



Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie  
Département : Mathématiques et Informatique

**Mémoire de fin d'études**  
Présenté pour l'obtention du diplôme de

**Master2**

**Spécialité:** Informatiques.

**Option:** Systèmes et Multimédia.

**Thème**

# Apprentissage Résiduel Approfond pour la vérification de signature manuscrite hors ligne

**Présenté par:**  
- HAROUN Loubna

**Devant le jury:**

Dr	DJEDDI Chawki	MCA Université de Tebessa	Président
Dr	Bennour Akram	MCA Université de Tebessa	Examineur
Ms	Hadjadj Ismail	MAA Université de Tebessa	Encadreur

Promotion 2019/2020

# Remerciements

Je tiens à remercier toutes les personnes qui ont contribué au succès de mon stage et qui m'ont aidée lors de la rédaction de ce mémoire.

Je voudrais dans un premier temps remercier, mon encadreur de mémoire HADJADJ ISMAIL, prof de informatique à l'université de tebessa, pour sa patience, sa disponibilité et surtout ses judicieux conseils, qui ont contribué à alimenter ma réflexion.

Je remercie également toute l'équipe pédagogique de l'université de Tebessa et les intervenants professionnels responsables de ma formation, pour avoir assuré la partie théorique de celle-ci.

Mes parents, pour leur soutien constant et leurs encouragements.

Je tiens à témoigner toute ma reconnaissance aux personnes suivantes, pour leur aide dans la réalisation de ce mémoire :

FAYOUZ TRAD.WAFAA HAROUN.AMIRA.NADJMA.ZINA.LAMIA.



*Merci à tous !*

LOUBNA HAROUN

# Résumé

La signature d'une personne est un attribut biométrique important d'un être humain qui peut être utilisé pour authentifier l'identité humaine.

Cependant, les signatures humaines peuvent être traitées comme une image et reconnues en utilisant la vision par ordinateur et les techniques de réseaux neuronaux. Avec les ordinateurs modernes, il faut développer des algorithmes rapides pour la reconnaissance des signatures.

Il existe différentes approches de la reconnaissance des signatures, de la portée de la recherche.

Dans cet article consiste à proposer un modèle basé sur les réseaux de neurones à convolution (CNN) pour la vérification de la signature hors ligne indépendante de l'écrivain (WI-OSV).

Les signatures sont vérifiées en fonction des paramètres extraits à partir de la signature en utilisant diverses techniques de traitement d'image.

La reconnaissance et la vérification des signatures hors ligne sont mises en œuvre à l'aide de ResNet; La base de données ICDAR 2011 sigComp est utilisée pour l'ensemble des expériences et pour la validation du modèle.

# Abstract

The signature of a person is an important biometric attribute of a human being which can be used to authenticate human identity. However human signatures can be handled as an image and recognized using computer vision and neural network techniques. With modern computers, there is need to develop fast algorithms for signature recognition.

There are various approaches to signature recognition with a lot of scope of research. In this paper consists in proposing a model based on convolution neural networks (CNN) for the verification of writer independent offline signature verification (WI-OSV).

Signatures are verified based on parameters extracted from the signature using various image processing techniques.

The Off-line Signature Recognition and Verification is implemented using The ResNet ; The ICDAR 2011 sigComp database is used for the set of experiments and for model validation.

# Table des matières

<b>Remerciements</b>	<b>i</b>
<b>Résumé</b>	<b>ii</b>
<b>Abstract</b>	<b>iii</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Systèmes Biométriques</b>	<b>4</b>
1 Définition . . . . .	5
1.1 Les modules de systém biométrique . . . . .	6
1.2 Architecture d'un système biométrique . . . . .	7
2 Principaux Modalités Biométriques . . . . .	8
2.1 Modalités morphologiques (physiologiques) . . . . .	9
2.2 Modalités biologiques . . . . .	11
2.3 Modalités comportementale . . . . .	12
2.4 Représentation comparative entre quelques Techniques Biométriques . . . . .	14
3 Les systèmes de vérification de la signature . . . . .	15
3.1 Signature Authentique . . . . .	15
3.2 Signature Falsifiée . . . . .	15
3.3 Modes de fonctionnement . . . . .	15
3.4 La vérification de la signature En ligne(Online) . . . . .	16
3.5 La vérification de la signature Hors ligne(Offline) . . . . .	17
3.6 Type de falsification . . . . .	17
4 Processus d'un système de la vérification de signature . . . . .	18

4.1	L'acquisition des données . . . . .	18
4.2	Prétraitement de l'image . . . . .	20
4.3	Amélioration d'image . . . . .	20
4.4	Ségmentation . . . . .	21
4.5	Extraction de caractéristiques . . . . .	21
4.6	Classification . . . . .	22
5	Présentation de certaines techniques de la classification . . . . .	23
5.1	K plus proches voisin(KNN) . . . . .	23
5.2	Fuzzy c-means . . . . .	23
5.3	k-means . . . . .	24
5.4	Machine à vecteurs de support(SVM) . . . . .	24
5.5	Les Réseaux de Neurones . . . . .	25
6	Conclusion . . . . .	26
<b>2</b>	<b>Les réseaux de neurones convolutionnels</b>	<b>27</b>
1	Apprentissage automatique (Machine learning) . . . . .	28
1.1	Les Différents Procédés d'Apprentissage . . . . .	29
1.2	La différence entre l'apprentissage supervisé et non-supervisé . . . . .	29
2	réseaux de neurones artificielles (ANNs) . . . . .	30
2.1	Neurone Formel . . . . .	30
2.2	Neurones multicouche . . . . .	30
2.3	Types de réseaux de neurones artificielles (ANNs) . . . . .	31
3	L'apprentissage Profond(Deep Learning) . . . . .	34
3.1	Domaines d'application de l'apprentissage profond . . . . .	34
3.2	Quelques algorithmes de l'apprentissage profond . . . . .	34
3.3	la Différence entre Apprentissage profond et Apprentissage automatique . . . . .	35
4	Les réseaux de neurones convolutifs CNN . . . . .	35
4.1	L'architecture de CNN . . . . .	36
4.2	Choix des paramètres . . . . .	39
4.3	Avantages de CNNs . . . . .	39
5	Deep Résidual Learning . . . . .	40

5.1	Apprentissage résiduel profond (Deep Residual Learning) . . . . .	40
5.2	Apprentissage Résiduel . . . . .	41
5.3	Mappage D'identité par Raccourcis . . . . .	42
6	Conclusion . . . . .	43
<b>3</b>	<b>Etat de l'Art</b> . . . . .	<b>44</b>
1	Vérification de signature (Etat de l'Art) . . . . .	45
1.1	CNN basé VGG architecture pour la vérification de signature hors ligne . . . . .	45
1.2	CNN pour la vérification de la signature dans le secteur bancaire . . . . .	45
1.3	Vérification des signatures manuscrites à l'aide du Deep Learning . . . . .	46
1.4	Vérification de signature hors ligne à l'aide de DAG-CNN . . . . .	47
1.5	Vérification des signatures hors ligne authentiques et falsifiées à l'aide de Siamese Neural Network (SNN) . . . . .	47
1.6	Détection des falsification à l'aide du Deep Learning . . . . .	48
2	Comparaison des Travaux . . . . .	49
3	Deep Résiduel Learning (Etat de l'Art) . . . . .	49
3.1	Travaux William Du et al . . . . .	49
3.2	Travaux Songtao Wu et al.2017 . . . . .	50
3.3	Travaux Dongwook Lee et al.2017 . . . . .	50
4	Conclusion . . . . .	52
<b>4</b>	<b>Deep Résiduel Learning Pour la Vérification des signatures</b> . . . . .	<b>53</b>
1	Présentation des outils de développement . . . . .	54
1.1	Matériel . . . . .	54
1.2	Python . . . . .	54
1.3	Google Colab . . . . .	54
2	Architecture du système proposé . . . . .	55
2.1	Prétraitement . . . . .	55
2.2	Structure de Residual Learning (ResNet) . . . . .	56
3	Résultats et comparaison les travaux . . . . .	57
3.1	Présentation de la base de données . . . . .	57
3.2	Résultats . . . . .	58

---

4	Conclusion . . . . .	59
	<b>Conclusion</b>	<b>60</b>



# Table des figures

1.1	Les modalités biométriques.[3] . . . . .	6
1.2	Architecture d'un système biométrique . . . . .	8
1.3	Classification d'un certain nombre de modalités biométriques [8] . . . . .	8
1.4	Images de l'empreinte digitale[10]. . . . .	9
1.5	Image visage[5]. . . . .	10
1.6	Image Iris[11]. . . . .	10
1.7	Image de la rétine . . . . .	10
1.8	Image Géométrie de main[5]. . . . .	11
1.9	Image d'ADN[X]. . . . .	11
1.10	Image de système configuration des veines[13] . . . . .	12
1.11	Image de la Reconnaissance vocale[3]. . . . .	12
1.12	Image de la frappe au clavier[3]. . . . .	13
1.13	Images sur la démarche[2]. . . . .	13
1.14	Image signature[14]. . . . .	14
1.15	Les différents types de falsification a) Signature authentique b) Falsification aléatoire c) Falsification non qualifiée (simple) d) Falsification qualifiée . . . . .	18
1.16	Processus d'un système de la vérification de signature . . . . .	18
1.17	Signature hors ligne (statique)[17]. . . . .	19
1.18	Signature en ligne (dynamique)[17]. . . . .	19
1.19	Prétraitement de la signature (a) signature scannée, (b) après binarisation, (c) après réduction du bruit, (d) après normalisation de la taille, (e) après dilution . . . . .	20
1.20	Image binarisée . . . . .	20
1.21	Exemple de lissage [8] . . . . .	21
1.22	Amélioration d'image . . . . .	21

