

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITÉ ABDELHAMID IBN BADIS – MOSTAGANEM



Faculté des Sciences Exactes et d'Informatique

Département de Mathématiques et informatique

Filière : Informatique

MEMOIRE DE FIN D'ETUDE

Option : Réseaux et Systèmes

**THEME : Reconnaissance Faciale par Réseaux Neuronaux
Convolutifs (CNNs)**

**Etudiant(e) : « ZAHAFI Yasmine Narimene »
« GHOBRIINI Boualem El-ghali
Abdelkader »**

Soutenu le : 26 Juin 2022

Devant le jury :

Mr. Zahmani Mohamed Habib Président

Mr. Djebara Encadrant

Mr. Moumen Mohamed Elamine Examineur

Année Universitaire 2021-2022

Remerciements

« Avant toutes choses, nous remercions **DIEU** grand et Puissant pour tout, nous le remercions de nous avoir donné la santé, la volanté et le courage d'arriver j'jusqu'à accomplir nos études et mener ce travail à bout et cela en dépit des difficultés.

Nous tenons à remercier « **Mr ZAHMANI Habib Mohamed** » et « **Mr MOUMEN Mohamed Elamine** » pour l'aide précieuse qui nous accorder pour finir ce travail. Veuillez accepter nos profonds respects.

Nos remerciements vont également aux membres du jury, vous nous faites honneur en jugeant notre modeste travail.

Nous voudrions également remercier tous les anceniens qui ont contribué à notre arrivée jusque-là. Veuillez accepter notre profonde reconnaissance.

Enfin, nous tenons à exprimer nos sincères remerciements à tous ceux qui ont contribué de près ou de loin à l'élaboration de ce travail. »

Dédicaces

Je dédie ce travail à mes très chers parents pour tous leurs sacrifices, amour, et aide financière et émotionnel qui m'ont accordé. Merci « **Papa** », merci « **Maman** ».

Je dédie ce travail aussi à ma très cher sœur « **Beni** », qui a toujours était là pour moi, et ma soutenue jusqu'ici.

Ce travail est aussi dédié à mes deuxièmes parents : « **Ommi** », « **Abi** », je vous remercie du fin fond de mon cœur.

Je dédie ce travail également à mes sœurs « **Assala** », « **Touha** » et « **Amel** », et à mes meilleures amies « **Insaf** » et « **Ikram** ».

Et pour finir, je dédie ce travail aux anceniens qui ont contribué à mon évaluation, et à toutes les personnes qui mon soutenu et étaient là pour moi quand j'en avais besoin.

Milles mercis !

ZAHAFI Yasmine Narimene

Dédicaces

Je dédie ce travail à tous ceux qui me sont chère.

GHOBINI Boualem El-ghali Abdelkader

Résumé

De nos jours, le besoin d'identifier les individus de façon précise et efficace devient de plus en plus nécessaire, d'où la nécessité de développer de nouvelles techniques de reconnaissance faciales plus robustes et plus fiable.

Heureusement, cela est devenu possible grâce aux avancées faites dans le domaine de l'apprentissage machine, plus particulièrement les réseaux de neurones qui ont connus un regain en popularité de nos jours, notamment grâce au développement technologique actuel.

Notre recherche concerne la reconnaissance faciale par réseaux de neurones profonds, plus particulièrement les réseaux de neurones convolutifs (CNN), vu que ce sont les systèmes les mieux adaptés pour la classification des images et la reconnaissance de formes.

C'est dans ce contexte que s'inscrit ce projet de master 2, il s'agit de développer un système de reconnaissance faciale automatique capable de faire une détection et authentification en temps réel.

Mots-clés :

Apprentissage machine, réseaux de neurones, reconnaissance faciale, réseaux de neurones convolutifs (CNN).

Abstract

Nowadays, the need to identify individuals accurately and efficiently is becoming more and more necessary, hence the need to develop new, more robust and more reliable facial recognition techniques.

Fortunately, this has become possible thanks to the advances made in the field of machine learning, more particularly neural networks which have experienced a resurgence in popularity these days, especially thanks to the current technological development.

Our research concerns facial recognition by deep neural networks, more specifically convolutional neural networks (CNN), view that they are the most suitable systems for image classification and pattern recognition.

It is in this context that this master 2 project fits, it is about developing an automatic facial recognition system capable of real-time detection and authentication.

Keywords:

Machine Learning, neural networks, face recognition, convolutional neural networks (CNN).

Liste des figures

Figure N°	Titre de la figure	Page
Figure 1	Structure d'un neurone artificiel	6
Figure 2	Architecture de réseau de neurones généralisée (récurrente) avec deux couches cachées	10
Figure 3	Architecture du système de reconnaissance faciale	10
Figure 4	Schéma représentant l'architecture d'un CNN	11
Figure 5	Schéma du parcours de la fenêtre de filtre sur l'image	13
Figure 6	La Convolution	17
Figure 7	Représentation de la bdd BUPT-Balancedface en termes de races	21
Figure 8	8 paires fausses positives et fausses négatives sur RFW données par la ligne de base mais vérifiées avec succès par le GAC	22
Figure 9	Problèmes liés à la reconnaissance d'image : (a) Sélection échelle/orientation du noyau. (b) Forme d'objet complexe	23
Figure 10	Le noyau piloté par les données proposé et son adaptation à la variation cible	23
Figure 11	Suivi des résultats de la méthode proposée (rouge) et du décalage moyen standard (vert) sur la séquence manuelle	24
Figure 12	10 époques d'entraînement du CNN.	27
Figure 13	Premier exemple de détection positif.	33
Figure 14	Deuxième exemple de détection positif.	33
Figure 15	Exemple de détection négatif.	34

Liste des abréviations

Abréviation	Expression Complète	Page
IA	Intelligence Artificielle	1
CNN	Convolutional Neural Network	1
ACNN	Adaptatif Convolutional Neural Network	1
RNN	Recurrent Neural Network	7
RVB	Rouge, Vert, Bleu	8
ADN	Acide DésoxyriboNucléique	10
GPU	Graphics Processing Unit	15
MLP	Multi Layers Perceptron	16
ReLu	Rectified Linear Unit	19
MNIST	Modified ou Mixed National Institute of Standards and Technology	20
NIST	National Institute of Standards and Technology	20
FR	Face Ricognition	21
GAC	Group Adaptatif Classificator	21
RFW	Racial Faces in-the-Wild	21

LSTM	Long Short-Term Memory	27
BSD	Berkeley Software Distribution	28
MIT	Massachusetts Institute of Technology	29
HTML	HyperText Markup Language	30
SQL	Structured Query Language	31

Table des matières

Introduction Générale.....	1
CHAPITRE 1 Apprentissage machine, réseaux de neurones et reconnaissance faciale.....	3
1.1 Introduction	3
1.2 Apprentissage machine et réseaux de neurones	3
1.2.1 Définition de l'apprentissage machine	3
1.2.2 Techniques d'apprentissage machine.....	4
1.2.2 Origine des réseaux de neurones artificiels	5
1.2.3 Structure des réseaux de neurones artificiels	5
1.2.4 Architectures de réseaux neuronaux	7
1.3 La biométrie	9
1.3.1 Définition	9
1.3.2 But de la biométrie.....	9
1.3.3 Types de sécurité biométrique	10
1.3.4 Rôle de la sécurité biométrique.....	10
1.4 Reconnaissance Faciale	11
1.4.1 Fonctionnement de la reconnaissance faciale	11
1.4.2 Cas d'usage en matière de reconnaissance faciale biométrique	13
1.5 Conclusion.....	14
CHAPITRE2 Réseaux de neurones convolutifs (CNNs).....	15
2.1 Introduction.....	15
2.2 Définition des réseaux de neurones convolutifs	15
2.3 L'architecture d'un réseau de neurones convolutif	15
2.4 Comment fonctionnent les réseaux de neurones convolutifs ?	18
2.4.1 Couche convolutive.....	18
2.4.2 Couche de mutualisation	18
2.3.3 Couche entièrement connectée (FC).....	19
2.5 Réseaux de neurones convolutifs adaptatifs (Travail futur).....	19

2.5.1 Noyau convolutif adaptatif.....	20
2.5.2 Classificateurs adaptatifs de groupe	20
2.5.3 Noyau adaptatif axé sur la forme	22
2.6 Conclusion	25
CHAPITRE 3 Environnements d'implémentation	26
3.1 Introduction	26
3.2 Étapes nécessaires de construction du CNN	26
3.3 Technologies d'implémentation disponibles	28
3.4 Sélection des technologies d'implémentation.....	31
3.5 Environnement de travail	31
3.5.1 Environnement matériel	32
3.5.2 Environnement logiciel.....	32
3.6 Mode de fonctionnement	32
3.5 Conclusion.....	34
Conclusion générale	35
Bibliographie	36

Introduction Générale

Avec l'évolution de l'informatique et l'apparition des réseaux, la sécurité devient de plus en plus difficile à gérer et à assurer, l'usurpation d'identité et les moyens de tromper l'identification et l'authentification demeurent parmi les failles majeures de la sécurité informatique.

Afin de pallier aux faiblesses de l'authentification traditionnelle par les mots de passe et d'améliorer le taux de reconnaissance, l'utilisation d'une technologie d'identification émergente telle que la reconnaissance faciale apparaît comme un excellent candidat à la vérification ou la confirmation d'identité.

Grâce à l'utilisation de l'intelligence artificielle (IA) et des technologies d'apprentissage automatique, les systèmes de reconnaissance faciale peuvent fonctionner conformément aux standards les plus élevés de la sécurité et de la fiabilité. De manière similaire, grâce à l'intégration de ces algorithmes et techniques informatiques, le processus peut être mené à bien en temps réel.

Dans le cadre de ce mémoire la notion de réseaux de neurones convolutifs CNNs « *Convolutional Neural Network* » (une sous-catégorie de réseaux de neurones) est exploitée car, ceux sont des modèles de programmation puissants, utilisés dans des tâches telles que l'analyse d'images, le traitement du langage naturel et d'autres problèmes complexes de classification d'images, notamment la reconnaissance d'images.

Notre travail consiste, à développer un système de reconnaissance faciale en utilisant les approches de réseaux de neurones convolutifs CNNs Le système est capable d'identifier ou d'authentifier une personne en disant si oui ou non il connaît cette personne en précisant le nom de celle-ci, si le résultat est positif. [Avec un faible taux d'erreur].

Ce document est divisé en trois chapitres comme suit :

Le chapitre 1 expose d'abord des concepts de base reliés à notre travail : l'apprentissage machine, la reconnaissance faciale et les réseaux de neurones artificiels (leur origine, structure et architectures) etc, et explique la relation entre ces différents concepts, pour pouvoir expliquer par la suite notre travail sans ambiguïté.

Le chapitre 2 se focalise ensuite sur les CNNs et leurs modes de fonctionnement, vu qu'ils représentent la pièce maîtresse de notre travail. Dans cette partie nous détaillons le concept des CNN, leur architecture et la manière dans ils procède pour fonctionner. A la fin du chapitre la notion de ACNNs « *Adaptatif Convolutional Neural Network* » est introduite comme étant des variants de réseaux de neurones convolutifs plus performants, une version mieux adaptée des CNNs classiques, en citant les démarches adoptées pour la création des différents ACCNs choisis, en prenant soins de préciser la partie adaptative et les résultats de chacun. Ce sera un objectif à atteindre, de pouvoir implémenter une ces approches avancées très intéressantes.

Le chapitre 3 est consacré à l'explication du travail pratique que nous avons accomplie et aux environnements d'implémentation disponibles et ceux que nous avons choisis pour implémenter notre projet, Divers technologies et outils sont introduit dans ce chapitre.

