATION DES IMAGES ASSOCIEES AUX PLACES DE STATIONNEMENT D'UN PARC DE VEHICULE ,MEMOIRE , UNIVERSITE DJILALI BOUNAAMA KHEMIS MILIANA
- [17] "MATPLOTLIB OFFICIEL WEB SITE," [ONLINE]. AVAILABLE: [HTTPS://MATPLOTLIB.ORG/](https://matplotlib.org/).
- [18]"PANDAS," [ONLINE]. AVAILABLE: [HTTPS://PANDAS.PYDATA.ORG/](https://pandas.pydata.org/).
- [19] "GITHUB TENSORFLOW," [ONLINE]. AVAILABLE: [HTTPS://GITHUB.COM/TENSORFLOW/TENSORFLOW](https://github.com/tensorflow/tensorflow).
- [20] "KERAS," [ONLINE]. AVAILABLE: [HTTPS://KERAS.IO/](https://keras.io/).
- [21] TENSORFLOW," GOOGLE, [ONLINE]. AVAILABLE: [HTTPS://WWW.TENSORFLOW.ORG/](https://www.tensorflow.org/).
- [22] [HTTPS://LE-DATASCIENIST.FR/LES-ALGORITHMES-DE-NAIVES-BAYES](https://le-datascientist.fr/les-algorithmes-de-naives-bayes)
- [23] [HTTPS://DATAANALYTICSPOST.COM/LEXIQUE/SVM/](https://dataanalyticspost.com/lexique/svm/)
- [24] ABADI ET AL : M, AGARWAL A, BARHAM P, BREVD E, CHEN Z, CITRO C, CORRADO GS, DAVIS A, DEAN J, DEVIN M, GHEMAWAT S, GOODFELLOW I, HARP A, IRVING G, ISARD M, JIA Y, JOZEFOWICZ R, KAISER L, KUDLUR M, LEVENBERG J, MANE D, MONGA R, MOORE S, MURRAY D, OLAH C, SCHUSTER M, SHLENS J, STEINER B, SUTSKEVER I, TALWAR K, TUCKER P, VANHOUCHE V, VASUDEVAN V, VIEGAS F, VINYALS O, WARDEN P, WATTENBERG M, WICKE M, YU Y, ZHENG X. TENSORFLOW: LARGE-SCALE MACHINE LEARNING ON HETEROGENEOUS SYSTEMS 2015. [HTTP://TENSORFLOW.ORG/](http://tensorflow.org/). ACCESSED 1 NOV 2018.
- [25] THEANO DEVELOPMENT TEAM. THEANO: A PYTHON FRAMEWORK FOR FAST COMPUTATION OF MATHEMATICAL EXPRESSIONS. 2016. ARXIV E-PRINTS ARXIV:1605.02688.
- [26] CHOLLET F, ET AL. KERAS. 2015. [HTTPS://KERAS.IO](https://keras.io). ACCESSED 1 NOV 2018.
- [27] PASZKE A, GROSS S, CHINTALA S, CHANAN G, YANG E, DEVITO Z, LIN Z, DESMAISON A, ANTIGA L, LERER A. AUTOMATIC DIFFERENTIATION IN PYTORCH. IN: NIPS-W. 2017.
- [28] CHETLUR S, WOOLLEY C, VANDERMERSCH P, COHEN J, TRAN J, CATANZARO B, SHELHAMER, E. CUDNN: EFFICIENT PRIMITIVES FOR DEEP LEARNING 2014.
- [29] KRIZHEVSKY A, SUTSKEVER I, HINTON GE. IMAGENET CLASSIFICATION WITH DEEP CONVOLUTIONAL NEURAL NETWORKS. IN: NEURAL INFORMATION PROCESSING SYSTEMS. 2012. P. 25. [HTTPS://DOI.ORG/10.1145/3065386](https://doi.org/10.1145/3065386).