1.23	Ségmentation d'image[17]. . . . .	21
1.24	Structure d'un réseau de neurone biologique et le cerveau humain.[23] . . . . .	25
2.1	La relation entre l'intelligence artificielle, le ML et le deep learning . . . . .	28
2.2	philosophie du Machine learning . . . . .	29
2.3	schéma d'un perceptron multicouche[32]. . . . .	31
2.4	Le modèle de Kohonen[23]. . . . .	32
2.5	La séparation linéaire entre la classe A et B[22]. . . . .	33
2.6	Réseaux de neurones récurrents[22]. . . . .	33
2.7	L'architecture de CNN . . . . .	36
2.8	Représentation de la fonctionnalité Convolution [22] . . . . .	37
2.9	Max Pooling avec un filtre $2 \times 2$ et un pas de 2 . . . . .	38
2.10	Représentation de la fonctionnalité FC . . . . .	38
2.11	Exemple de max pooling ( $2 \times 2$ ). . . . .	40
2.12	Erreur d'apprentissage (à gauche) et erreur de test (à droite) sur CIFAR-10 Avec des réseaux "simples" à 20 et 56 couches. Le réseau plus profond a une erreur d'apprentissage plus importante, et donc une erreur de test, Des phénomènes similaires sur ImageNet sont présentés dans la Fig4.1 . . . . .	41
2.13	Residuel learning . . . . .	42
3.1	Architecture Résumé de la couche . . . . .	46
3.2	Model Architecture . . . . .	46
3.3	Architecture proposé pour DAG-CNN . . . . .	47
3.4	Architecture de Siamese Neural . . . . .	48
3.5	L'architecture outline des couches CNN . . . . .	48
3.6	Architecture de CNN . . . . .	49
3.7	Architecture générale de notre modèle de ResNet[52] . . . . .	50
3.8	DRN for steganalysis . . . . .	51
3.9	L'échelle simple l'apprentissage restant avec un modifié le cadre de réseau de deconvolution [54] . . . . .	51
4.1	L'architecture de système Proposé . . . . .	55
4.2	Structure de Residual Learning (ResNet) . . . . .	56

---

4.3	Exemples de signatures de la base de données ICDAR 2011. Rangée du haut: signatures du sous-ensemble chinois, rangée du bas: signatures du sous-ensemble néerlandais. . . .	58
-----	---	----

# Liste des tableaux

1.1	Comparaison entre les traits biométriques [14] . . . . .	14
2.1	La différence entre apprentissage profond et Apprentissage automatique[36] . . . . .	35
3.1	Principaux travaux de recherche dans le domaine vérification de la signature . . . . .	49
4.1	Couches du CNN . . . . .	57
4.2	Principaux travaux de recherche dans le domaine vérification de la signature . . . . .	58

# Introduction générale

La sécurité des systèmes d'information est devenue un domaine de recherche d'une très grande importance, La conception d'un système d'identification fiable, efficace et robuste est une tâche prioritaire.

L'identification de l'individu est essentielle pour assurer la sécurité des systèmes et des organisations. Elle correspond à la recherche de l'identité de la personne qui se présente dans une base de données et peut servir à autoriser l'utilisation des services. Elle peut être également utilisée par la police judiciaire . Pour répondre à ces besoins, la biométrie semble être une solution pratique. En effet, cette technique connaît un développement fulgurant. entraîne le développement de méthodes biométriques très variées :comme l'étude des empreintes,les signatur..

La signature manuscrite d'un individu représente un bon compromis :tout en étant relativement fiable, elle est facile à acquérir et elle est socialement bien acceptée comme mode d'identification.

La signature est un moyen utilisé depuis fort longtemps, pour authentifier des documents, pour responsabiliser les individus face à des engagements . La signature est donc reconnue comme mode de validation associé à l'identité d'une personne.

Plusieurs systèmes ont été développés à ce jour afin d'automatiser la vérification des signatures et on peut diviser ces méthodes en deux classes suivant le mode d'acquisition de l'image des signatures: en-ligne et hors-ligne.

Dans le cas en-ligne (On-Line), la signature est capturée à l'aide d'un périphérique de saisie spécial (un disque numérique connecté à un ordinateur, par exemple). Cette méthode vous permet d'utiliser des informations dynamiques telles que la vitesse, la position, la pression et / ou l'inclinaison du stylet, Ces systèmes ne peuvent pas être utilisés pour vérifier des signatures déjà apposées sur des documents (chèques bancaires par exemple).

Inversement, lors du contrôle de la signature en mode hors-ligne (Off-Line), la signature est obtenue une fois le processus d'écriture terminé, en numérisant un document contenant la signature et en le représentant sous la forme d'une image numérique. Les informations dynamiques sur la création de signature (telles que la position du stylo et la vitesse dans le temps) sont perdues, ce qui rend le problème très difficile.

Dans ce projet, nous visons à établir un système de vérification de signature utilisant un Réseau de Neurones Convolutif (CNN), afin d'améliorer le taux de la vérification. Nous avons discuté des notions

fondamentales des réseaux de neurones convolutif. Notre travail a été validé sur la base de données ICDAR2011.

\* **Problématique:**

Dans ce mémoire, qui consiste à essayer de résoudre les problèmes liés à la vérification de signature hors ligne, Nous proposons pour cela, d'étudier l'efficacité d'utilisation des Residual networks (ResNet) pour détecter la falsification de signature.

Pour élaborer cette problématique, nous progressons étape par étape, en commençant par introduire le sujet tout en se focalisant sur la vérification de signature, Nous continuons par l'état de l'art de la vérification de signature par l'utilisation de Deep Learning dans la littérature, ainsi les travaux liée au Residual Learning , qui nous permettra de proposer une méthode indépendante d'utilisateur basé sur les Residual Networks pour la détection de falsification et la mettre sous test en utilisant la base de données ICDAR 2011.

\* **Objectifs principaux de mon travail:**

Etat de l'art sur différentes méthodes basé Deep Learning pour la vérification de la signature.

Proposition d'une méthode basé ResNet pour la détection de falsification.

Evaluation des performances du système proposé.

\* **Organisation du mémoire:**

Dans le cadre de ce mémoire,nous aborderons le problème de la vérification des signatures manuscrites à partir d'une saisie«OffLine», à l'aide d'une approche inspirée des méthodes utilisées par les experts.

- \* Le premier chapitre contient une généralité sur la biométrie et définit ce qu'est la vérification de signature en général, et puis définit le processus d'un système de la vérification de signature et présentation de certaines techniques de la classification
- \* Le deuxième chapitre est consacré à l'apprentissage profond (deep learning), une description plus détaillée et les étapes principales d'opérations sur les réseaux de neurones convolutifs (CNNs) qui est la méthode choisie dans notre projet.

- \* Dans le troisième chapitre, nous présentons les différents travaux pour la vérification de signature avec CNN et Deep Résidual Learning.
- \* Dans le dernier chapitre, un modèle basé sur les Réseau de nuerons convolutifs est présenté, où un ensemble d'expérimentation sont faites sur la base de données ICDAR2011. Enfin nous terminerons ce mémoire par une conclusion générale et perspective pour les futurs travaux.

## Chapter 1

# Systemes Biométriques



Avec le développement technologique rapide, la sécurité devient l'un des sujets le plus préoccupant au sein de notre société et qui pose un délicat problème pour les citoyens, les entreprises et le gouvernement au niveau de la protection des informations et des données sensibles. Pour toutes ses raisons, il est obligatoire de créer une nouvelle technique de contrôle, il s'agit du système biométrique qui constitue une solution efficace.

Dans ce chapitre, on donne quelques notions et définitions de base liées à la biométrie. Nous introduirons aussi le principe de fonctionnement d'un système biométrique et ses performances ainsi que les différentes modalités utilisées.

## 1 Définition

L'étymologie de ce terme biométrie provient de deux mots grecs : ['bios':la vie et 'Metrikos': mesure] [1]. Le mot biométrie est une traduction du mot anglais « biométrics » qui correspond en français à l'anthropométrie. Il désigne dans un sens très large l'étude quantitative des êtres vivants.

La biométrie est une mesure des caractéristiques biologiques pour l'identification ou l'authentification d'un individu à partir de certaines de ses caractéristiques: comportementales (exemple de la dynamique de frappe au clavier), physiques ou physiologiques (exemple de l'ADN).