En passant par des points fondamentaux, à savoir :

1. Étapes nécessaires de construction du CNN.
2. Technologies d'implémentation disponibles.
3. Sélection de la technologie d'implémentation à utiliser.
4. Environnement de travail
5. Mode de fonctionnement

Nous finissons notre travail avec une conclusion générale.

CHAPITRE 1

Apprentissage machine, réseaux de neurones et reconnaissance faciale

1.1 Introduction

La reconnaissance faciale est considérée comme l'une des méthodes les plus sûres pour s'authentifier [1], or, malheureusement, cette tâche demeure relativement très complexe en prenant en considération les difficultés engendrées par les variations visibles sur les visages durant l'acquisition des vidéos (la pose du visage, l'illumination sur celui-ci, la résolution et le flou de mouvement causé par les caméras). De ce fait, plusieurs approches ont été mises en œuvre pour résoudre cette problématique notamment les réseaux de neurones, et plus particulièrement les réseaux de neurones convolutifs. Dans ce chapitre tous ces concepts cités seront expliqués en détail avec exemples et illustrations.

1.2 Apprentissage machine et réseaux de neurones

1.2.1 Définition de l'apprentissage machine

L'apprentissage machine, également appelé apprentissage artificiel ou encore apprentissage automatique, le terme en anglais pour le designer est « *machine learning* », c'est une sorte d'intelligence artificielle (IA) permettant à un système quelconque d'apprendre à partir des données et non à l'aide d'une programmation prédéfinie [2].

L'apprentissage automatique est utilisé lorsque le problème à résoudre est trop complexe pour le décrire à une machine en lui donnant une série d'instructions ou des règles simples. Une solution peut consister à définir un ensemble de règles à la main afin d'orienter la machine dans ses choix, mais la définition manuelle de ces règles est soit trop complexe à mettre en œuvre, soit insuffisante. Cette difficulté se retrouve dans l'analyse d'image, le traitement des langues naturelles ou la reconnaissance de parole. Ces trois domaines associent des espaces de représentation de grande dimension avec des éléments sémantiques contenant une grande variabilité.

Au lieu d'exprimer à la machine sa manière de réagir en fonction de tous les cas possibles, nous lui donnons des exemples concrets sur lesquels elle doit acquérir une expérience par apprentissage. De cette expérience, nous espérons qu'elle sera capable de résoudre des cas qu'elle n'a jamais vu, c'est à-dire de généraliser. Par exemple, être capable de jouer à un jeu dans une configuration pas encore rencontrée, ou détecter un nouveau visage humain dans une photo [3].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

L'apprentissage machine est la dernière avancée dans le domaine de l'informatique qui utilise des méthodologies à la pointe de la technologie pour améliorer les performances des entreprises.

1.2.2 Techniques d'apprentissage machine

Voici ci-dessous six techniques d'apprentissage machine qui constituent la base de l'apprentissage machine [4] :

1. Régression

Elle est basée sur les principes de base de la physique qui aident à prédire l'avenir à partir des données actuelles. Par exemple, prévoir les tendances du marché [4].

2. Classification

La méthode définit une valeur de classe basée sur les données d'entrée. Elle vous donnera des prédictions définitives sur une certaine action. Par exemple, elle vous indiquera si le visiteur deviendra un client ou non [4].

3. Regroupement

Il s'agit d'une technique, dans laquelle les traits similaires sont utilisés pour faire une prédiction, au lieu des données passées. L'algorithme utilise des repères visuels pour concevoir une solution. Par exemple pour déterminer si un bâtiment économe en énergie est efficace ou inefficace (en termes d'unités de refroidissement, de gaz domestique...) [4].

4. Réduction de la dimensionnalité

Il s'agit du processus de réduction des variables aléatoires tout en catégorisant les données. Plus le nombre de variables est élevé, plus les résultats seront complexes. L'exemple le plus courant de réduction dimensionnelle est le processus de classification des courriers électroniques utilisé pour trier les courriers indésirables [4].

5. Méthode d'ensemble

Il s'agit d'une technique permettant d'empiler des données en utilisant des variables de prédiction provenant de divers modèles. Elle combine donc divers modèles prédictifs pour former une sortie prédictive très précise et optimisée.

Par exemple, prédire votre réponse (oui ou non) si vous envisagez d'acheter une propriété en ville, en fonction de divers facteurs tels que le type de propriété, la valeur, les économies, les objectifs d'investissement à long terme et les conditions économiques [4].

6. Réseaux neuronaux et apprentissage profond

Les réseaux de neurones, communément appelés des réseaux de neurones artificiels sont des imitations simples des fonctions d'un neurone dans le cerveau humain pour résoudre des problématiques d'apprentissage de la machine « *Machine Learning* » [5].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Les réseaux de neurones sont un sous-ensemble de l'apprentissage automatique et ils sont au cœur des algorithmes d'apprentissage en profondeur. Ils sont composés de couches de nœuds, contenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque nœud se connecte à un autre et a un poids et un seuil associés. Si la sortie d'un nœud individuel est supérieure à la valeur de seuil spécifiée, ce nœud est activé, envoyant des données à la couche suivante du réseau. Sinon, aucune donnée n'est transmise à la couche suivante du réseau [6].

1.2.2 Origine des réseaux de neurones artificiels

Le concept des réseaux de neurones artificiels fut inventé en 1943 par deux chercheurs de l'Université de Chicago : le neurophysicien 'Warren McCullough', et le mathématicien 'Walter Pitts'. Dans un article publié dans le journal 'Brain Theory', les deux chercheurs présentent leur théorie selon laquelle l'activation de neurones est l'unité de base de l'activité cérébrale [7].

En 1957, 'le **Perceptron**' fut inventé. Il s'agit du **plus ancien algorithme de Machine Learning**, conçu pour effectuer des tâches de reconnaissance de patterns complexes. C'est cet algorithme qui permettra plus tard aux machines d'apprendre à reconnaître des objets sur des images [7].

Malheureusement, à l'époque, les réseaux de neurones étaient limités par les ressources techniques. Par exemple, **les ordinateurs n'étaient pas assez puissants** pour traiter les données nécessaires au fonctionnement des réseaux de neurones. C'est la raison pour laquelle la recherche dans le domaine des « *Neural Networks* » est restée en sommeil durant de longues années [7].

Il aura fallu attendre le début des années 2010, avec l'essor du « *Big Data* » et du traitement massivement parallèle, pour que les « *Data Scientists* » disposent des données et de la puissance de calcul nécessaires pour exécuter des réseaux de neurones complexes. En 2012, lors d'une compétition organisée par 'ImageNet', un « *Neural Network* » est parvenu pour la première fois à surpasser un humain dans la reconnaissance d'image. C'est la raison pour laquelle cette technologie est de nouveau au cœur des préoccupations des scientifiques. A présent, les réseaux de neurones artificiels ne cessent de s'améliorer et d'évoluer de jour en jour [7].

Les réseaux de neurones ne sont pas les seuls algorithmes d'apprentissage automatique, mais ils sont les plus répandus [8] !

1.2.3 Structure des réseaux de neurones artificiels

Un réseau de neurones est un système composé de neurones, généralement répartis en plusieurs couches connectées entre elles [9].

Le neurone est une unité qui est exprimée généralement par une fonction sigmoïde, qui est la suivante :

$$f(x) = \frac{1}{1 + e^{-x}} \quad [5]$$

Structure d'un neurone artificiel à consulter sur la figure 1.

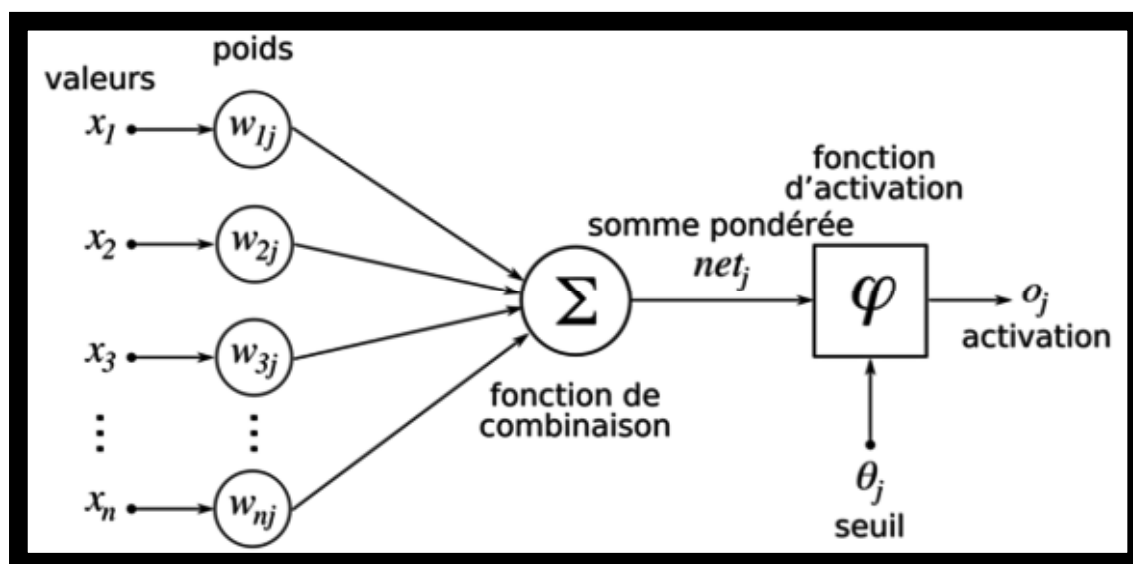


Figure N° 1 – Structure d'un neurone artificiel [5].

Entrée (valeurs) : C'est l'ensemble des caractéristiques qui sont introduites dans le modèle pour le processus d'apprentissage. Par exemple, l'entrée dans la détection d'objets peut être un tableau de valeurs de pixels appartenant à une image [10].

Poids : Sa fonction principale est de donner de l'importance aux caractéristiques qui contribuent le plus à l'apprentissage. Il le fait en introduisant une multiplication scalaire entre la valeur d'entrée et la matrice de poids. Par exemple, un mot négatif aurait plus d'impact sur la décision du modèle d'analyse des sentiments qu'une paire de mots neutres [10].

Fonction de transfert (combinaison) : Le travail de la fonction de transfert consiste à combiner plusieurs entrées en une valeur de sortie afin que la fonction d'activation puisse être appliquée. Elle se fait par une simple sommation de toutes les entrées de la fonction de transfert. Ça sortie est la somme pondérée [10].

Fonction d'activation : Elle introduit la non-linéarité dans le fonctionnement des perceptrons pour considérer une linéarité variable avec les entrées. Sans cela, la sortie ne serait qu'une combinaison linéaire de valeurs d'entrée et ne pourrait pas introduire de non-linéarité dans le réseau. Ça sortie est l'activation [10].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Pourquoi recourir à des réseaux de neurones ? La réponse est plutôt simple dans le sens où les réseaux de neurones s'avèrent être parmi les techniques les plus performantes pour des tâches de « *Machine Learning* » [10].

Un réseau de neurones peut prendre des formes différentes selon l'objet de la donnée qu'il traite et selon sa complexité et la méthode de traitement de la donnée [5].

1.2.4 Architectures de réseaux neuronaux

Les architectures ont leurs forces et faiblesses et peuvent être combinées pour optimiser les résultats. Le choix de l'architecture s'avère ainsi crucial et il est déterminé principalement par l'objectif [5].

Les architectures de réseaux neuronaux peuvent être divisées en 5 grandes familles :

1.2.4.1 Réseaux de neurones standard

Contenant elle-même plusieurs sous-catégories de réseaux de neurones dont :

a. Le perceptron

C'est un type de réseau neuronal qui prend un certain nombre d'entrées, applique certaines opérations mathématiques sur ces entrées et produit une sortie. Il prend un vecteur d'entrées de valeurs réelles, effectue une combinaison linéaire de chaque attribut avec le poids correspondant attribué à chacun d'eux. L'entrée pondérée est additionnée en une seule valeur et passée à travers une fonction d'activation [10].