- [30] FUKUSHIMA K. NEOCOGNITRON: A SELF-ORGANIZING NEURAL NETWORK MODEL FOR A MECHANISM OF PATTERN RECOGNITION UNAFFECTED BY SHIFT IN POSITION. *BIOLCYBERN.* 1980;36(4):193–202. [HTTPS://DOI.ORG/10.1007/BF00344251](https://doi.org/10.1007/BF00344251).
- [31] LECUN Y, BOTTOU L, BENGIO Y, HAFNER P. GRADIENT-BASED LEARNING APPLIED TO DOCUMENT RECOGNITION. *PROC IEEE.* 1998;86(11):2278–324.] WITTEN IH, FRANK E, HALL MA, PAL CJ. DATA MINING, FOURTH EDITION: PRACTICAL MACHINE LEARNING TOOLS AND TECHNIQUES. 4TH ED. SAN FRANCISCO: MORGAN KAUFMANN PUBLISHERS INC.; 2016.
- [32] GOODFELLOW I, BENGIO Y, COURVILLE A. DEEP LEARNING. CAMBRIDGE: THE MIT PRESS; 2016.
- [33] MINAR MR, NAHER J. RECENT ADVANCES IN DEEP LEARNING: AN OVERVIEW. 2018. ARXIV:1807.08169.[22] LECUN Y, BENGIO Y, HINTON G. DEEP LEARNING. *NATURE.* 2015;521:436.
- [34] SCHMIDHUBER J. DEEP LEARNING IN NEURAL NETWORKS: AN OVERVIEW. *NEURAL NETW. ;*61:85–117.
- [35] RUMELHART DE, HINTON GE, WILLIAMS RJ. LEARNING REPRESENTATIONS BY BACK-PROPAGATING ERRORS. *NATURE.* 1986;323:533.
- [36] LECUN Y, BOSER B, DENKER JS, HENDERSON D, HOWARD RE, HUBBARD W, JACKEL LD. BACKPROPAGATION APPLIED TO HANDWRITTEN ZIP CODE RECOGNITION. *NEURAL COMPUT.* 1989;1(4):541–51. [HTTPS://DOI.ORG/10.1162/NECO.1989.1.4.541](https://doi.org/10.1162/NECO.1989.1.4.541).
- [37] HINTON GE, OSINDERO S, TEH Y-W. A FAST LEARNING ALGORITHM FOR DEEP BELIEF NETS. *NEURAL COMPUT.* 2006;18(7):1527–54. [HTTPS://DOI.ORG/10.1162/NECO.2006.18.7.1527](https://doi.org/10.1162/NECO.2006.18.7.1527).
- [38] BENGIO Y, LAMBLIN P, POPOVICI D, LAROCHELLE H. GREEDY LAYER-WISE TRAINING OF DEEP NETWORKS. IN: PROCEEDINGS OF THE 19TH INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS. NIPS'06. MIT PRESS, CAMBRIDGE, MA, USA. 2006. P. 153–60. [HTTP://DL.ACM.ORG/CITATION.CFM?ID=2976456.2976476](http://dl.acm.org/citation.cfm?id=2976456.2976476).
- [39] RUSSAKOVSKY O, DENG J, SU H, KRAUSE J, SATHEESH S, MA S, HUANG Z, KARPATHY A, KHOSLA A, BERNSTEIN M, BERG AC, FEI-FEI L. IMAGENET LARGE SCALE VISUAL RECOGNITION CHALLENGE. *INT J COMPUT VISION (IJCV).* 2015;115(3):211–52. [HTTPS://DOI.ORG/10.1007/s11263-015-0816-y](https://doi.org/10.1007/s11263-015-0816-y).
- [40] SHATNAWI A, AL-AYYOUB M, ALBDOUR G, AL-QURRAN R. A COMPARATIVE STUDY OF OPEN SOURCE DEEP LEARNING FRAMEWORKS. [HTTPS://DOI.ORG/10.1109/IACS.2018.8355444](https://doi.org/10.1109/IACS.2018.8355444).
- [41] KUMAR M. AN INCORPORATION OF ARTIFICIAL INTELLIGENCE CAPABILITIES IN CLOUD COMPUTING. *INT J ENG COMPUT SCI.* 2016. [HTTPS://DOI.ORG/10.18535/IJECS/v5i11.63](https://doi.org/10.18535/IJECS/v5i11.63).
- [42] SAIYEDA A, MIR MA. CLOUD COMPUTING FOR DEEP LEARNING ANALYTICS: A SURVEY OF CURRENT TRENDS AND CHALLENGES. *INT J ADV RES COMPUT SCI.* 2017;8(2):68–72. [HTTPS://DOI.ORG/10.26483/IJARCS.v8i2.2931](https://doi.org/10.26483/IJARCS.v8i2.2931).