Cette technique est utilisée de plus en plus aujourd'hui pour établir la reconnaissance des personnes dans un grand nombre d'applications diverses.[2]

On peut aussi la définir comme suit : c'est l'analyse mathématique de toutes caractéristiques physiques ou traits personnels automatiquement mesurables, permanents et distinctives qui peuvent être utilisées pour identifier un individu ou pour vérifier l'identité prétendue d'un individu.[3]

Pour que les caractéristiques, propre à chaque individu, puissent être qualifiées de modalités biométriques, On distingue trois catégories des caractéristiques biométriques :

- \* Biologiques: comme le sang, la salive, l'urine, l'odeur ou encore l'ADN. Ces méthodes sont difficiles à mettre en œuvre pour une utilisation courante .
- \* Comportementales: comme la signature, les frappes clavier, la démarche (le mouvement des hanches, des bras et des épaules) .
- \* Morphologiques: comme les empreintes digitales, le visage, l'iris, la rétine ou la forme de la main.


Afin d'être fiable, une modalité biométrique doit être déterminée par quelque caractéristiques. Parmi les propriétés d'une modalité biométrique, on trouve :

- \* Universelle : toute personne possède la modalité,
- \* Unique : deux personnes ne partagent pas la même modalité,

- \* Permanente : la modalité ne change pas,
- \* Percevable : la modalité est facilement recueillie,
- \* Acceptable : les utilisateurs acceptent d'utiliser la modalité[1].

Le mode de vérification ou authentification est une comparaison "un à un", dans lequel le système valide l'identité d'une personne en comparant les données biométriques saisies avec le modèle biométrique de cette personne stockée dans la base de données du système.

Le mode d'identification est une comparaison "un à N", dans lequel le système reconnaît un individu en l'appariant avec un des modèles de la base de données [4].



**Figure 1.1** – Les modalités biométriques.[3]

## 1.1 Les modules de système biométrique

Dans un système biométrique il existe toujours trois modules: le module d'apprentissage, celui de la reconnaissance et le module d'adaptation [2] [1].

### Module d'apprentissage

Au cours de l'apprentissage, la caractéristique biométrique est tout d'abord mesurée grâce à un capteur ; on parle d'acquisition ou de capture. En général, cette capture n'est pas directement stockée et des transformations lui sont appliquées. En effet, le signal contient de l'information inutile à la reconnaissance et seuls les paramètres pertinents sont extraits. Le modèle est une représentation compacte du signal qui permet de faciliter la phase de reconnaissance, mais aussi de diminuer la quantité de données à stocker. Il est à noter que la qualité du capteur peut grandement influencer les performances du système. Meilleure est la qualité du système d'acquisition, moins il y aura de pré- traitements à effectuer pour extraire les paramètres du signal.

### Module de reconnaissance

Au cours de la reconnaissance, la caractéristique biométrique est mesurée et un ensemble de paramètres est extrait comme lors de l'apprentissage. Le capteur utilisé doit avoir des propriétés aussi proches que possibles du capteur utilisé durant la phase d'apprentissage. Si les deux capteurs ont des propriétés trop différentes, il faudra en général appliquer une série de pré-traitements supplémentaires pour limiter la dégradation des performances. La suite de la reconnaissance sera différente suivant le mode opératoire du système : identification ou vérification. En mode identification, le système doit deviner l'identité de la personne. Il répond donc à une question de type : « Qui suis je ? ». Dans ce mode, le système compare le signal mesuré avec les différents modèles contenus dans la base de données (problème de type 1 : n). En général, lorsque l'on parle d'identification, on suppose que le problème est fermé, c'est-à-dire que toute personne qui utilise le système possède un modèle dans la base de données.[5]

### Module d'adaptation

Pendant la phase d'apprentissage, le système biométrique ne capture souvent que quelques instances d'un même attribut afin de limiter la gêne pour l'utilisateur. Il est donc difficile de construire un modèle assez général capable de décrire toutes les variations possibles de cet attribut. De plus, les caractéristiques de cette biométrie ainsi que ses conditions d'acquisition peuvent varier. L'adaptation est donc nécessaire pour maintenir voire améliorer la performance d'un système utilisation après utilisation.[5]

L'adaptation peut se faire en mode supervisé ou non-supervisé mais le second mode est de loin le plus utile en pratique. Si un utilisateur est identifié par le module de reconnaissance, les paramètres extraits du signal serviront alors à ré-estimer son modèle. En général, le taux d'adaptation dépend du degré de confiance du module de reconnaissance dans l'identité de l'utilisateur. Bien entendu, l'adaptation non-supervisée peut poser problème en cas d'erreurs du module de reconnaissance. L'adaptation est quasi indispensable pour les caractéristiques non permanentes comme la voix [6] [7].

## 1.2 Architecture d'un système biométrique

Le système biométrique repose sur deux processus : celui dit d'enrôlement biométrique et celui de recherche et de vérification (contrôle).

L'enrôlement : cette étape sert à créer la base de données de référence. Ses étapes sont multiples et ordonnées : capture de l'échantillon biométrique, extraction des données décrivant les caractéristiques de cet échantillon, création d'un gabarit reproduisant l'ensemble des données de l'échantillon original, mise en mémoire de celui-ci sur une base de données centralisée ou dans un dispositif tel que disque dur, carte à puce, code barre.

Le processus de vérification (contrôle) : cette étape permet de comparer une donnée d'utilisateur à une

donnée de référence. Il se décompose de la façon suivante : utilisation du dispositif biométrique pour la capture d'un échantillon, extraction des données numériques, création d'un candidat gabarit reproduisant l'ensemble des données caractéristiques de l'échantillon original qui servira à effectuer la recherche et la vérification, placement du candidat gabarit dans le moteur de vérification biométrique pour qu'il puisse être comparé avec le gabarit biométrique original.[2]

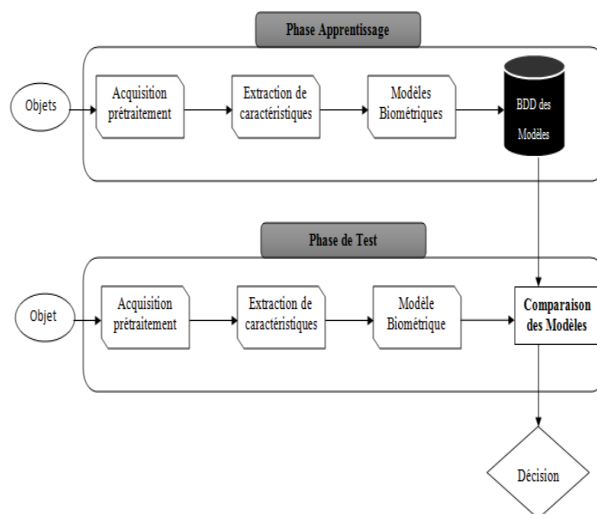


Figure 1.2 – Architecture d'un système biométrique

## 2 Principaux Modalités Biométriques

Il existe plusieurs modalités biométriques utilisées dans divers secteurs, on peut distinguer trois catégories

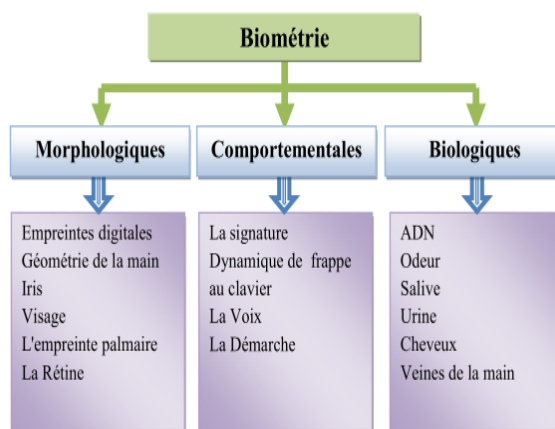


Figure 1.3 – Classification d'un certain nombre de modalités biométriques [8]

## 2.1 Modalités morphologiques (physiologiques)

Elles sont basées sur l'identification des traits physiques particuliers pour chaque personne. On cite :

### L'empreinte digitale

L'identification à l'aide des empreintes digitales est l'une des premières techniques biométriques qui se base sur le fait que chaque personne a des empreintes uniques. Les lecteurs d'empreintes digitales scannent puis relèvent[9] des éléments permettant de différencier les empreintes. Ces éléments sont appelés minuties .

Les minuties sont des changements de continuité de l'empreinte digitale. Il existe plusieurs types de minuties : lac, bifurcation, delta ou impasse...etc. Généralement une quarantaine sont extraites de la zone scannée. Statistiquement il est impossible de trouver douze points identiques chez deux individus.

Ce type de système est utilisé par les institutions financières pour leurs employés et leurs clients. Il se retrouve également dans les hôpitaux, les écoles, les aéroports, les cartes d'identité, les passeports, les permis de conduire et de nombreuses autres applications [10].



**Figure 1.4** – Images de l'empreinte digitale[10].

### La reconnaissance de visage

Le visage est certainement la caractéristique biométrique que les humains utilisent le plus naturellement pour s'identifier entre eux, ce qui peut expliquer pourquoi elle est en général très bien acceptée par les utilisateurs. Le système d'acquisition est soit un appareil photo, soit une caméra numérique.(Figure 1.5) La difficulté de la reconnaissance de visage varie énormément suivant que l'acquisition se fait dans un environnement contrôlé ou non. Dans un environnement contrôlé,des paramètres tels que l'arrière plan, la direction et l'intensité des sources lumineuses,l'angle de la prise de vue, la distance de la caméra au sujet sont des paramètres maîtrisés par le système. Dans un environnement non-contrôlé, une série de prétraitements sont souvent nécessaires avant de faire la reconnaissance à proprement parler. Il faut tout d'abord détecter la présence ou l'absence de visage dans l'image (face détection). Le visage doit ensuite être segmenté (face segmentation) [5].