Ces unités de perceptron sont combinées pour former une plus grande architecture de réseau de neurones artificiels [10].

b. Réseaux à rétropropagation

Il s'agit d'un réseau neuronal multicouche et, comme son nom l'indique, les informations sont transmises dans le sens direct, de gauche à droite. Les informations arrivent à l'intérieur du modèle via la couche d'entrée, passent à travers la série de couches cachées et vont enfin à la couche de sortie. Cette architecture de réseaux neuronaux est de nature avancée : les informations ne bouclent pas avec deux couches cachées [10].

1.2.4.2 Réseaux de neurones récurrents

Les réseaux de neurones récurrents (RNN pour « *Recurrent Neural Network* ») traitent l'information en cycle. Ces cycles permettent au réseau de traiter l'information plusieurs fois en la renvoyant à chaque fois au sein du réseau.

Ils ont le pouvoir de se souvenir de ce qu'ils ont appris dans le passé et de l'appliquer dans les prédictions futures [10].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Le réseau de neurone se compose d'une couche d'entrée, de couches cachées et d'une couche de sortie. Le RNN est construit sur la structure de réseaux neuronaux avec l'ajout d'"effets de mémoire" à chaque couche cachée (indiquée par les flèches en pointillés dans la figure 2) [11].




Figure N° 2 – Architecture de réseau de neurones généralisée (récurrente) avec deux couches cachées [11].

1.2.4.3 Réseaux de neurones convolutifs

Réseaux de neurones convolutifs en français, désignent une sous-catégorie de réseaux de neurones [12]. Désignés par l'acronyme CNN, de l'anglais « *Convolutional Neural Network* », les réseaux de neurones convolutifs sont des modèles de programmation puissants, des réseaux de neurones de type « *Feed-Forward* » [10], utilisés dans des tâches telles que l'analyse d'images, le traitement du langage naturel et d'autres problèmes complexes de classification d'images, notamment la reconnaissance d'images en attribuant automatiquement à chaque image fournie en entrée, une étiquette correspondant à sa classe d'appartenance.

Ils sont à ce jour un des modèles de classification d'images réputés être les plus performant [13] !

Le CNN compare les images fragment par fragment. Les fragments qu'il recherche sont appelés les caractéristiques.

Leur mode de fonctionnement est à première vue simple : l'utilisateur fournit en entrée une image sous la forme d'une **matrice de pixels**.

Celle-ci dispose de 3 dimensions :

- **Deux dimensions** pour une image en niveaux de gris.
- Une **troisième dimension**, de profondeur 3 pour représenter les couleurs fondamentales RVB (**Rouge, Vert, Bleu**) [12].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

1.2.4.4 Réseaux antagonistes génératifs

La modélisation générative relève de l'apprentissage non supervisé, où des données nouvelles/synthétiques sont générées sur la base des modèles découverts à partir de l'ensemble de données d'entrée [9].

GAN est un modèle génératif et est utilisé pour générer des données synthétiques entièrement nouvelles en apprenant le modèle et constitue donc un domaine actif de la recherche en IA. Il est utilisé dans des scénarios tels que la prédiction de l'image suivante dans une vidéo, la génération de texte en image, la traduction d'image en image comme le transfert de style, le dé bruitage de l'image, etc [9].

1.2.4.5. Réseaux de neurones transformateurs

Ces réseaux utilisent une structure codeur-décodeur avec une différence que les données d'entrée peuvent être transmises en parallèle.

Dans la structure RNN, un mot à la fois était passé à travers la couche d'entrée. Mais dans les réseaux de neurones transformateurs, il n'y a pas de concept d'horodatage pour transmettre l'entrée. Nous alimentons la phrase complète en entrée et obtenons les plongements pour tous les mots ensemble [9].

1.3 La biométrie

1.3.1 Définition

La biométrie est la mesure et l'analyse statistique des caractéristiques physiques et comportementales uniques des personnes. Cette technologie est principalement utilisée pour l'identification et le contrôle d'accès ou pour identifier les personnes sous surveillance. Le principe de base de l'authentification biométrique est que chaque personne peut être identifiée avec précision par des traits physiques ou comportementaux intrinsèques. Le terme biométrie est dérivé des mots grecs bio, signifiant la vie, et métrique, signifiant mesurer [14].

La biométrie est en train de devenir une couche avancée pour de nombreux systèmes de sécurité personnels et d'entreprise. Avec les identifiants uniques de votre biologie et de vos comportements, cela peut sembler infaillible. [15].

1.3.2 But de la biométrie

La cybersécurité moderne se concentre sur la réduction des risques pour cette puissante solution de sécurité : les mots de passe traditionnels ont longtemps été un point faible des systèmes de sécurité. La biométrie vise à répondre à ce problème en liant la preuve d'identité à notre corps et à nos comportements [15].

1.3.3 Types de sécurité biométrique

Bien qu'elles puissent avoir d'autres applications, la biométrie a souvent été utilisée dans la sécurité, et on peut principalement classer la biométrie en trois groupes :

- a. Biométrie biologique
- b. Biométrie morphologique
- c. Biométrie comportementale

a. La biométrie biologique :

Utilise des traits au niveau génétique et moléculaire. Ceux-ci peuvent inclure des caractéristiques telles que l'ADN (Acide DésoxyriboNucléique) ou votre sang, qui peuvent être évaluées à l'aide d'un échantillon des fluides de votre corps [15].

b. La biométrie morphologique :

Concerne la structure de votre corps. D'autres traits physiques comme votre œil, vos empreintes digitales ou la forme de votre visage peuvent être cartographiés pour être utilisés avec des scanners de sécurité [15].

c. La biométrie comportementale :

Est basée sur des modèles propres à chaque personne. La façon dont vous marchez, parlez ou même tapez sur un clavier peut être une indication de votre identité si ces schémas sont suivis [15].

Notre travail prend place dans la biométrie morphologique.

1.3.4 Rôle de la sécurité biométrique

L'identification biométrique joue un rôle croissant dans notre sécurité quotidienne. Les caractéristiques physiques sont relativement fixes et individualisées, même dans le cas de jumeaux. L'identité biométrique unique de chaque personne peut être utilisée pour remplacer ou au moins augmenter les systèmes de mot de passe pour les ordinateurs, les téléphones et les salles et bâtiments à accès restreint [15].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Une fois les données biométriques obtenues et cartographiées, elles sont ensuite enregistrées pour être mises en correspondance avec les futures tentatives d'accès. La plupart du temps, ces données sont cryptées et stockées dans l'appareil ou sur un serveur distant [15].

1.4 Reconnaissance Faciale

La reconnaissance faciale est une technologie permettant d'identifier ou de vérifier un sujet au moyen d'une image, une vidéo ou tout élément audiovisuel de son visage. Il s'agit d'une **méthode d'identification biométrique** qui utilise les mesures corporelles, dans ce cas, le visage et la tête, afin de **vérifier l'identité d'une personne** grâce à sa disposition et ses données biométriques faciales. La technologie recueille un ensemble de données biométriques uniques auprès de chaque personne, associées à son visage et expression faciale afin d'identifier, vérifier et/ou authentifier une personne [16].

L'objectif de la reconnaissance faciale consiste en, à partir d'une image entrante, trouver une série de données appartenant au même visage dans un ensemble d'images d'apprentissage d'une base de données. **La grande difficulté consiste à garantir que ce processus soit effectué en temps réel** [16].

Depuis son invention dans les années 70, la reconnaissance faciale a progressé à pas de géant. Elle s'impose aujourd'hui comme la plus naturelle des mesures biométriques. À ce jour, la reconnaissance faciale reste la reine des références en matière de mesures [17] !

1.4.1 Fonctionnement de la reconnaissance faciale

Les systèmes de reconnaissance faciale saisissent une image entrante provenant d'une caméra, de manière bidimensionnelle ou tridimensionnelle, conformément aux caractéristiques du dispositif [16].

Chaque système biométrique a quatre caractéristiques principales qui sont illustrées à la figure 3 : Détection faciale, prétraitement, extraction de caractéristiques et reconnaissance faciale [18].




Figure N° 3 – Architecture du système de reconnaissance faciale [18].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Comme le montre la figure 3, la première tâche du système de reconnaissance faciale est de capturer l'image en vidéo, caméra ou de la base de données et cette image est donnée à l'étape suivante de reconnaissance qui est discuté dans cette section [18] :

a. Détection faciale

La fonction principale de cette étape est de détecter le visage à partir de la capture d'image ou de l'image de la base de données. Ce processus de détection de visage vérifie en fait si l'image donnée est une image de visage ou non, après avoir détecté le visage, cette sortie sera plus loin donnée à l'étape de pré-traitement [18].

b. Pré-traitement

Dans cette étape, le bruit indésirable, flou, conditions d'éclaircissement variables, les effets d'ombre peuvent être supprimés en utilisant des techniques de pré-traitement. Une fois que nous aurons une image de visage lisse et fine, ce sera utilisé pour le processus d'extraction de caractéristiques [18].

c. Extraction de caractéristiques

Dans cette étape, les caractéristiques du visage peuvent être extraites à l'aide d'un algorithme d'extraction de caractéristiques. Les extractions sont effectuées pour le conditionnement des informations, la réduction des dimensions, et le nettoyage du bruit [18a].

d. Reconnaissance de visage

Une fois l'extraction des caractéristiques terminée, cette étape analyse la représentation de chaque visage ; cette dernière est utilisée pour reconnaître les identités des visages. Pour chaque visage, plusieurs images sont prises et leurs caractéristiques sont extraites et stockées dans la base de données. Puis lorsqu'une image de visage d'entrée vient pour être reconnue, on effectue d'abord la détection de visage, le prétraitement et l'extraction de caractéristiques, après elle compare sa caractéristique à chaque classe de visage qui est stockées dans la base de données [18].

Lors de cette comparaison entre visages, on **analyse mathématiquement** l'image entrante en minimisant la marge d'erreur et on vérifie que les données biométriques correspondent à la personne qui doit faire usage du service ou sollicite l'accès à une application, un système, voire un immeuble [18].

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

Grâce à l'utilisation de l'intelligence artificielle (IA) et des technologies d'apprentissage automatique, les systèmes de reconnaissance faciale peuvent fonctionner conformément aux **standards les plus élevés de sécurité et fiabilité**. De manière similaire, grâce à l'intégration de ces algorithmes et techniques informatiques, le processus peut être mené à bien en temps réel [16].

Il existe deux applications générales de la reconnaissance faciale, l'une est appelée **identification** et une autre est appelée **vérification** [18].

Vérification : veut dire que le system va comparer les données biométriques capturées de d'une personne à la base de données du system. La personne en question qui désire être identifié dans un tel système propose une identité, habituellement par l'intermédiaire d'un nom d'utilisateur ou d'un PIN (numéro d'identification personnelle), ..., et le système conduit une comparaison d'un - à - un pour déterminer si la réclamation est vraie ou fausse (soit il valide ou pas).

Plus facilement la vérification répond à la question : suis-je celui que je prétends être ?

Identification : veut dire l'identification d'un individu en recherchant les signatures (Template) de tous les utilisateurs dans la base de données du système. Le système, par conséquent, va effectuer plusieurs comparaisons pour établir l'identité d'un individu (ou échoue si le sujet n'est pas inscrit dans la base de données de système) sans devoir soumettre ou réclamer une certaine identité.

Donc l'identification répond à la question qui suis-je ?