- [43] DUMBILL E. WHAT IS BIG DATA? : AN INTRODUCTION TO THE BIG DATA LANDSCAPE. 2012.
[HTTP://RADAR.OREILLY.COM/2012/01/WHAT-IS-BIG-DATA.HTML](http://radar.oreilly.com/2012/01/what-is-big-data.html)
- [44] NAJAFABADI MM, VILLANUSTRE F, KHOSHGOFTAAR TM, SELIYA N, WALD R, MUHAREMAGIC E.
DEEP LEARNING APPLICATIONS AND CHALLENGES IN BIG DATA ANALYTICS. J BIG DATA. 2015;2(1):1.
[HTTPS://DOI.ORG/10.1186/S40537-014-0007-7.](https://doi.org/10.1186/s40537-014-0007-7)
- [45] HINTON G, SALAKHUTDINOV R. DISCOVERING BINARY CODES FOR DOCUMENTS BY LEARNING DEEP
GENERATIVE MODELS. TOP COGN SCI. 2011;3(1):74–91.
- [46] SALAKHUTDINOV R, HINTON G. SEMANTIC HASHING. INT J APPROX REASON. 2009;50(7):969–78.
[HTTPS://DOI.ORG/10.1016/J.IJAR.2008.11.00](https://doi.org/10.1016/j.ijar.2008.11.00)
- [47][HTTPS://NANONETS.COM/IMAGE-RECOGNITION](https://nanonets.com/image-recognition)
- [48] [HTTPS://LAREVUEDESMEDIAS.INA.FR/LA-RECONNAISSANCE-DIMAGES-PEUT-ELLE-AUSSI-PROFITER-AUX-MEDIAS](https://larevueedesmedias.ina.fr/la-reconnaissance-dimages-peut-elle-aussi-profiter-aux-medias)
- [49] [HTTPS://WWW.NATURAL-SOLUTIONS.EU/BLOG/LA-RECONNAISSANCE-DIMAGE-AVEC-LES-RSEAUX-DE-NEURONES-CONVOLUTIONS](https://www.natural-solutions.eu/blog/la-reconnaissance-dimage-avec-les-rseaux-de-neurones-convolutifs)
- [50] ANACONDA (2019)[HTTPS://WWW.ANACONDA.COM/DISTRIBUTION/ \[](https://www.anaconda.com/distribution/)
- [51] TENSORFLOW ,(2019)[HTTPS://WWW.TENSORFLOW.ORG/](https://www.tensorflow.org/)

Les notifications d'acceptation des papiers dans les conférences:

1. Nadjet Bouafia, Said Gadri, Hassina Tahmi, Nourelhouda Adouane and Baya Laoues: Efficient Clothes Categorization Based on Deep Learning Predictive Model, 4th Edition of the National Study Days on Computer Sciences Research JERI'2020, Université de Saida, May 20, 2020.

Dear Authors:

We are pleased to inform you that your paper “Efficient Clothes Categorization Based on Deep Learning Predictive Model,” to JERI’2020 has been accepted for Poster Presentation.

We look forward to seeing you in Saida!

Best regards,
JERI’2020 PC chairs “”

2. Hassina Tahmi, Said Kadri , Baya Laoues, Nour Elhouda Adouane and Nadjet Bouafia: Handwritten Digit Recognition: Developing an Efficient ML and DL Model to Recognize Handwritten Digits, Conférence Nationale sur l’Intelligence artificielle et les technologies de l’information CNIATI'20, Chadli Bendjedid University El Tarf, Algeria, 2020.

“”Paper ID: 14

Author(s): TAHMI Hassina, Said GADRI, LAOUES Baya, ADOUANE Nour ElHouda, BOUAFIA Nadjet

Title: Handwritten Digit Recognition: Developing an Efficient ML and DL Model to Recognize Handwritten Digits

It is our pleasure to inform you that the paper referenced above has been accepted for Oral presentation at the CNIATI'2020, to be held in El-Tarf, Algeria 17 March 2020. “”

3. Nour Elhouda Adouane, Said Kadri , Hassina Tahmi, Baya Laoues and Nadjet Bouafia: An Efficient CNN Model to Detect Traffic Signs for the Use of Self-Driving Cars, Conférence Nationale sur l’Intelligence artificielle et les technologies de l’information CNIATI'20, Chadli Bendjedid University El Tarf, Algeria, 2020.