**Figure 1.5** – Image visage[5].

## L'iris

L'iris est la partie colorée de l'œil qui entoure la pupille noire [10]. La reconnaissance par l'iris est très utilisée dans les applications d'identification et de vérification suite à stabilité de sa forme, plus distinctive, et unique. Elle est extrêmement fiable mais les équipements d'acquisition sont coûteux(Figure 1.6).

L'acquisition de l'iris est effectuée au moyen d'une caméra pour pallier aux mouvements inévitables de la pupille. Elle est très sensible (précision, reflet...) et relativement désagréable pour l'utilisation car l'œil doit rester grand ouvert et il est éclairé par une source lumineuse par assurer un contraste correct [11].




**Figure 1.6** – Image Iris[11].

## La Rétine

Cette mesure biométrique est plus ancienne que celle utilisant l'iris. Elle se base sur le fait que le schéma et le dessin formés par les vaisseaux sanguins de la rétine sont uniques pour chaque personne différents entre jumeaux et assez stables tout au long de la vie. C'est une mesure très fiable. Très difficile à falsifier. Mais elle est très peu utilisée.

Mal acceptée par le public et les utilisateurs. Cette méthode requiert une collaboration étroite de la part du sujet car il doit placer son œil près de la caméra (quelques centimètres). Elle est utilisée essentiellement dans des environnements de haute sécurité comme l'accès aux sites nucléaires militaires.[07]



**Figure 1.7** – Image de la rétine

### Géométrie de la main

Cette méthode consiste à déterminer les caractéristiques de la main d'un individu :

sa forme, la longueur, la largeur, la courbure des doigts, . . . etc. Les systèmes de reconnaissance de la géométrie de la main sont simples d'usage. L'utilisateur doit poser la paume de sa main sur une plaque qui possède des guides afin de l'aider à positionner ses doigts.

La géométrie de la main a un faible pouvoir discriminant et les systèmes peuvent être facilement trompés par de vrais jumeaux ou même par des personnes de la même famille. Il existe une alternative à la géométrie de la main : la géométrie des doigts qui s'appuie sur la forme du majeur et de l'index [5].



Figure 1.8 – Image Géométrie de main[5].

## 2.2 Modalités biologiques

Elle est basée sur l'identification de traits biologique particuliers.

### L'ADN

L'ADN est un liquide biologique est analysé à travers des méthodes simples telles que l'analyse du groupe sanguin, de différentes protéines ou enzymes. La plupart de ces analyses furent vite abandonnées en faveurs du profilage ADN, appelé aussi empreinte génétique, vu sa haute discrimination et robustesse.

L'analyse la plus commune de l'ADN est basée sur les séquences répétées en tandem courtes, appelées aussi microsatellites ou STR (Short Tandem Repeats) qui ne font pas partie des portions codant des protéines et qui présentent des caractères distinctifs. L'ADN présente une percée majeure dans la criminalistique pour l'identification des personnes inconnues ou pour déterminer la source des échantillons biologiques laissées dans les lieux de crime [12] .



Figure 1.9 – Image d'ADN[X].

### Veines de la main

On a longtemps considéré que le modèle des veines dans l'anatomie humaine peut être unique aux individus. En conséquence, il y a eu de diverses réalisations du balayage de veine au cours des années, du balayage de main, au balayage de poignet et, plus récemment, au balayage de doigt.

Cette technique utilise un «scanner du réseau veineux palmaire», pour être identifié il faut placer la surface concernée au-dessus du lecteur. Il s'agit ici d'analyser le dessin formé par le réseau des veines pour en garder quelques points caractéristiques [13].



**Figure 1.10** – Image de système configuration des veines[13]

### 2.3 Modalités comportementale

Elle est basée sur l'analyse de certains comportements d'une personne.

#### La voix (Reconnaissance vocale)

La voix humaine est trait unique de chaque individu. Elle est classée comme caractéristique biométrique comportementale. En effet, une grande partie de cette caractéristique est déterminée par le conduit vocal ainsi que les cavités buccales. La voix n'est pas un attribut permanent. Elle change bien entendu avec l'âge mais peut être aussi affectée temporairement par l'état de santé ou émotionnel du locuteur. [10]

Cette biométrie est en général très bien acceptée car la voix est un signal naturel à produire. De nos jours, tous les ordinateurs sont équipés en standard d'un microphone ce qui explique la popularité de la reconnaissance du locuteur pour les applications de type «desktop» . [3]



**Figure 1.11** – Image de la Reconnaissance vocale[3].



### Dynamique de la frappe au clavier

La dynamique de la frappe au clavier est une caractéristique propre de l'individu, c'est la transposition de la graphologie aux moyens électronique. C'est une méthode basée sur la façon d'utiliser ou de taper sur un clavier. Les paramètres pris en compte sont généralement les durées entre frappes.

La fréquence des erreurs et la durée de la frappe. En revanche elle dépend de l'état physique et psychique de la personne (âge, maladie....) qui feront varier la qualité de la frappe [3]




Figure 1.12 – Image de la frappe au clavier[3].

### La démarche

Il s'agit de reconnaître un individu par sa façon de marcher et de bouger (vitesse, accélération, mouvements du corps...), en analysant des séquences d'images. La démarche serait en effet étroitement associée à la musculature naturelle et donc très personnelle. Mais des vêtements amples, par exemple, peuvent compromettre une bonne identification[2].




Figure 1.13 – Images sur la démarche[2].

### La Signature

L'identification par la signature est une méthode automatique de mesure des signatures des personnes. Cette technique est considérée parmi les premières utilisées dans le domaine de la biométrie. Elle se base généralement sur le fait que l'utilisateur signe avec un stylo électronique sur une palette graphique et au même temps elle examine l'ensemble de dynamique comme la vitesse, la direction, et la pression de l'écriture, le temps pendant lequel le stylo est en contact avec le papier, le temps pris pour faire la signature et les positions où le stylo est relevé et abaissé sur le papier [5].

Ces données sont enregistrées pour comparaison ultérieure. Certains systèmes ne font qu'enregistrer l'image statique de la signature pour comparaison [14].



**Figure 1.14** – Image signature[14].

## 2.4 Représentation comparative entre quelques Techniques Biométriques

Il existe plusieurs techniques biométriques qui sont utilisées dans diverses applications. Chaque technique biométrique a ses forces et faiblesses, alors le choix dépend de l'application. Aucune technique biométrique ne répond efficacement aux exigences de toutes les applications. Institut de la Francophonie pour l'Informatique, Hanoï, Vietnam, 07 – 2005. En d'autres termes, aucune technique biométrique n'est optimale.

La correspondance entre une technique biométrique et une application dépend du mode opérationnel de l'application et des propriétés de la caractéristique biométrique [15].

Les traits biométriques	Universalité	Distinctif	Permanence	Mesurabilité	Acceptabilité
Empreinte digitale	Moyenne	Haute	Haute	Moyenne	Moyenne
Visage	Haute	Faible	Moyenne	Haute	Haute
Iris	Haute	Haute	Haute	Moyenne	Faible
Rétine	Haute	Haute	Moyenne	Faible	Faible
ADN	Haute	Haute	Haute	Faible	Faible
Signature	Faible	Faible	Faible	Haute	Haute
Voix	Moyenne	Faible	Faible	Moyenne	Haute
Démarche	Moyenne	Faible	Faible	Haute	Haute
Frappe Clavier	Faible	Faible	Faible	Moyenne	Moyenne
Géométrie de la main	Moyenne	Moyenne	Moyenne	Haute	Haute
Veines Main	Moyenne	Moyenne	Moyenne	Moyenne	Moyenne

**Table 1.1** – Comparaison entre les traits biométriques [14]

## 3 Les systèmes de vérification de la signature

En général un système biométrique est un système automatique de mesure basé sur la reconnaissance de caractéristiques propres à un individu : physique ou comportementale. Il est basé sur l'analyse de données liées à l'individu qui peuvent être classées en trois grandes catégories : analyse basée sur la morphologie, analyse de traces biologiques, l'analyse comportementale[16].

La tâche principale de tout système de vérification de signature est de déterminer si la signature est authentique ou falsifiée.

### 3.1 Signature Authentique

On sait que les signatures d'une même personne ne sont jamais les mêmes, qu'elles diffèrent à la fois globalement, localement et qu'elles peuvent également différer en taille et en orientation.

Les circonstances dans lesquelles la signature a été écrite ont également un impact comme: la taille de l'espace de signature, les signatures négligentes, les stylos différents, l'état physique et psychologique de la personne, la surface. En outre, la signature d'une personne change souvent au fil du temps, mais ces modifications sont mineurs et peuvent être résolues en mettant à jour les signatures de cette personne dans la base de données.

### 3.2 Signature Falsifiée

Le processus de falsification d'une signature, si l'on veut qu'elle réussisse, implique un double processus exigeant du faussaire non seulement qu'il copie les caractéristiques de l'écriture imitée, mais qu'il masque également les caractéristiques personnelles de l'auteur. En fait, c'est le surmenage de la signature qui en fait surtout de la contrefaçon.