1.4.2 Cas d'usage en matière de reconnaissance faciale biométrique

Les usages de la reconnaissance faciale se focalisent sur la vérification ou l'authentification. Cette technologie est utilisée, par exemple, dans des situations telles que :

- **Deuxième facteur d'authentification**, afin de rendre plus sûr tout processus de connexion.
- **Accès aux applications portables** sans mot de passe.
- **Accès à des services en ligne** préalablement souscrits (connexion à des plateformes en ligne, par exemple).
- **Accès aux immeubles** (bureau, évènements, installations de toute sorte ...).

CHAPITRE 1 : APPRENTISSAGE MACHINE, RESEAUX DE NEURONES ET RECONNAISSANCE FACIALE

- **Méthode de règlement**, à la fois dans des magasins physiques et en ligne.
- **Accès à un dispositif verrouillé.**
- **Enregistrement des services touristiques** (aéroports, hôtels...) [12].

1.5 Conclusion

Dans ce chapitre, nous avons présenté les concepts de base reliés à l'apprentissage machine les réseaux de neurones artificiels et la reconnaissance faciale, nous avons cité la relation entre les trois et précisé les différentes architectures existantes de réseaux neuronaux.

Dans le chapitre suivant, nous nous concentrerons sur l'architecture de réseaux de neurone : réseaux de neurones convolutifs (CNNs), car les réseaux de neurones convolutifs sont utilisés pour tout usage autour de l'image donc ils ont réussi à se faire une place dans le domaine de la reconnaissance faciale, on peut même dire que ce sont les systèmes les mieux adaptés pour notre travail qui concerne la reconnaissance des visages.

CHAPITRE2

Réseaux de neurones convolutifs (CNNs)

2.1 Introduction

Depuis son premier exemple réussi en 1991, la reconnaissance faciale éblouit le monde, mais encore avec l'utilisation de réseau de neurones depuis 2011 les performances de ces systèmes s'améliore de plus en plus [19]. Dans cette partie, nous allons nous focaliser les réseaux de neurones utiliser pour la reconnaissance faciale, considérés comme l'un des algorithmes les plus performants de l'apprentissage profondi, les réseaux de neurones convolutifs ou aussi appelés CNN.

2.2 Définition des réseaux de neurones convolutifs

Les Réseaux de neurones convolutifs (ConvNets ou CNN), sont des modèles de programmation puissants permettant notamment la reconnaissance d'images, Les CNN désignent une sous-catégorie de réseaux de neurones et sont à ce jour un des modèles de classification d'images réputés être les plus performant [12].

Avant les CNN, des méthodes d'extraction de caractéristiques manuelles et chronophages étaient utilisées pour identifier les objets dans les images. Cependant, les réseaux de neurones convolutifs offrent désormais une approche plus évolutive des tâches de classification d'images et de reconnaissance d'objets, en exploitant les principes de l'algèbre linéaire, en particulier la multiplication matricielle, pour identifier des modèles dans une image. Cela dit, ils peuvent être exigeants en termes de calcul, nécessitant des unités de traitement graphique (GPU) (en anglais : « *Graphics Processing Unit* ») pour entraîner les modèles. [6]

2.3 L'architecture d'un réseau de neurones convolutif

L'architecture du « *Convolutional Neural Network* » dispose en amont d'une partie convolutive et comporte par conséquent deux parties bien distinctes, comme le montre la figure 4 :

- Une partie convolutive :

CHAPITRE 2 : RESEAUX DE NEURONES CONVOLUTIFS (CNNs)

Son objectif final est d'extraire des caractéristiques propres à chaque image en les compressant de façon à réduire leur taille initiale. En résumé, l'image fournie en entrée passe à travers une succession de filtres, créant par la même occasion de nouvelles images appelées cartes de convolutions. Enfin, les cartes de convolutions obtenues sont concaténées dans un vecteur de caractéristiques appelé code CNN [12].

- **Une partie classification :**

Le code CNN obtenu en sortie de la partie convolutive est fourni en entrée dans une deuxième partie, constituée de couches entièrement connectées appelées perceptron multicouche (MLP pour « *Multi Layers Perceptron* »). Le rôle de cette partie est de combiner les caractéristiques du code CNN afin de classer l'image [12].

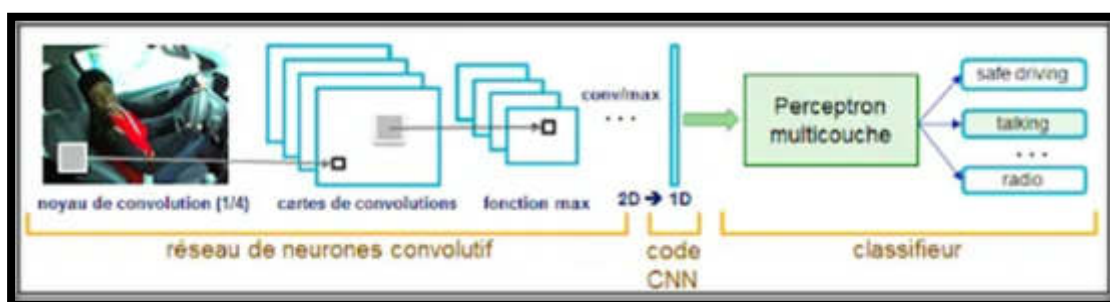


Figure N° 4 – Schéma représentant l'architecture d'un CNN [12].

1.2.5.1 Importance de la convolution

La convolution est une opération mathématique simple généralement utilisée pour le traitement et la reconnaissance d'images. Sur une image, son effet s'assimile à un filtrage (illustré sur la figure 5) dont voici le fonctionnement [12] :

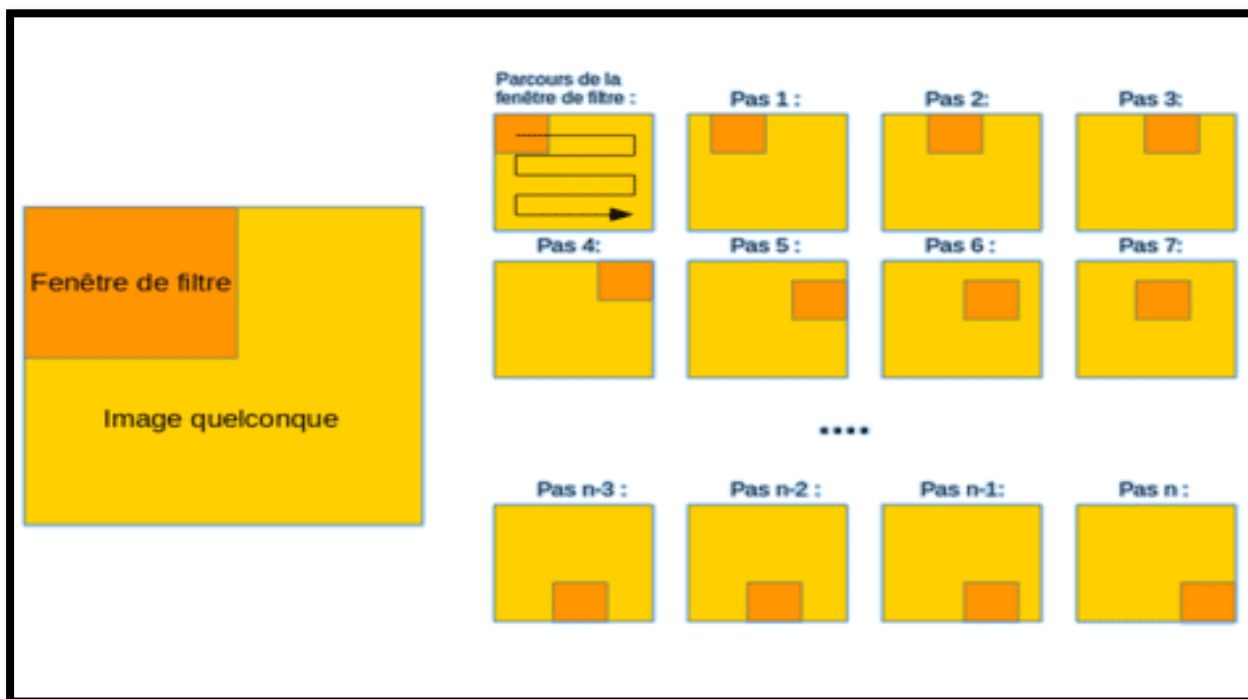


Figure N° 5 – Schéma du parcours de la fenêtre de filtre sur l'image [12].

1. Dans un premier temps, on définit la taille de la fenêtre de filtre située en haut à gauche.
2. La fenêtre de filtre, représentant la « *feature* », se déplace progressivement de la gauche vers la droite d'un certain nombre de cases défini au préalable appelés « le pas » jusqu'à arriver au bout de l'image.
3. À chaque portion d'image rencontrée, un calcul de convolution s'effectue permettant d'obtenir en sortie une carte d'activation ou « *feature map* » (voir figure 6) qui indique où sont localisées les « *features* » dans l'image : plus la « *feature map* » est élevée, plus la portion de l'image balayée ressemble à la « *feature* » [12].

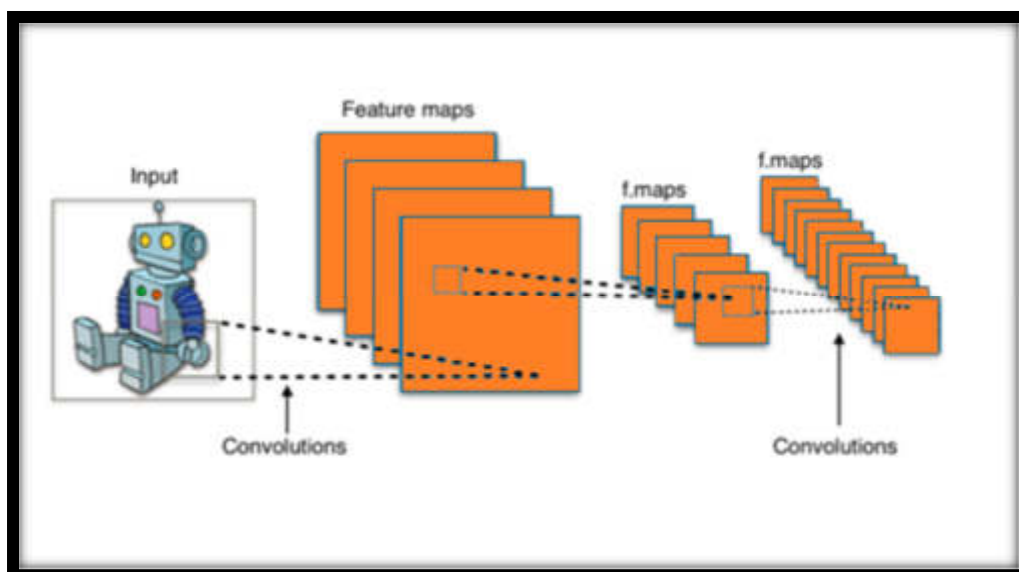


Figure N° 6 – La Convolution [20].

CHAPITRE 2 : RESEAUX DE NEURONES CONVOLUTIFS (CNNs)

Un CNN a des couches cachées de couches convolutives qui forment la base des ConvNets. Les « *features* » font référence à des détails infimes dans les données d'image comme les bords, les bordures, les formes, les textures, les objets, les cercles, etc [9].

À un niveau supérieur, les couches convolutives détectent ces motifs dans les données d'image à l'aide de filtres. Les détails de niveau supérieur sont pris en charge par les premières couches convolutives [9].

Plus le réseau est profond, plus la recherche de modèles devient sophistiquée. Par exemple, dans les couches ultérieures plutôt que sur les bords et les formes simples, les filtres peuvent détecter des objets spécifiques comme des yeux ou des oreilles, et éventuellement un chat, un chien, etc [9].