“”Paper ID: 13

Author(s): ADOUANE Nour ElHouda, Said GADRI, TAHMI Hassina, LAOUES Baya, BOUAFIA Nadjet

Title: An Efficient CNN Model to Detect Traffic Signs for the Use of SelfDriving Cars

It is our pleasure to inform you that the paper referenced above has been accepted for Poster presentation at the CNIATI'2020, to be held in El-Tarf, Algeria 17 March 2020. “”

4. Nour Elhouda Adouane, Said Kadri , Hassina Tahmi, Baya Laoues and Nadjet Bouafia:
An Efficient CNN Model to Detect Traffic Signs for the Use of Self-Driving Cars, 4th Edition of the National Study Days on Computer Sciences Research JERI'2020, Université de Saida, May 20, 2020.

““We are pleased to inform you that your paper “An Efficient CNN Model to Detect Traffic Signs for the Use of Self-Driving Cars” to JERI’2020 has been accepted for Oral Presentation.

We look forward to seeing you in Saida!

Best regards,

JERI’2020 PC chairs ““

ملخص

التعلم العميق dl هو مجال فرعي حديث ينحدر من ال م آلل ّ تعل ي ، ويستخدم لتطوير خوارزميات أكثر تطوراً دقة عالي ّ، مما يوفر ة في بعض مهام التعرف على الأشياء الأكثر معالجة من طرف الباحثين ّ مثل: التعرف على الأنماط، تصنيف الصور، التعرف على الأحرف المكتوبة بخط اليد، ...، أكثر كفاءة م الآلي التقليدية ّ في DL، تعتبر الشبكات العصبية من خوارزميات التعل . من بين أكثر الطرق استخداماً CNN ذات أهمية خاصة. في هذا العمل، قمنا بتطوير مصنف تلقائي يسمح بتصنيف عدد كبير من المالبس استناداً مقارنة ML ومقارنة DL. في البداية، قمنا بعملية التصنيف ّ الوحدات الخاصة إلى باستخدام العديد من خوارزميات ML منها LDA, LR, NB, CART, KNN و SVM ثم يتكون من: العديد من الطبقات المتصورة وطبقات التخزين المؤقت، فضلاً عن اقتراحنا نموذج CNN طبقة واحدة متصلة بالكامل. وأخيراً، قمنا بإنشاء مقارنة موجزة بين الخوارزميات المختلفة

الكلمات المفتاحية ML,SVM,NB ,CART,KNN,LDA,LR,LD,CNN

Résumé :

Deep learning DL est un sous-domaine récent de l'apprentissage automatique, que l'approche traditionnelle de machine learning. Parmi les méthodes les plus utilisées dans le DL, les CNN sont pour un intérêt particulier. Dans ce travail, nous avons développé un classificateur automatique qui permet de classer un grand nombre d'articles vestimentaires selon l'approche ML et l'approche DL. Initialement, nous avons procédé à la tâche de classification en utilisant de nombreux algorithmes de ML, notamment : LR, LDA, KNN, CART, NB et SVM . Nous avons ensuite proposé un modèle CNN composé de : de nombreuses couches convolutionnelles et maxpooling ainsi que d'une couche entièrement connectée. Enfin, nous avons établi une brève comparaison entre les différents algorithmes.

Mots-clés ML,SVM,NB ,CART,KNN,LDA,LR,LD,CNN

Abstract :

Deep learning DL is a recent subfield of machine learning ML area which is used to develop much more sophisticated algorithms providing high performance in some interesting recognition tasks such as: pattern recognition, image classification, handwritten character recognition, ..., than traditional machine learning approach. Among the most used methods in DL, CNNs are for a special interest. In this work, we have developed an

automatic classifier that permits to classify a large number of clothing articles based on ML approach and DL approach. Initially, we have proceeded the classification task using many ML algorithms including: LR, LDA, KNN, CART, NB, and SVM. Then we proposed a CNN model composed of: many convolutional and maxpooling layers, as well as one full connected layer. Finally, we established a brief comparison between different algorithms.

Keywords: ML,SVM,NB ,CART,KNN,LDA,LR,LD,CNN