Certains experts en matière de signature notent que si deux signatures d'une même personne écrites sur papier étaient identiques, elles pourraient être considérées comme de la falsification par traçage, et bien sûr il y a les faux qualifiés qui peuvent tromper le système.[17]

### 3.3 Modes de fonctionnement

Tout système biométrique peut fonctionner en mode d'enrôlement ou en mode de vérification ou bien en mode d'identification:

### **Le Mode d'enrôlement**

C'est une phase d'apprentissage qui a pour but de recueillir des informations biométriques sur les personnes à identifier. Plusieurs campagnes d'acquisitions de données peuvent être réalisées afin d'assurer une certaine robustesse au système de reconnaissance aux variations temporelles des données. Dans cette phase, les caractéristiques biométriques des individus sont saisies par un capteur biométrique, puis représentées sous forme numérique (signatures), et enfin stockées dans la base de données [18].

### **Le Mode de vérification**

C'est la comparaison 1-à-1, entre les données biométriques capturées (model test) et les donnée stockée dans sa propre base (les modèles d'apprentissage). Dans un tel système, un individu qui désire être identifié réclame une identité, habituellement par l'intermédiaire d'un PIN (numéro d'identification personnelle), d'un nom d'utilisateur, d'une carte d'identité, etc. Le système doit alors répondre à la question suivante "Suis-je réellement la personne que suis-je entrain de proclamer?" [18].

### **Le mode d'identification**

Le système identifie un individu en cherchant les signatures (Template) de tous les utilisateurs dans la base de données. Par conséquent, le système conduit plusieurs comparaisons 1-à-N pour établir l'identité d'un individu [19]. En résumé, un système biométrique opérant en mode identification répond à la question "Suis-je bien connu du système?".

## **3.4 La vérification de la signature En ligne(Online)**

La vérification de la signature est l'opération de l'authentification d'une personne en se basant sur sa signature. Etant donné un utilisateur  $U$  et une signature  $S$ , le système de vérification doit déterminer si la signature  $S$  est produite par l'utilisateur  $U$ . Si la réponse est oui, l'utilisateur est accepté comme client du système ; sinon, il est considéré comme imposteur (intrus).

Dans un système de vérification de signatures en ligne, les utilisateurs sont d'abord introduits dans le système par l'enregistrement de quelques échantillons de leurs signatures qui servent de références. Plus tard, quand un utilisateur, qui prétend être un client particulier du système, présente sa signature pour la vérification, elle est comparée avec les signatures de référence de l'individu proclamé. A l'issue de cette comparaison un score mesurant la similarité (ou la dissimilarité) entre les deux signatures est fourni. Si le score de similarité est supérieur (score de dissimilarité inférieur, respectivement) à un seuil, fixé à l'étape d'entraînement du système, l'utilisateur est accepté ; sinon il est rejeté.

Dans le cas d'un système en ligne, la signature est effectuée sur une tablette graphique ou tout autre

support muni d'un stylet électronique. La signature est donc représentée par une suite de points définis par au moins 3 valeurs :  $x$ ,  $y$ ,  $t$ . Nous avons remarqué, lors de nos expérimentations, que les dispositifs actuels d'acquisition de l'écriture manuscrite en ligne sont loin d'offrir une ergonomie suffisante pour que les usagers les utilisent sans stress. En effet, la gêne occasionnée entraîne des efforts supplémentaires. Beaucoup de personnes adaptent ou modifient leur manière d'écrire et de signer lors du passage sur un support numérique. Cela est critique lorsqu'il s'agit de signer car on ne signe pas de la même manière sur papier ou avec un stylet et un temps d'adaptation au support numérique est donc nécessaire avant d'obtenir une stabilité suffisante de la signature[20][21].


### 3.5 La vérification de la signature Hors ligne(Offline)

Dans un système hors ligne, la signature est effectuée sur un support papier puis scannée. La signature est donc assimilée à une image en niveaux de gris. C'est le cas notamment pour les systèmes de vérification de chèques. En hors ligne, on ne dispose pas de la dynamique de façon directe mais d'autres informations sont disponibles comme l'épaisseur du trait ou la variation d'intensité du niveau de gris constituant la signature. Au contraire, lors d'une acquisition en ligne, le trait n'a pas d'épaisseur et est représenté avec la même intensité sur les systèmes ne permettant pas l'acquisition de la pression. Hormis pour l'étude de la forme, les techniques appliquées en hors-ligne ne peuvent donc pas, en général, être adaptées aux techniques en ligne puisqu'elles sont basées la plupart du temps sur l'étude des niveaux de gris de l'image. Les problèmes liés à l'acquisition sont différents dans le cadre du en ligne et dans celui du hors ligne. En effet, en hors ligne, le papier utilisé pour signer peut être de différentes textures, le stylo a aussi une grande influence et enfin l'acquisition via le scanner peut donner des résultats différents suivant la résolution choisie. C'est aussi le cas pour les systèmes d'acquisition en ligne pour lesquels la résolution ou la fréquence d'acquisition ne sont pas fixées[20][21].

### 3.6 Type de falsification

Les contrefaçons impliquées dans les signatures manuscrites ont été classées en fonction de leurs caractéristiques. Les contrefaçons dans les signatures peuvent être classées dans les types suivants:

- \* Falsification aléatoire : Le signataire utilise le nom de la victime dans son propre style pour créer une falsification connue sous le nom de falsification simple ou falsification aléatoire.
- \* Falsification non qualifiée (simple) : Le signataire imite la signature dans son propre style, sans aucune connaissance de l'orthographe ni expérience préalable.
- \* Falsification qualifiée : des imposteurs professionnels ou des personnes expérimentées dans la copie de la signature constituent sans aucun doute la falsification la plus difficile.

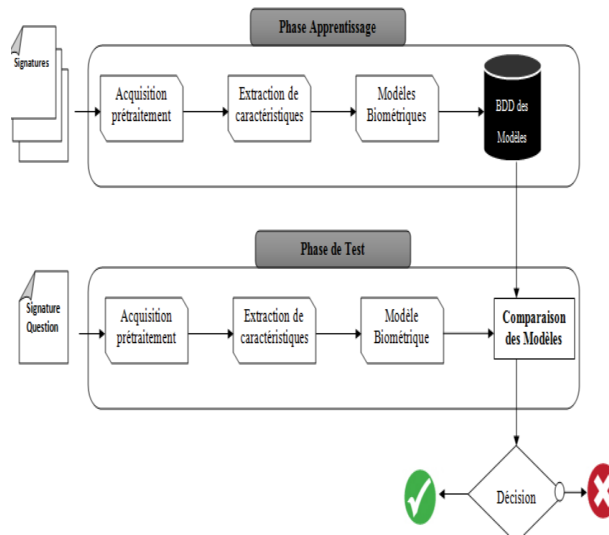


**Figure 1.15** – Les différents types de falsification a) Signature authentique b) Falsification aléatoire c) Falsification non qualifiée (simple) d) Falsification qualifiée

## 4 Processus d'un système de la vérification de signature

Un système de la classification de la vérification de signature fait appel généralement aux étapes suivantes : acquisition, prétraitement, segmentation, extraction des caractéristiques, sélection des caractéristiques et leur classification.

Le schéma suivant explique ce processus: (Figure 1.16)



**Figure 1.16** – Processus d'un système de la vérification de signature

### 4.1 L'acquisition des données

Selon la méthode d'acquisition de signature utilisée, les systèmes de vérification de signature peuvent être classés en deux groupes:

- \* Signature hors ligne (statique).
- \* Signature en ligne (dynamique).

Dans la vérification de la signature hors ligne (statique), seules les formes géométriques de la signature est utilisée pour authentifier une personne (Figure 1.17). Dans cette approche, l'extraction de données dynamiques n'est pas si facile, par ce que l'entrée dans ce système sera une image 2D de la signature et les informations dynamiques ne seront pas disponibles.[17]



**Figure 1.17** – Signature hors ligne (statique)[17].

Pour la deuxième approche (Signature en ligne (dynamique)) de la vérification des signatures, elle utilise, en plus de la forme géométrique(Figure1.18), les caractéristiques dynamiques telles que les profils d'accélération, de vitesse et de trajectoire de la signature. La signature évolue avec le temps et est influencée par les conditions physiques et émotionnelles de la personne.



**Figure 1.18** – Signature en ligne (dynamique)[17].

Les deux types de variation trouvés dans les signatures sont: la variabilité interpersonnelle et la variabilité intrapersonnelle. La variation entre les signatures d'une même personne s'appelle Variation intrapersonnelle.


Cette variation peut être due à:

- \* Âge.
- \* La maladie.
- \* Les blessures.
- \* Les contraintes de temps.
- \* Drogues.
- \* Température.

La variation entre les originaux et les contrefaçons s'appelle interpersonnel.