2.4 Comment fonctionnent les réseaux de neurones convolutifs ?

Les réseaux de neurones convolutifs se distinguent des autres réseaux de neurones par leurs performances supérieures avec des entrées d'image, de parole ou de signal audio. Ils ont trois principaux types de couches, qui sont :

2.4.1 Couche convolutive

La couche convolutive est le bloc de construction central d'un CNN, c'est la partie où se produit la majorité des calculs. Elle nécessite quelques composants, qui sont : des données d'entrée, un filtre et une carte des fonctionnalités. Supposons que l'entrée soit une image couleur, composée d'une matrice de pixels en 3D. Cela signifie que l'entrée aura trois dimensions - une hauteur, une largeur et une profondeur - qui correspondent au RVB dans une image. Dans cette couche figure également un détecteur de caractéristiques, généralement connu sous le nom de noyau ou de filtre, qui se déplacera à travers les champs récepteurs de l'image, vérifiant si la caractéristique est présente. Ce processus est connu sous le nom de « convolution ». [6]

2.4.2 Couche de mutualisation

Le regroupement des couches, aussi connu sous le nom de sous-échantillonnage, permet de réduire la dimensionnalité, réduisant ainsi le nombre de paramètres dans l'entrée. Semblable à la couche convolutive, l'opération de regroupement balaie un filtre sur toute l'entrée, mais la différence est que ce filtre n'a pas de poids. Au lieu de cela, le noyau applique une fonction d'agrégation aux valeurs dans le champ réceptif, remplissant le tableau de sortie.

Il existe deux grands types de mutualisation :

Regroupement maximal : lorsque le filtre se déplace sur l'entrée, il sélectionne le pixel avec la valeur maximale à envoyer au tableau de sortie. Soit dit en passant, cette approche a tendance à être utilisée plus souvent que la mise en commun moyenne.

CHAPITRE 2 : RESEAUX DE NEURONES CONVOLUTIFS (CNNs)

Regroupement moyen : lorsque le filtre se déplace sur l'entrée, il calcule la valeur moyenne dans le champ récepteur à envoyer au tableau de sortie.

Bien que de nombreuses informations soient perdues dans la couche de mise en commun, cela présente également un certain nombre d'avantages pour le CNN. Ils contribuent à réduire la complexité, à améliorer l'efficacité et à limiter le risque de surajustement [6].

2.3.3 Couche entièrement connectée (FC)

Le nom de la couche entièrement connectée se décrit bien. Comme mentionné précédemment, les valeurs de pixels de l'image d'entrée ne sont pas directement connectées à la couche de sortie dans des couches partiellement connectées. Cependant, dans la couche entièrement connectée, chaque nœud de la couche de sortie se connecte directement à un nœud de la couche précédente [6].

Cette couche effectue la tâche de classification basée sur les caractéristiques extraites à travers les couches précédentes et leurs différents filtres. Alors que les couches convolutionnelles et de regroupement ont tendance à utiliser les fonctions ReLu (une fonction d'activation très couramment utilisée. Acronyme de « *Rectified Linear Unit* » (unité linéaire rectifiée), elle permet tout simplement de remplacer les résultats négatifs par zéro), les couches FC exploitent généralement une fonction d'activation softmax (une fonction d'activation utilisé pour de la multi classification en couche de sortie) pour classer les entrées de manière appropriée [6].

La couche convolutive est la première couche d'un réseau convolutif. Alors que les couches convolutives peuvent être suivies de couches convolutives supplémentaires ou de couches de regroupement, la couche entièrement connectée est la couche finale. Avec chaque couche, le CNN augmente dans sa complexité, identifiant de plus grandes parties de l'image.

Les couches précédentes se concentrent sur des fonctionnalités simples, telles que les couleurs et les bords. Au fur et à mesure que les données d'image progressent à travers les couches du CNN, elles commencent à reconnaître des éléments ou des formes plus grands de l'objet jusqu'à ce qu'elles identifient finalement l'objet souhaité [6].

2.5 Réseaux de neurones convolutifs adaptatifs (Travail futur)

Malgré l'utilisation généralisée des réseaux de neurones convolutifs (CNN), et tous les bénéfices et facilitations qu'ils représentent, les opérations de convolution utilisées dans les CNN standard présentent certaines limites. Pour surmonter ces limitations, et afin de pousser la technologie plus loin, de nouvelles approches ont été adoptées parmi elles on trouve les réseaux de neurones convolutifs adaptatifs. En voici quelques exemples de réseaux de neurones convolutif adaptatif :

2.5.1 Noyau convolutif adaptatif

2.5.1.1 Concept

Un noyau adaptatif est défini par un filtre dynamique qui change lui-même ses poids en fonction de l'image entrée. Ce noyau adaptatif peut être généré à l'aide d'un tableau de noyaux traditionnels. C'est-à-dire avoir la possibilité de redéfinir dynamiquement le noyau convolutif. Où une couche adaptative peut remplacer deux couches traditionnelles [21]. En d'autres termes : les noyaux s'adaptent dynamiquement pour extraire de meilleures fonctionnalités en fonction de l'image d'entrée [21].

Des recherches ont démontré que la réponse des cellules visuelles dans l'œil humain est une fonction non linéaire. Or la convolution est une opération linéaire. Ainsi, trouver des modèles non linéaires qui représentent le mieux les données visuelles pourraient augmenter les performances de votre système. Motivé par ces résultats, un noyau est proposé dans cette approche qui inclut les transformations non linéaires. Le noyau convolutif adaptatif utilise l'image d'entrée pour définir les poids d'un noyau changeant dynamiquement. Ce nouveau noyau adaptatif est utilisé pour performer une seconde opération de convolution sur l'image d'entrée afin de générer les caractéristiques de sortie [21].

Cette approche substitue les couches de convolution ordinaires par les couches adaptatives pour comparer leurs performances d'apprentissage et de généralisation [21].

2.5.1.2 Les résultats

Les résultats dans les ensembles de données de classification d'images populaires tels que MNIST (« *Modified ou Mixed National Institute of Standards and Technology* », une base de données de chiffres écrits à la main. C'est un jeu de données très utilisé en apprentissage automatique), CIFAR-10 (un jeu de données qui comprend 60000 images 32×32 ombrées dans 10 classes, avec 6000 images pour chaque classe), Fashion et « *Faces in the Wild* » ont montré que les noyaux adaptatifs peuvent apporter des améliorations statistiquement significatives par rapport aux noyaux de convolution ordinaires. [22].

D'autre part une expérimentation faite par [21], a pu représenter une technique de noyau adaptatif qui présente le plus petit modèle CNN qui atteint plus de 99% de précision sans pré-traitement en utilisant seulement au lieu de 25 noyaux différents de taille 5x5, 15 de la même taille. De plus, cette méthode peut être mise en œuvre avec la plupart des architectures CNN existantes, comme ResNet, générant une version améliorée de celui-ci [21].

2.5.2 Classificateurs adaptatifs de groupe

2.5.2.1 Concept

La reconnaissance faciale est connue pour présenter des préjugés - les sujets de certains groupes démographiques peuvent être mieux reconnus que d'autres groupes [23]. Le test en 2019 des fournisseurs de reconnaissance faciale du NIST « *National Institute of Standards and*

CHAPITRE 2 : RESEAUX DE NEURONES CONVOLUTIFS (CNNs)

Technology » «FRVT» [24] montre que les 106 algorithmes FR « *Face Recognition* » qui ont participé au test présentent des performances déformées variables sur le sexe, la race et les groupes d'âge. [25] Le classificateur adaptatif de groupe proposé, GAC « *Group Adaptive Classifier* », apprend à atténuer les préjugés en utilisant des noyaux de convolution adaptatifs et des mécanismes d'attention sur les visages en fonction de leurs attributs démographiques (les attributs démographiques sont des propriétés liées au sujet sans impact apparent sur la reconnaissance de l'identité, du moins du point de vue d'un profane) [23].

L'étude de préjugé utilise l'ensemble de données RFW (base de données « *Racial Faces in-the-Wild* ») pour tester et l'ensemble de données BUPT-Balancedface (une base de données contenant un ensemble de données d'entraînement) pour l'entraînement (voir figure 7). Chaque groupe contient environ 10 000 images de 3 000 individus pour la vérification du visage. BUPT-Balancedface contient 1,3 million d'images de 28 000 célébrités et est approximativement équilibré par race avec 7 000 identités par race. Outre la race, les préjugés sexistes sont également étudiés [23].

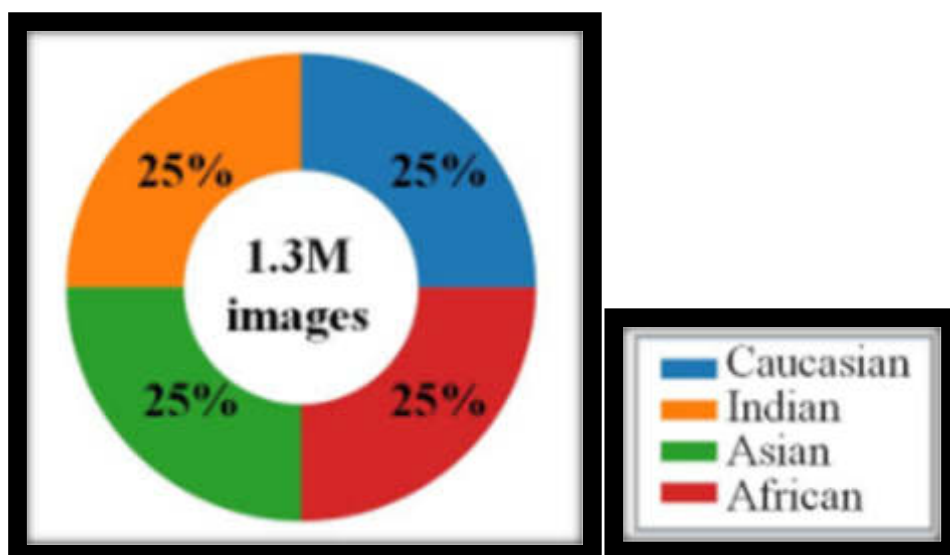


Figure N° 7 – Représentation de la bdd BUPT-Balancedface en termes de races [25].

2.5.2.2 Les résultats

Le classificateur adaptatif de groupe (GAC) a prouvé sa capacité à améliorer la robustesse des représentations pour chaque groupe démographique.

Les résultats d'expériences de [23] suggèrent que les visages peuvent être mieux représentés en utilisant des couches adaptatives à différents groupes démographiques, conduisant à un gain de performance plus équilibré pour tous les groupes. Les expériences sur les références faciales (RFW, LFW, IJB-A et IJB-C) montrent que cette approche est capable d'atténuer les préjugés de reconnaissance faciale dans les groupes démographiques tout en maintenant une précision et des performances concurrentielles. Voir figure 8 [25].

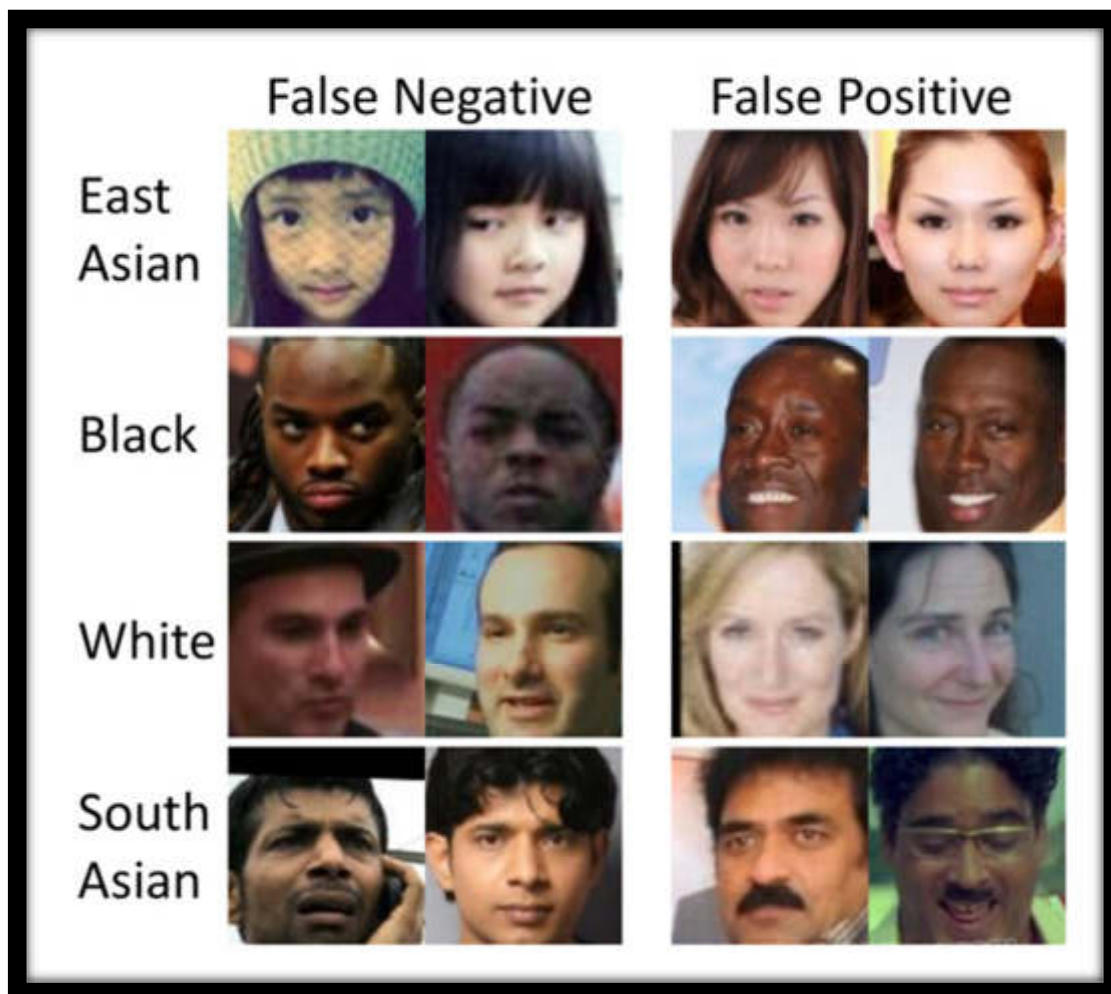


Figure N° 8 – 8 paires fausses positives et fausses négatives sur RFW données par la ligne de base mais vérifiées avec succès par le GAC [25].

2.5.3 Noyau adaptatif axé sur la forme

2.5.3.1 Concept

Le suivi d'objets est un sujet de recherche stimulant dans le domaine de la vision par ordinateur. De nombreuses approches ont été dédiées au calcul de la translation d'un objet dans des trames consécutives. Parmi lesquelles les méthodes de décalage moyen montrent des performances impressionnantes et ont reçu une attention considérable. Malgré ses performances prometteuses, il existe un problème important face au décalage moyen traditionnel, c'est-à-dire le mécanisme de sélection à l'échelle du noyau peu clair (voir figure 9). Cependant, il n'existe actuellement aucun mécanisme solide pour choisir cette échelle de manière mûre [26].

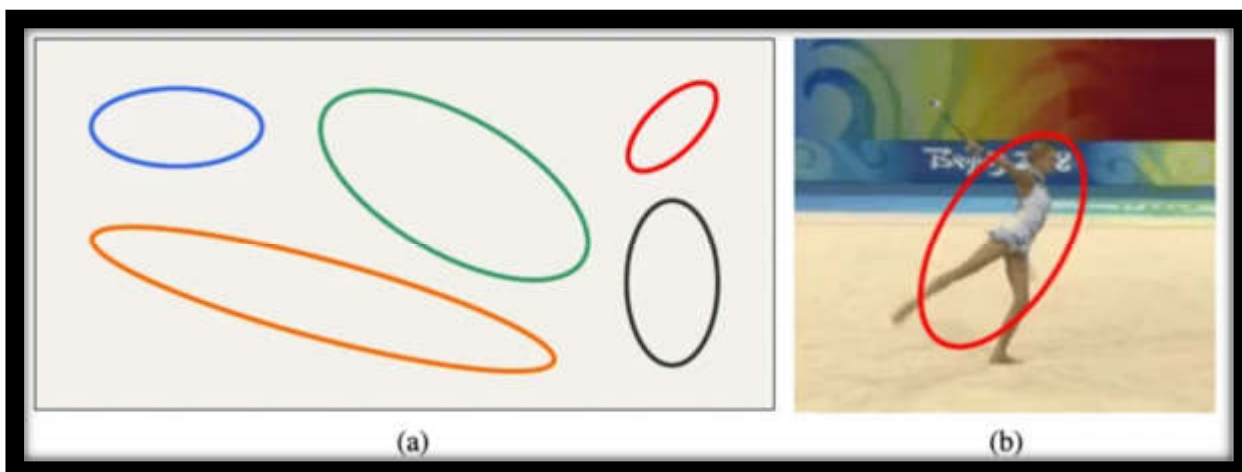


Figure N° 9 – Problèmes liés à la reconnaissance d’image : (a) Sélection échelle/orientation du noyau. (b) Forme d'objet complexe [26].

Une nouvelle approche du suivi d'objets non rigides est présentée dans cette approche en dérivant un noyau adaptatif piloté par les données. Contrairement aux trackers conventionnels basés sur le noyau qui souffrent de la constance de la forme du noyau ainsi que du problème de sélection d'échelle et d'orientation lorsque les cibles de suivi changent de taille, le noyau adaptatif peut s'adapter de manière robuste à la variation de la cible et agir vers la cible réelle. En utilisant le contour simultanément avec les itérations de décalage moyen. La technique d'ensemble de niveaux est nouvellement introduite dans l'espace d'échantillonnage de décalage moyen pour à la fois faire face à des informations de bas niveau insuffisantes et implémenter l'évolution et la mise à jour adaptatives du noyau. Étant donné que le modèle de contour actif est conçu pour diriger constamment le noyau dans la direction qui maximise la similitude d'apparence, ce noyau adaptatif peut continuellement saisir la forme cible pour donner un meilleur biais d'estimation et produire un décalage précis de la moyenne, comme illustrer sur la figure 10. Enfin, une région cible précise peut éviter avec succès la perte de performances due à la pollution des pixels d'arrière-plan cachés à l'intérieur du noyau [26].




Figure N° 10– Le noyau piloté par les données proposé et son adaptation à la variation cible [26].

CHAPITRE 2 : RESEAUX DE NEURONES CONVOLUTIFS (CNNs)

L'approche explore la manière avec laquelle, on peut dire les positions des points de repère des objets, notamment celles du visage [26].

Premièrement, au lieu d'utiliser des noyaux fixes, une méthode d'adaptation de noyau a été proposée, afin de déterminer dynamiquement les noyaux convolutifs en fonction de la distribution spatiale des repères faciaux, ce qui permet d'apprendre des caractéristiques plus robustes. Deuxièmement, se basant sur l'intuition que différentes régions faciales locales peuvent exiger différentes fonctions d'adaptation, une architecture convolutive arborescente a été proposée pour fusionner hiérarchiquement plusieurs sous-réseaux CNN adaptatifs locaux [26].

Le noyau piloté par les données proposé peut s'adapter à la forme de l'objet réel pour le suivi et ainsi qualifier les échantillons pour la mise à jour du modèle d'apparence. Une nouvelle technologie est introduite qui est le modèle de contour actif dans l'espace d'échantillonnage de décalage moyen pour à la fois faire face à l'insuffisance des informations de bas niveau et obtenir le noyau adaptatif. De plus, la dérivation d'un noyau piloté par les données, est capable d'agir vers le contour cible réel simultanément avec les itérations de décalage moyen [26].

2.5.3.2 Les résultats

Le noyau adaptatif peut être évolué et mis à jour pour s'adapter à la variation cible simultanément avec les itérations de décalage moyen. Étant donné que le modèle de contour actif est conçu pour conduire le noyau constamment dans la direction maximisant la similitude d'apparence, ce noyau adaptatif peut continuellement saisir la forme cible pour donner un meilleur biais d'estimation et produire un décalage précis de la moyenne, abordant le problème de la forme constante du noyau. Les résultats expérimentaux (représentés sur la figure 11) ont vérifié l'efficacité de la méthode proposée dans de nombreux problèmes de sélection d'orientation compliqués auxquels sont confrontés les traqueurs de noyau traditionnels [26].



Figure N° 11 – Suivi des résultats de la méthode proposée (rouge) et du décalage moyen standard (vert) sur la séquence manuelle [26].

Des expériences complètes sur les bases de données WebFace, Morph II et MultiPIE valident bien l'efficacité de la méthode d'adaptation du noyau et de l'architecture convolutive arborescente proposées pour les tâches de reconnaissance des traits du visage, y compris la reconnaissance de l'identité, de l'âge et du sexe. Pour toutes les tâches, l'architecture proposée atteint systématiquement les performances de attendues [27].

2.6 Conclusion

Nous avons éclaircie dans ce chapitre le concept de réseaux de neurones convolutifs et expliqué leur mode de fonctionnement en précisant à quel point ils sont performants, nous avons aussi abordé le sujet des réseaux de neurones convolutif adaptatif qui offrent la possibilité de rendre les CNN encore plus performants en donnant quelques exemples d'approches adaptatives.

Dans le chapitre suivant nous allons détailler les étapes nécessaires pour la construction de notre système de reconnaissance facile basé sur les réseaux de neurones convolutifs.

CHAPITRE 3

Environnements d'implémentation

3.1 Introduction

Afin de se familiariser avec l'approche de réseaux de neurones convolutifs et mieux comprendre leur mode de fonctionnement nous allons, dans ce chapitre, détailler le processus de construction de cette approche plus précisément, détailler les étapes et les outils nécessaires à cette construction.

3.2 Étapes nécessaires de construction du CNN

Les données d'entraînement :

Nos données contiennent des images de visage recadrées d'une à plusieurs personnes divisées en deux dossiers : entraînement et Test. Nous allons entraîner le modèle CNN en utilisant les images du dossier "entraînement" et ensuite tester le modèle en utilisant les images non vues du dossier "Test", et cela aurait pour but de vérifier si le modèle est capable de reconnaître et différencier entre les visages vues et non vues.

Le modèle CNN pour la reconnaissance des visages :

On a créé un modèle CNN comportant les éléments suivants :

- 2 couches cachées de convolution.
- 2 couches cachées de max pooling.
- 1 couche d'aplatissement.
- 1 couche cachée ANN.
- 1 couche de sortie avec x neurones (un pour x visage).

On a la possibilité d'augmenter ou de diminuer la convolution, le max pooling et les couches cachées ANN ainsi que le nombre de neurones qu'elles contiennent. En sachant que le plus on ajoute des couches (neurones), plus le modèle devient lent.