## 4.2 Prétraitement de l'image

La reconnaissance de signature hors ligne nécessite l'application de plusieurs étapes de prétraitement sur les ensembles d'apprentissage et de test afin de la préparer au processus d'extraction de caractéristiques. En du prétraitement, l'image de la signature passe: numérisation en gris (ou conversion en échelle de gris), puis élimination du bruit de fond, réduction du bruit, normalisation de la taille et dilution. (Figure 1.19)



**Figure 1.19** – Prétraitement de la signature (a) signature scannée, (b) après binarisation, (c) après réduction du bruit, (d) après normalisation de la taille, (e) après dilution

### La binarisation

La binarisation qu'il signifie convertit une image jusqu'à 256 niveaux de gris en une image en noir et blanc. (Figure 1.20)



**Figure 1.20** – Image binarisée

### Le lissage (Filtrage)


Le filtrage est une technique pour modifier ou améliorer une image. Par exemple, vous pouvez filtrer une image pour mettre en valeur certaines caractéristiques ou en supprimer d'autres. Les opérations de traitement d'image mises en œuvre avec filtrage comprennent le lissage, l'accentuation et l'amélioration des contours. (Figure 1.21)

## 4.3 Amélioration d'image

L'amélioration de l'image est un domaine le plus simple et le plus attrayant du traitement des images numériques. (Figure 1.22)

L'idée sous-jacente aux techniques d'amélioration consiste à faire ressortir les détails obscurcis ou





**Figure 1.21** – Exemple de lissage [8]




**Figure 1.22** – Amélioration d'image

simplement à mettre en évidence certaines caractéristiques de l'image. Comme la luminosité changeante, etc.

#### 4.4 Ségmentation

Les procédures de segmentation divisent une image en ses parties ou objets constitutifs. En général, la segmentation autonome est l'une des tâches les plus difficiles du traitement numérique des images. (Figure 1.23)

Une procédure de segmentation robuste apporte une solution efficace aux problèmes d'imagerie qui nécessitent l'identification individuelle des objets. [17]



**Figure 1.23** – Ségmentation d'image[17].

#### 4.5 Extraction de caractéristiques

Dans cette section, nous décrivons les caractéristiques des méthodes d'extraction utilisées dans la vérification de signature. L'étape d'extraction des caractéristiques réduit la dimension des images de signature originales tout en préservant et en extrayant les informations importantes encodées dans l'image.

Un ensemble de caractéristiques soigneusement sélectionnées transformera les images pour qu'il soit plus facile de distinguer les classes authentiques des classes falsifiées.

### Caractéristiques globales

Les caractéristiques globales décrivent l'ensemble de l'image de signature, telles que la largeur, la hauteur et le rapport hauteur/largeur. Ces caractéristiques sont utilisées en combinaison avec d'autres caractéristiques. Ces caractéristiques sont moins sensibles au bruit et peuvent être obtenues en considérant tous les points à l'intérieur d'une région, ou par les points à la limite d'une région (zone de signature). Il inclut les caractéristiques des régions dans les images, les moments, les descripteurs de Fourier, le périmètre.

### Caractéristiques locales

Les caractéristiques locales font référence à un motif ou à une structure distincte que l'on trouve dans une image, comme un point, un bord ou un petit patch d'image. Ils sont généralement associés à une tache d'image qui diffère de son environnement immédiat par sa texture, sa couleur ou son intensité. Ce que l'élément représente réellement n'a pas d'importance, juste qu'il est distinct de son environnement.

Donc, une caractéristique globale signifie que vous regardez toute l'image, alors que caractéristique locale signifie que vous vous concentrez sur quelque chose.

## 4.6 Classification

Après la segmentation et l'extraction de caractéristiques, une étape de reconnaissance basée sur la classification des caractéristiques.

Les techniques de la classification reposent sur une stratégie de décision qui permet de catégoriser un objet le mieux possible selon certains critères d'optimisation.

Le type d'une méthode de classification se décline généralement en trois familles : Le mode supervisé, le mode non supervisé et le mode semi supervisé.

- \* Classification supervisée : cette technique est basée sur l'étiquetage des observations en affectant chaque observation à une classe (supervisés où la sortie correcte doit être fournie à l'avance).
- \* Classification non supervisée : aucune des observations n'est étiquetée (non supervisés où la sortie correcte n'est pas exigée à l'avance, elle résulte après une étape d'apprentissage).
- \* Classification semi supervisée : cette technique est basée sur l'étiquetage d'une partie des observations.[17]

## 5 Présentation de certaines techniques de la classification

### 5.1 K plus proches voisin(KNN)

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation  $x$ , l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de  $x$  est déterminée en fonction de la classe majoritaire parmi les  $k$  plus proches voisins de l'observation  $x$ .

Donc la méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche, au regard des covariables utilisées. La détermination de leur similarité est basée sur des mesures de distance. [22]

### 5.2 Fuzzy c-means

Fuzzy C-Means (FCM) est un algorithme de classification non-supervisée floue. Issu de l'algorithme des C-moyennes (C-means), il introduit la notion d'ensemble flou dans la définition des classes : chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré, et tous les clusters sont caractérisés par leur centre de gravité.

Comme les autres algorithmes de classification non supervisée, il utilise un critère de minimisation des distances intra-classe et de maximisation des distances interclasse, mais en donnant un certain degré d'appartenance à chaque classe pour chaque pixel. Cet algorithme nécessite la connaissance préalable du nombre de clusters et génère les classes par un processus itératif en minimisant une fonction objective.

Ainsi, il permet d'obtenir une partition floue de l'image en donnant à chaque pixel un degré d'appartenance (compris entre 0 et 1) à une classe donnée. Le cluster auquel est associé un pixel est celui dont le degré d'appartenance sera le plus élevé.

Les principales étapes de l'algorithme Fuzzy C-means sont :

1. La fixation arbitraire d'une matrice d'appartenance.
2. Le calcul des centroïdes des classes .
3. Le réajustement de la matrice d'appartenance suivant la position des centroïdes.
4. Calcul du critère de minimisation et retour à l'étape 2 s'il y a non convergence de critère.[22]

### 5.3 k-means

L'algorithme k-means est l'algorithme de regroupement le plus connu et le plus utilisé, du fait de sa simplicité de mise en œuvre. Il partitionne les données d'une image en K clusters. Contrairement à d'autres méthodes dites hiérarchiques, qui créent une structure en « arbre de clusters » pour décrire les groupements, k-means ne crée qu'un seul niveau de clusters.

L'algorithme renvoie une partition des données, dans laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters. Chaque cluster de la partition est défini par ses objets et son centroïde. Le k-means est un algorithme itératif qui minimise la somme des distances entre chaque objet et le centroïde de son cluster.

La position initiale des centroïdes conditionne le résultat final, de sorte que les centroïdes doivent être initialement placés le plus loin possible les uns des autres de façon à optimiser l'algorithme. K-means change les objets de cluster jusqu'à ce que la somme ne puisse plus diminuer. Le résultat est un ensemble de clusters compacts et clairement séparés, sous réserve qu'on ait choisi la bonne valeur K du nombre de clusters. Les principales étapes de l'algorithme k-means sont :

1. CChoix aléatoire de la position initiale des K clusters.
2. Ré-Affecter les objets à un cluster suivant un critère de minimisation des distances(généralement selon une mesure de distance euclidienne).
3. Une fois tous les objets placés, recalculer les K centroïdes.
4. Répéter les étapes 2 et 3 jusqu'à ce que plus aucune réaffectation ne soit faite. [22]

### 5.4 Machine à vecteurs de support(SVM)


Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification. les SVM sont une généralisation des classifiées linéaires. [17] les SVM ont été développés dans les années 1990 à partir des considérations théoriques de Vladimir Vapnik sur le développement d'une théorie statistique de l'apprentissage :

la Théorie de Vapnik- Chervonenkis. Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper paramètres, leurs garanties théoriques, et leurs bons résultats en pratique.

Les SVM ont été appliqués à de très nombreux domaines (bio-informatique, recherche d'information, vision par ordinateur, finance...). Selon les données, la performance des machines à vecteurs de support est de même ordre, ou même supérieure, à celle d'un réseau de neurones ou d'un modèle de mixture gaussienne[22].

Hyperplan qui est le lieu des points  $x$  satisfaisant  $\langle w, x \rangle + b = 0$ . En orientant l'hyperplan, la règle de décision correspond à observer de quel côté de l'hyperplan se trouve l'exemple  $x$ . On voit que le vecteur  $w$  définit la pente de l'hyperplan ( $w$  est perpendiculaire à l'hyperplan). Le terme  $b$  quant à lui permet de translater l'hyperplan parallèlement à lui-même. ; Décision  $h(s)$ . La classe de tous les hyperplans qui en découle sera notée  $H$ .

## 5.5 Les Réseaux de Neurones



**Figure 1.24** – Structure d'un réseau de neurone biologique et le cerveau humain.[23]

Le terme de réseau de Neurone peut prendre des significations différentes [24]

- \* Réseaux artificiels.
- \* Neurosciences calculatoires.
- \* Modélisation neuronale.

Les réseaux de Neurones est une dénomination assez floue qui recouvre un ensemble de mécanismes de calcul inspirée initialement par des modèles issus du fonctionnement des systèmes nerveux que des techniciens y voient une source d'inspiration pour la construction des systèmes automatiques [25]. Un grand effort a été consacré au développement des réseaux neurones qui présentent une Alternative aux architectures classiques. Ceci est dû à leurs structures parallèles, à leurs Performances de classification et à leurs aptitudes de comprendre des phénomènes non linéaires.