Outre la sélection du meilleur nombre de couches et du nombre de neurones, pour chaque couche, certains paramètres doivent être réglés :

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION

- 32 Filters est le nombre de filtres que nous utilisons pour examiner les pixels de l'image pendant l'étape de convolution. Certains filtres peuvent capturer des bords nets, d'autres des variations de couleur, d'autres encore des contours ... Ce qui a pour but d'obtenir des informations importantes à partir des images.
- La taille du filtre ou kernel (5,5) pour indiquer la taille de la fenêtre glissante pendant la convolution dans cette étude de cas nous utilisons une fenêtre glissante de 5X5 pixels.
- Strides (1, 1) ce qui indique la vitesse ou le rythme de la fenêtre coulissante pendant la convolution, On a utilisé le paramètre le plus bas de 1X1 pixels. Cela signifie faire glisser la fenêtre de convolution de 5X5 (kernel size) de 1 pixel dans l'axe x et de 1 pixel dans l'axe y jusqu'à ce que l'image entière soit scannée.
- Input shape (64,64,3) la forme d'entrée des images n'est rien d'autre qu'une matrice de codes de couleur rouge vert et bleu (RVB). Pendant le prétraitement des données, nous avons compressé les images en 64X64. Cela signifie 3 tableaux de 64X64, un pour chaque couleur RVB.
- Initialisation du kernel "uniforme" : Lorsque les neurones commencent leur calcul, un algorithme doit décider de la valeur de chaque poids. Ce paramètre spécifie cela. On peut choisir différentes valeurs pour ce paramètre comme 'normal' ou 'glorot_uniform'.
- Activation 'relu': la fonction d'activation pour les calculs à l'intérieur de chaque neurone. On peut choisir des valeurs comme 'relu', 'tanh', 'sigmoïde', ...
- Optimiseur 'adam' : Ce paramètre permet de trouver les valeurs optimales de chaque poids dans le réseau neuronal. 'adam' est l'un des optimiseurs les plus utiles, un autre est 'rmsprop'.
- Batch_size 10 : Ce paramètre spécifie le nombre de lignes qui seront transmises au réseau en une seule fois ce qui a pour but d'ajuster les poids du réseau neuronal en fonction des erreurs. 1-époque (cycle de données complet) représente la fin de la transmission des lots de 10 lignes. Une remarque pourrait être faite : Une petite valeur de batch_size fera que le LSTM (Long Short Term Memory) regarde les données lentement, comme 2 lignes à la fois ou 4 lignes à la fois, ce qui pourrait conduire à un sur-ajustement, par rapport à une grande valeur comme 20 ou 50 lignes à la fois, qui fera que le LSTM regarde les données rapidement, ce qui pourrait conduire à un sous-ajustement.
- Epochs 10 ce qui est la même activité d'ajustement des poids qui se poursuit pendant 10 fois, comme spécifié sur la figure 12.

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION

```
8/8 [=====] - 3s 324ms/step - loss: 44.4018 - accuracy: 0.0615
Epoch 2/10
8/8 [=====] - 2s 175ms/step - loss: 3.1303 - accuracy: 0.1352
Epoch 3/10
8/8 [=====] - 2s 178ms/step - loss: 2.2880 - accuracy: 0.3811
Epoch 4/10
8/8 [=====] - 2s 181ms/step - loss: 1.2750 - accuracy: 0.6393
Epoch 5/10
8/8 [=====] - 2s 189ms/step - loss: 0.5019 - accuracy: 0.9139
Epoch 6/10
8/8 [=====] - 2s 185ms/step - loss: 0.2259 - accuracy: 0.9262
Epoch 7/10
8/8 [=====] - 2s 177ms/step - loss: 0.0957 - accuracy: 0.9713
Epoch 8/10
8/8 [=====] - 2s 195ms/step - loss: 0.0544 - accuracy: 0.9918
Epoch 9/10
8/8 [=====] - 2s 177ms/step - loss: 0.0363 - accuracy: 0.9918
Epoch 10/10
8/8 [=====] - 2s 181ms/step - loss: 0.0252 - accuracy: 0.9918
##### Total Time Taken: 0 Minutes #####
```

Figure N° 12 – 10 époques d'entraînement du CNN.

Comme on peut le remarquer dans l'illustration d'en haut le niveau, après chaque fin d'epoch Accuracy ne cesse d'augmenter ce qui indique un apprentissage continu.

3.3 Technologies d'implémentation disponibles

Il existe plusieurs technologies et outils d'implémentation disponibles nécessaires à notre travail parmi eux on trouve :

Bibliothèque PyTorch :

Adam Paszke, Sam Gross, Soumith Chintala et Gregory Chanan sont les auteurs de PyTorch, qui est principalement développé par le laboratoire de recherche en intelligence artificielle de Facebook (FAIR). Il s'appuie sur le cadre de calcul scientifique basé sur Lua pour les algorithmes d'apprentissage automatique et d'apprentissage profond. PyTorch utilise Python, CUDA, ainsi que des bibliothèques C/C++, pour le traitement et a été conçu pour faire évoluer la production de modèles de construction et la flexibilité globale.[28]

Sa version initiale était en Septembre 2016, la version stable 1.7.1 / 10 décembre 2020 sous la License "Berkeley Software Distribution (BSD)" [28]

Bibliothèque TensorFlow :

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION

L'équipe de google a développé une bibliothèque d'apprentissage profond appelée TensorFlow qui prend en charge des langages comme Python et R, et utilise des graphes pour représenter et traiter les données, car lorsque vous construisez ces réseaux neuronaux, vous pouvez regarder comment les données circulent dans le réseau neuronal [28].

Sa version initiale était le 9 Novembre 2015, la version stable 2.4.1 / 21 Janvier 2021, elle a été écrite avec Python, C ++, CUDA et peut être utilisée dans de multiples plates-formes comme Linux, macOS, Windows, Android, JavaScript sous la License "Apache License 2.0" [28].

Bibliothèque Keras :

François Chollet est à l'origine de Keras, qui compte plus de 350 000 utilisateurs et plus de 700 contributeurs open-source, ce qui en fait l'une des bibliothèques d'apprentissage profond à la croissance la plus rapide. Il prend en charge une API de réseau neuronal de haut niveau, écrite en Python. Ce qui rend Keras intéressant, c'est qu'il fonctionne au-dessus de TensorFlow, Theano et CNTK (*Microsoft Cognitive Toolkit*). Il est utilisé par plusieurs startups, laboratoires de recherche et entreprises, notamment Microsoft Research, la NASA, Netflix et le Cern [28].

Sa version initiale était le 27 Mars 2015, la version stable 2.4.0 / 17 Juin 2021 sous la License "Massachusetts Institute of Technology (MIT)" [28].

Bibliothèque Theano :

L'Université de Montréal a développé Theano, écrite en Python et centrée sur NVIDIA CUDA, ce qui permet aux utilisateurs de l'intégrer au GPU. La bibliothèque Python permet aux utilisateurs de définir, d'optimiser et d'évaluer des expressions mathématiques impliquant des tableaux multidimensionnels [28].

Sa version initiale était 2007, la version stable 1.0.5 / 27 juillet 2020 sous la License "The 3-Clause Berkeley Software Distribution (BSD)" [29].

Bibliothèque Deeplearning4j (DL4J) :

Un groupe d'apprentissage automatique comprenant les auteurs Adam Gibson Alex D. Black, Vyacheslav Kokorin, Josh Patterson a développé cette bibliothèque d'apprentissage profond Deeplearning4j. Écrit en Java, Scala, C++, C, CUDA, DL4J prend en charge différents réseaux neuronaux, comme le CNN, le RNN et le LSTM (*Long Short-Term Memory*). Après que SkyMind a rejoint la Fondation Eclipse en 2017, DL4J a été intégré à Hadoop et Apache Spark. Il apporte l'IA aux environnements professionnels pour une utilisation sur des CPU et GPU distribués [28].

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION

Sa version initiale était en 2014, la version stable 1.0.0-beta6 / 10 septembre 2019 sous la License "Apache License 2.0" [28].

Jupyter Notebook :

Le Jupyter Notebook est une application web open-source qui permet aux « *data scientists* » de créer et de partager des documents qui intègrent du code en direct, des équations, des résultats de calcul, des visualisations et d'autres ressources multimédias, ainsi qu'un texte explicatif dans un seul document. Il peut être utilisé pour toutes sortes de tâches de science des données, notamment le nettoyage et la transformation des données, la simulation numérique, l'analyse exploratoire des données, la visualisation des données, la modélisation statistique, l'apprentissage automatique, l'apprentissage profond, et bien plus encore [29].

Environnement Colab :

Colab, ou "Colaboratoire", vous permet d'écrire et d'exécuter du Python dans votre navigateur. Les carnets Colab vous permettent de combiner du code exécutable et du texte enrichi dans un seul document, ainsi que des images, du HTML (*HyperText Markup Language*), du LaTeX et bien plus encore. Lorsque vous créez vos propres carnets Colab, ils sont stockés dans votre compte Google Drive. Vous pouvez facilement partager vos carnets Colab avec des collègues ou des amis, en leur permettant de commenter vos carnets ou même de les modifier [30].

Langage de programmation Python 3.6.9 :

Python est un langage de programmation créé en par Guido van Rossum au centre recherche CWI au pays- bas, sa première version est sortie en 1991. Il est connu par les caractéristiques suivantes :

- Il est gratuit
- C'est un langage de haut niveau. Il demande relativement peu de connaissance sur le fonctionnement d'un ordinateur pour pouvoir l'utilisé.
- Python est un langage facile à apprendre et son code est plus lisible, il est donc plus facile à maintenir. Il est parfois jusqu'à 5 fois plus concis que le langage **Java** par exemple
- C'est un langage interprété. Un script Python n'a pas besoin d'être compilé pour être Exécuté, contrairement à des langages comme C ou C++.
- Il est multiplate-forme, il fonctionne sur plusieurs systèmes d'exploitation : Linux, Mac OS X, Android, iOS et Windows.
- Il est orienté objet. Il est possible de concevoir en Python des entités qui simule les objets du monde réel, avec un certain nombre de règles de fonctionnement et d'interactions. [32].

3.4 Sélection des technologies d'implémentation

On a choisi les technologies suivantes pour plus tard implémenter notre travail :

Bibliothèque TensorFlow car :

- Les modèles d'apprentissage automatique de TensorFlow sont faciles à construire, peuvent être utilisés pour une production robuste d'apprentissage automatique et permettent une expérimentation puissante pour la recherche.
- Elle est la mieux adaptée au développement de modèles DL et à l'expérimentation d'architectures d'apprentissage profond.
- Elle est utilisée pour les fonctions d'intégration de données, notamment la saisie de graphiques, de tables SQL (*Structured Query Language*) et d'images ensemble [32].

Bibliothèque Keras car :

- Elle permet d'apprendre et de prototyper facilement des concepts simples.
- Elle favorise l'expérimentation rapide des réseaux neuronaux profonds.
- Elle aide à écrire un code lisible et précis [32].

Jupyter Notebook car :

- Il offre un environnement d'apprentissage profond interactif et facile à utiliser.
- Il offre également la possibilité d'utiliser python
- Il comprend les bibliothèques qui seront nécessaires à notre travail [29].

3.5 Environnement de travail

Dans cette section, nous présentons l'environnement matériel utilisé pour réaliser l'application. Les caractéristiques sont les suivantes :

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION

3.5.1 Environnement matériel

La configuration de la machine utilisée est comme suit :

- Processus : Intel Core i7 -6550 CPU 1.80 GHz x 8
- Système d'exploitation : Zorin Debian
- RAM : 8.00 GO
- Disque Dur : 1.00 TO HDD
- Carte graphique accélératrice de traitements en temps réel (GPU) : NVIDIA 920 mx

3.5.2 Environnement logiciel

Le langage de programmation utilisé dans ce travail est **Python 3.6.9**, Ou on y a rajouté les bibliothèques suivantes :

- **TensorFlow** et **keras** pour la construction du modèle de reconnaissance faciale CNN.
- **matplotlib** pour la visualisation des graphes.
- **numpy** pour le traitement des tableaux multidimensionnel.
- **pillow** pour le traitement d'images : le recadrage et le traitement de couleurs.
- **onpencv** pour la détection faciale, la capture d'image à travers vidéo.

3.6 Mode de fonctionnement

Notre système détecte le visage de la personne voulant être détecté en temps réel, si le système réussit à la reconnaître il précisera l'identité de la personne reconnue et affichera « **le nom** » de cette dernière sous son visage, si non le mot « **unkown** » sera affiché sous le visage, voulant dire « non reconnu ».

En voici des exemples de reconnaissance faciale (illustrés dans les figures 13,14 et 15) touchant aux deux cas possibles (cas positif = reconnu // cas négatif = non reconnu) :

CHAPITRE 3 : ENVIRONNEMENT D'IMPLEMENTATION




Figure N° 13 – Premier exemple de détection positive



Figure N° 14 – Deuxième exemple de détection positive




Figure N° 15 – Exemple de détection négatif

3.5 Conclusion

Pour conclure ce travail, ce chapitre a été consacré à la partie environnement d'implémentation nous avons commencé par les étapes nécessaires pour la construction de notre réseau de neurones convolutifs CNN, et après, cité les technologies d'implémentation disponibles puis, une sélection a été faite concernant ces technologies pour utiliser celles qui conviennent justement la construction de notre système.

Par la suite nous avons montré des exemples concrets d'exécution du système en question pour mieux expliquer son fonctionnement et les résultats obtenus.

Conclusion générale

La machine serait toujours située à des années-lumière du cerveau humain, n'empêche que les chercheurs essaient encore et encore d'atteindre le maximum de performances automatisées possibles, d'où la naissance des réseaux de neurones artificiels, et même après cet immense exploit, on continue à pousser la science de l'avant et les approches de réseaux de neurones convolutifs adaptatifs en sont la preuve. Ces réseaux réussissent à atteindre des performances presque dignes de l'œil et du cerveau humain, ils peuvent reconnaître les images avec une haute précision et presque sans fautes.

Grace a la capacite des réseaux de neurones dans l'apprentissage, les réseaux de neurones convolutifs peuvent surmonter le challenge de reconnaissance et d'identification dans les cas non contrôlés, à savoir : les changements de pose, variations d'éclairage, les expressions faciales, les occultations partielles, etc.

Notre projet consiste en la réalisation d'un système de reconnaissance faciale par CNN, notre système est capable de reconnaître les visages des personnes en temps réel et de préciser l'identité de la personne reconnue, si cette dernière ne figure pas sur la base de données du système il rend le résultat « unkown » qui veut dire « inconnu ».

Les outils et technologiques choisie sont des bibliothèques open source et gratuites pour le développement et la commercialisation, ce qui implique qu'ils sont disponibles sans tarif ou paiement par ailleurs il y a une grande communauté de développeur qui les utilise ce qui faciliteras la recherche et la documentation et cela vas permettre un développement fluide.

On a choisi Jupyter Notebook comme environnement d'implémentation car il inclut keras et tensorflow dans ses bibliothèques, de plus il permet le développement en local, keras pour sa simplicité, sa capacité à réduire la charge cognitive et ces messages d'erreur explicites, et enfin, tensorflow pour son abstraction et facilité concernant la création de modèles.

Au final de ce travail, nous aimerions souligner le fait que la technologie n'est jamais satisfaite et ne s'arrête guère de progresser, de nouvelles dérivées de réseaux de neurones convolutifs sont apparue rendant les résultats de la reconnaissance faciale meilleur et presque même parfaits !

Notre système permettra la reconnaissance de visage d'une manière sure et efficace avec le moins de possibilité d'erreurs possible et un temps de réponse moindre.

Nous visons dans un travail futur d'implémenter une de ces approches adaptatives afin de comparer nos résultats obtenus avec ce travail avec les résultats futurs.

Bibliographie

Livre

2. Hurwitz, J., & Kirsch, D. (2018). Machine learning for dummies. IBM Limited Edition, 75.

Documents webs

- 1-« Electronic IDentification (eID) , " Reconnaissance Faciale : son fonctionnement et sa sécurité",» [En ligne]. Accessible : <https://www.electronicid.eu/fr/blog/post/reconnaissance-faciale/fr> [Accès le 12/11/2021]
- 3-«VeoNum ,» [En ligne]. Accessible : <https://www.veonum.com/wp-content/uploads/2019/10/Machine-learning-et-NN.pdf> [Accès le 12/11/2021]
- 4- «datascience (Data Science Team),» [En ligne]. Accessible : <https://datascience.eu/fr/apprentissage-automatique/top-6-des-techniques-dapprentissage-machine/> [Accès le 12/11/2021]
- 5-«Djamel Belhaouci ,» [En ligne]. Accessible : <https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-les-reseaux-de-neurones-artificiels> [Accès le 14/11/2021]
- 6-«IBM Cloud Education “ Convolutional neural networks ”» [En ligne]. Accessible : <https://www.ibm.com/cloud/learn/convolutional-neural-networks> [Accès le 12/06/2022]
- 7-«lebigdata ,5 avril 2019,» [En ligne]. Accessible : <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition> [Accès le 13/11/2021]
- 8-«stemmer-imaging ,» [En ligne]. Accessible : <https://www.stemmer-imaging.com/fr-ch/conseil-technique/apprentissage-automatique-et-apprentissage-profond/> [Accès le 13/11/2021]
- 9-«Pascal Monasse et Kimia Nadjahi , "Qu'est ce qu'un réseau de neurones convolutif" » [En ligne]. Accessible : <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn> [Accès le 16/11/2021]
- 10-«Pragati Baheti ,November 29, 2021 ,» [En ligne]. Accessible : <https://www.v7labs.com/blog/neural-network-architectures-guide#what-are-neural-networks> [Accès le 20/11/2021]
- 11-« Kaspersky, “What is Biometrics? How is it used in security?” » [En ligne]. Accessible : <https://www.kaspersky.com/resource-center/definitions/biometrics> [Accès le 12/06/2022]
- 12-«Gary B,"Convolutional neural network", 25 juin 2020,» [En ligne]. Accessible : <https://datascientest.com/convolutional-neural-network> [Accès le 21/11/2021]
- 13-«Julien Krywyk, Pierre-Alain Jachiet , "Classification d'images : les réseaux de neurones convolutifs en toute simplicité", 25/10/2016[En ligne]. accessible: <https://blog.octo.com/classification-dimages-les-reseaux-de-neurones-convolutifs-en-toute-simplicité/> [Accès le 20/11/2021]
- 14-« TechTarget, “biometrics” » [En ligne]. Accessible : <https://www.techtarget.com/searchsecurity/definition/biometrics> [Accès le 12/06/2022]
- 15-« Kaspersky, “What is Biometrics? How is it used in security?” » [En ligne]. Accessible : <https://www.kaspersky.com/resource-center/definitions/biometrics>
- 16-«electronicid , "Reconnaissance Faciale : son fonctionnement et sa sécurité", Oct 15, 2021 » [En ligne]. Accessible : <https://www.electronicid.eu/fr/blog/post/reconnaissance-faciale/fr> [Accès le 21/11/2021]

- 17-« thales , "Reconnaissance faciale, une biométrie qui fascine autant qu'elle interroge", 2021 » [En ligne]. Accessible : <https://www.thalesgroup.com/fr/europe/france/dis/gouvernement/biometrie/reconnaissance-faciale> [Accès le 21/11/2021]
- 18-« International Journal of Security and Its Applications, "Face Recognition Using Neural Network Vol. 10, No. 3 " ,2016» [En ligne]. Accessible : http://article.nadiapub.com/IJSIA/vol10_no3/8.pdf [Accès le 22/11/2021]
- 19-« WE DEMAIN," 9 dates qui ont marqué l'essor de la reconnaissance faciale" » [En ligne]. Accessible : https://www.wedemain.fr/inventer/9-dates-qui-ont-marque-l-essor-de-la-reconnaissance-faciale_a4568-html/ [Accès le 12/06/2022]
- 20-«Laurene B ,"Réseaux de neurones DenseNet : tout ce qu'il y a à savoir", 28 juin 2021 » [En ligne]. Accessible : <https://datascientest.com/reseaux-de-neurones-densenet> [Accès le 21/11/2021]
- 21-« Julio Zamora-Esquivel, Adan Cruz Vargas, Paulo Lopez Meyer et Omesh Tickoo,"Adaptive Convolutional Kernels",2019» [En ligne]. Accessible : https://openaccess.thecvf.com/content_ICCVW_2019/papers/NeurArch/Esquivel_Adaptive_Convolutional_Kernels_ICCVW_2019_paper.pdf [Accès le 22/11/2021]
- 22-«F. Boray Tek, Ilker C , am, Deniz Karlı ,"Adaptive Convolution Kernel for Artificial Neural", 15 septembre 2020» [En ligne]. Accessible : <https://arxiv.org/pdf/2009.06385.pdf> [Accès le 27/11/2021]
- 23-«Sixue Gong ,Xiaoming Liu et Anil K. Jain ,"Mitigating Face Recognition Bias via Group Adaptive Classifier", 1 decembre 2020 » [En ligne]. Accessible : <https://arxiv.org/pdf/2006.07576.pdf> [Accès le 03/12/2021]
- 24-«Patrick Grother, Mei Ngan et Kayee Hanaoka ,"Face Recognition Vendor Test (FRVT) Part 3: Demographic Effects", Decembre 2019» [En ligne]. Accessible : <https://nvlpubs.nist.gov/nistpubs/ir/2019/NIST.IR.8280.pdf> [Accès le 03/12/2021]
- 25-« Mei Wang et Weihong Deng, Mitigate Bias in Face Recognition using Skewness-Aware Reinforcement Learning, 25 novembre 2019 » [En ligne]. Accessible : <https://arxiv.org/pdf/1911.10692.pdf> [Accès le 03/12/2021]
- 26-«Xin Sun, Wei Wang et Dong Li ,"Object contour tracking via adaptive data-driven kernel", 28 Fevrier 2020» [En ligne]. Accessible : <https://link.springer.com/article/10.1186/s13634-020-0665-x> [Accès le 03/12/2021]
- 27-«Shaoxin Li, Junliang Xing, Zhiheng Niu, Shiguang Shan et Shuicheng Yan ,"Shape driven kernel adaptation in Convolutional Neural Network for robust facial trait recognition", juin 2015» [En ligne]. Accessible : <https://ieeexplore.ieee.org/document/7298618> [Accès le 03/12/2021]
- 28-«simplilearn, "Top 10 Deep Learning Frameworks You Should Know in 2021 (Lesson 6 of 18)", 18 septembre 2021, » [En ligne]. Accessible : <https://www.simplilearn.com/tutorials/deep-learning-tutorial/deep-learning-frameworks> [Accès le 14/02/2022]
- 29-«Karlijn Willems, "Jupyter Notebook Tutorial : The Definitive Guide", 12 novembre 2019, » [En ligne]. Accessible : <https://www.datacamp.com/community/tutorials/tutorial-jupyter-notebook> [Accès le 15/02/2022]
- 30-«Colaboratory, "Frequently Asked Questions " , » [En ligne]. Accessible : <https://research.google.com/colaboratory/faq.html> [Accès le 15/02/2022]
- 31-« Apprendre le langage de programmation python » [En ligne]. Accessible : <https://python.doctor/> [Accès le 12/06/2022]
- 32-«mobiskill,"Quels sont les frameworks utilisés en Deep Learning ?", 25 mai 2021, » [En ligne]. Accessible : <https://mobiskill.fr/blog/conseils-emploi-tech/quels-sont-les-frameworks-utilises-en-deep-learning/?fbclid=IwAR1tX84ya385vt5D45PjKpEhgpKkExCBExiyWpuLM4QJyNWKbDvViThLAI> [Accès le 14/02/2022]