Principalement un réseau de Neurone ne fonctionne qu'après avoir appris suffisamment de connaissances sur les sorties désirées à partir d'entrées données ; le développement de ces réseaux concerne essentiellement l'apprentissage et les lois de modification des poids de connexion. [24].

## 6 Conclusion

Dans ce chapitre, nous avons présenté quelques notions et définitions de base liées à la biométrie. On a présenté aussi quelques algorithmes ou méthodes de classification (K-plus proche voisin, k-means, Machine à Vecteur Support). Le prochain chapitre, nous allons voir type de l'apprentissage profond (Deep learning) et les réseaux de neurones Convolutif (CNN).

## Chapter 2


# Les réseaux de neurones convolutionnels

L'intelligence artificielle (IA) est un ensemble de techniques permettant à des machines d'accomplir des tâches et de résoudre des problèmes normalement réservés aux humains et à certains animaux.[26]

L'IA s'appuie sur des algorithmes en mesure d'ajuster leurs calculs en fonction des traitements qu'ils ont à effectuer. Ces réseaux de neurones artificiels, constitués de serveurs puissants, permettent de traiter de nombreuses sources d'informations issues de gigantesques bases de données en effectuant de lourds calculs.[27]

Par conséquent, L'apprentissage profond (Deep Learning) est un sous-domaine de l'apprentissage automatique. Conceptuellement, le fonctionnement de l'apprentissage profond se traduit par plusieurs couches de calques auxquels des données sont échangés pour générer un ou plusieurs rendu(s). [28]

Dans ce chapitre nous allons présenter les notions en relation avec l'apprentissage profond.



**Figure 2.1** – La relation entre l'intelligence artificielle, le ML et le deep learning

## 1 Apprentissage automatique (Machine learning)

Le machine learning ou « apprentissage automatique » en français est un concept qui fait de plus en plus parler de lui dans le monde de l'informatique, et qui se rapporte au domaine de l'intelligence artificielle. Encore appelé « apprentissage statistique », ce terme renvoie à un processus de développement, d'analyse et d'implémentation conduisant à la mise en place de procédés systématiques. Pour faire simple, 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. L'objectif visé est de rendre la machine ou l'ordinateur capable d'apporter des solutions à des problèmes compliqués, par le traitement d'une quantité astronomique d'informations. Cela offre ainsi une possibilité d'analyser et de mettre en évidence les corrélations qui existent entre deux ou plusieurs situations données, et de prédire leurs différentes implications.[29]



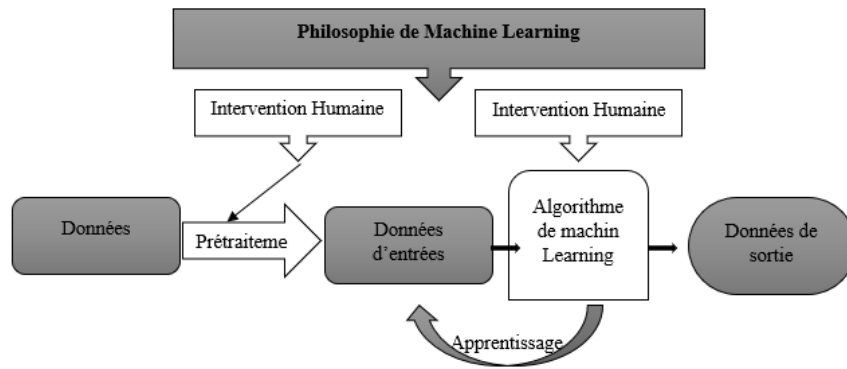


Figure 2.2 – philosophie du Machine learning

## 1.1 Les Différents Procédés d'Apprentissage

Le machine learning implique deux principaux systèmes d'apprentissage qui définissent ses différents modes de fonctionnement. Il s'agit de :

### L'apprentissage supervisé ou analyse discriminatoire

Ici, la machine s'appuie sur des classes prédéterminées et sur un certain nombre de paradigmes connus pour mettre en place un système de classement à partir de modèles déjà catalogués. Dans ce cas, deux étapes sont nécessaires pour compléter le processus, à commencer par le stade d'apprentissage qui consiste à la modélisation des données cataloguées. Ensuite, il s'agira au second stade de se baser sur les données ainsi définies pour attribuer des classes aux nouveaux modèles introduits dans le système, afin de les cataloguer eux aussi.[29]

### L'apprentissage non-supervisé ou clustering

Dans ce mode de fonctionnement du machine learning, il n'est pas question de s'appuyer sur des éléments prédéfinis, et la tâche revient à la machine de procéder toute seule à la catégorisation des données. Pour ce faire, le système va croiser les informations qui lui sont soumises, de manière à pouvoir rassembler dans une même classe les éléments présentant certaines similitudes. Ainsi, en fonction du but recherché, il reviendra à l'opérateur ou au chercheur de les analyser afin d'en déduire les différentes hypothèses.[29]

## 1.2 La différence entre l'apprentissage supervisé et non-supervisé

La différence entre ces deux principes de fonctionnement réside dans le fait que l'apprentissage supervisé peut être influencé par des à priori au moment de l'étiquetage des données. Ce n'est pas le cas de

l'apprentissage non-supervisé, qui se révèle ainsi beaucoup plus fiable dans la mesure où les réponses obtenues vont plus loin que la compréhension humaine des faits. Par ailleurs, il faut noter que le machine learning peut également faire intervenir un mode de fonctionnement mixte qui utilise les deux types d'apprentissage pour arriver à des résultats plus précis.[29]

## 2 réseaux de neurones artificielles (ANNs)


C'est une structure constituée de suite successive de couches de nœuds et qui permet de définir une fonction de transformation non linéaire des vecteurs d'entrées (composés dans le cas de classification des mots pondérés de leur poids) en vecteur de catégories. La disposition des neurones dans le réseau ainsi que le nombre de couches utilisées ont une influence sur le résultat de classification. Comparés aux autres méthodes de classification par apprentissage supervisé, les réseaux de neurones ont l'inconvénient que le coût d'apprentissage est assez élevé [30].

### 2.1 Neurone Formel

Un neurone formel est une représentation mathématique et informatique d'un neurone biologique. Le neurone formel possède généralement plusieurs entrées et une sortie qui correspondent respectivement aux dendrites et au cône d'émergence du neurone biologique (point de départ de l'axone). Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage. Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone. Le neurone formel est l'unité élémentaire des réseaux de neurones artificiels dans lesquels il est associé à ses semblables pour calculer des fonctions arbitrairement complexes, utilisées pour diverses applications en intelligence artificielle.[31]

### 2.2 Neurones multicouche

Dans le modèle du Perceptron Multicouches, les perceptrons sont organisés en couches. Les perceptrons multicouches sont capables de traiter des données qui ne sont pas linéairement séparables. Avec l'arrivée des algorithmes de rétro propagation, ils deviennent le type de réseaux de neurones le plus utilisé. Les MLP sont généralement organisés en trois couches, la couche d'entrée, la couche intermédiaire (dite couche cachée) et la couche de sortie. L'utilité de plusieurs couches cachées n'a pas été démontrée. La figure 2.4 illustre la structure d'un MLP présentant quatre neurones en entrée, trois neurones sur la couche cachée et deux en sortie. Lorsque tous les neurones d'une couche sont connectés aux neurones de la couche suivante,



**Figure 2.3** – schéma d'un perceptron multicouche[32].

on parle alors de couches complètement connectées. [32]

## 2.3 Types de réseaux de neurones artificielles (ANNs)

### Réseaux de Hopfield

Le réseau de neurones d'Hopfield est un modèle de réseau de neurones récurrents à temps discret dont la matrice des connexions est symétrique et nulle sur la diagonale et où la dynamique est asynchrone (un seul neurone est mis à jour à chaque unité de temps). Il a été découvert par le physicien John Hopfield en 1982. Sa découverte a permis de relancer l'intérêt dans les réseaux de neurones qui s'était essouffé durant les années 1970 à la suite d'un article de Marvin Minsky et Seymour Papert.

Un réseau de Hopfield est une mémoire adressable par son contenu : une forme mémorisée est retrouvée par une stabilisation du réseau, s'il a été stimulé par une partie adéquate de cette forme.[23]

### Modèle de Kohonen

Ce modèle a été présenté par T. Kohonen en 1982 en se basant sur des constatations biologiques. Il a pour objectif de présenter des données complexes et appartenant généralement à un espace discret de grandes dimensions dont la topologie est limitée à une ou deux dimensions. Les cartes de Kohonen sont réalisées à partir d'un réseau à deux couches, une en entrée et une en sortie. Notons que les neurones de la couche d'entrée sont entièrement connectés à la couche de sortie .

Les neurones de la couche de sortie sont placés dans un espace d'une ou de deux dimensions en général, chaque neurone possède donc des voisins dans cet espace. Et qu'enfin, chaque neurone de la couche de sortie possède des connexions latérales récurrentes dans sa couche (le neurone inhibe, les neurones éloignés et laisse agir les neurones voisins).[23]




Figure 2.4 – Le modèle de Kohonen[23].

### Le modèle de Perceptron

Le mécanisme perceptron fut inventé par le psychologue F. Rosenblat à la fin des années 50. Il représentait sa tentative d'illustrer certaines propriétés fondamentales des systèmes intelligents en générale.

Le réseau dans ce modèle est formé de trois couches : Une couche d'entrée, fournissant des données à une couche intermédiaire, chargée des calculs, cela en fournissant la somme des impulsions qui lui viennent des cellules auxquelles elle est connectée, et elle répond généralement suivant une loi définie avec un seuil, elle-même connectée à la couche de sortie (couche de décision), représentant les exemples à mémoriser. Seule cette dernière couche renvoie des signaux à la couche intermédiaire, jusqu'à ce que leurs connexions se stabilisent (voir figure 8).[23]


### Réseaux Neurones Convolutionnels

En apprentissage automatique, un réseau de neurone convolutifs (ou réseau de neurones à convolution, ou CNN ou ConvNet) est un type de réseau de neurones artificiels acycliques dans lequel le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux. Les neurones de cette région du cerveau sont arrangés de sorte à ce qu'ils correspondent à des régions qui se chevauchent lors du pavage du champ visuel. Leur fonctionnement est inspiré par les processus biologiques, ils consistent en un empilage multicouche de perceptrons, dont le but est de prétraiter 3 de petites quantités d'informations. Les réseaux neuronaux convolutifs ont de larges applications dans la reconnaissance d'image et vidéo, les systèmes de recommandation et le traitement du langage naturel.[22]

### Le modèle ADALINE

L'ADALINE de Widrow et Hoff est un réseau à trois couches : une d'entrée, une couche cachée et une couche de sortie. Ce modèle est similaire au modèle de perceptron, seule la fonction de transfert change, mais reste toujours linéaire. Les modèles des neurones utilisés dans le perceptron et l'ADALINE sont des modèles linéaires. Séparation linéaire : on dit que deux classes A et B, sont linéairement séparables si


on arrive à les séparer par une droite coupant le plan en deux . Le problème est résolu avec les réseaux multicouches, car il peut résoudre toute sorte de problèmes qu'ils soient linéairement séparables ou non.



**Figure 2.5** – La séparation linéaire entre la classe A et B[22].

### Réseaux de Neurones Récurrents(RNR)

Un réseau de neurones récurrents (Recurrent neural networks ou RNN) permettent d'analyser les séquences de vecteurs tout comme les modèles de Markov cachés .Le temps entre ici en ligne de compte car les sorties (de la coche de sortie et/ou de la coche cachées) calculées à l'instant t sont ré-injectées en entrée du réseau et/ou en entrée de la couche cachée. On peut en théorie conserver dans le réseau la mémoire de ce qui s'y est passé depuis le début. [22]



**Figure 2.6** – Réseaux de neurones récurrents[22].

### Machine de Boltzmann Profonde (MBP)

Une machine de Boltzmann restreinte (Deep Belief Network ou DBN) est un type de réseau de neurones artificiels inventé par Geoff Hinton, pionnier de l'apprentissage automatique et de la conception de réseaux de neurones.

Ce type de réseau génératif est utile pour le filtrage, l'apprentissage des fonctionnalités et la classification. Il utilise certains types de réduction de dimensionnalité pour aider à traiter des entrées compliquées.[33]

## 3 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. Il concerne les algorithmes inspirés par la structure et le fonctionnement du cerveau. Ils peuvent apprendre plusieurs niveaux de représentation dans le but de modéliser des relations complexes entre les données.

Le Deep Learning est basé sur l'idée des réseaux de neurones artificielles et il est taillé pour gérer de larges quantités de données en ajoutant des couches au réseau. Un modèle de deep learning a la capacité d'extraire des caractéristiques à partir des données brutes grâce aux multiples couches de traitement composé de multiples transformations linéaires et non linéaires et apprendre sur ces caractéristiques petit à petit à travers chaque couche avec une intervention humaine minimale [33]

Sur les cinq dernières années, le deep learning est passé d'un marché de niche ou seulement une poignée de chercheurs s'y intéressait au domaine le plus prisé par les chercheurs. Les recherches en relation avec le deep learning apparaissent maintenant dans les top journaux comme Science, Nature et Nature Methods pour ne citer que quelques-uns. Le deep learning a coché le GO, appris à conduire une voiture [34], diagnostiquer le cancer et l'autisme et même devenu un artiste.

### 3.1 Domaines d'application de l'apprentissage profond

Ces techniques se développent dans le domaine de l'informatique appliquée aux NTIC (reconnaissance visuelle — par exemple d'un panneau de signalisation par un robot ou une voiture autonome — et vocale notamment) à la robotique, à la bio-informatique, la reconnaissance ou comparaison de formes, la sécurité, la santé, etc. . . , la pédagogie assistée par l'informatique, et plus généralement à l'intelligence artificielle. L'apprentissage profond peut par exemple permettre à un ordinateur de mieux reconnaître des objets hautement déformables et/ou analyser par exemple les émotions révélées par un visage photographié ou filmé, ou analyser les mouvements et position des doigts d'une main, ce qui peut être utile pour traduire le langage des signes, améliorer le positionnement automatique d'une caméra, etc. . . Elles sont utilisées pour certaines formes d'aide au diagnostic médical (ex. : reconnaissance automatique d'un cancer en imagerie médicale), ou de prospective ou prédiction (ex. : prédiction des propriétés d'un sol filmé par un robot).[22]

### 3.2 Quelques algorithmes de l'apprentissage profond

Il existe différents algorithmes de Deep Learning. Nous pouvons ainsi citer:

- \* Réseaux de neurones profonds (Deep Neural Networks): Ces réseaux sont similaires aux réseaux MLP mais avec plus de couches cachées. L'augmentation du nombre de couches, permet à un réseau de

neurones de détecter de légères variations du modèle d'apprentissage, favorisant le sur-apprentissage ou sur-ajustement (« overfitting »).

- \* Les réseaux de neurones convolutionnels (CNN ou Convolutional Neural Networks): Le problème est divisé en sous parties, et pour chaque partie, un «cluster» de neurones sera créer afin d'étudier cette portion spécifique. Par exemple, pour une image en couleur, il est possible de diviser l'image sur la largeur, la hauteur et la profondeur (les couleurs).
- \* La machine de Boltzmann profonde (Deep Belief Network): Ces algorithmes fonctionnent suivant une première phase non supervisée, suivi de l'entraînement classique supervisé. Cette étape d'apprentissage non-supervisée, permet, en outre, de faciliter l'apprentissage supervisé.[36]

### 3.3 la Différence entre Apprentissage profond et Apprentissage automatique

L'apprentissage en profondeur est un sous-type de l'apprentissage automatique. Avec l'apprentissage automatique, on extrait manuellement les fonctions pertinentes d'une image. Grâce à l'apprentissage en profondeur, on alimente les images brutes directement dans un réseau neuronal profond qui apprend les fonctionnalités automatiquement.

L'apprentissage en profondeur nécessite souvent des centaines de milliers ou des millions d'images pour les meilleurs résultats. Il est également très gourmand en calcul et nécessite un GPU hautes performances.

l'apprentissage automatique(machine learning)	l'apprentissage profond(Deep Learning)
++De bons résultats avec de petits ensembles de données	–nécessite de très grands ensembles de données
++rapide pour former un modèle	–intensément computationnel
–Besoin d'essayer différentes fonctionnalités et classificateurs pour obtenir les meilleurs résultats	++apprendre les fonctionnalités et les classificateurs automatiquement
–plateaux de précision	++la précision est illimitée

**Table 2.1** – La différence entre apprentissage profond et Apprentissage automatique[36]

## 4 Les réseaux de neurones convolutifs CNN

Convolutional Neural Network (CNN) (réseaux de neurones convolutifs) sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Les exemples comprennent des données de type série temporelle, qui peuvent être considérées comme une grille 1D en prenant des échantillons à des intervalles de temps réguliers et des données de type image, qui peuvent

être considérées comme une grille 2D de pixels. Les réseaux convolutifs ont connu un succès considérable dans les applications pratiques. Le nom « réseau de neurones convolutif » indique que le réseau emploie une opération mathématique appelée convolution. La convolution est une opération linéaire spéciale. Les réseaux convolutifs sont simplement des réseaux de neurones qui utilisent la convolution à la place de la multiplication matricielle dans au moins une de leurs couches.

Ils ont de larges applications dans la reconnaissance de l'image et de la vidéo, les systèmes de recommandations [37] et le traitement du langage naturel [38].

## 4.1 L'architecture de CNN

La structure de CNN consiste en un ensemble de couches:

- \* La couche de convolution (CONV): est première étape qui traite des données de champ du récepteur.
- \* A couche de pooling (POOL): est l'étape où vous compressez les informations en réduisant la taille de l'image intermédiaire.
- \* A couche correction (Rectified Linear Unit (ReLU)).
- \* La couche "entièrement connecté" (FC).
- \* La couche de perte (LOSS).




Figure 2.7 – L'architecture de CNN

### La Couche de Convolution (CONV)


La couche de convolution est le bloc de construction de base d'un CNN. Trois paramètres permettent de dimensionner le volume de la couche de convolution la profondeur, le pas et la marge.

1. Profondeur de la couche : nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).



2. Le pas: contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
3. La marge (à 0) ou zero padding : parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zero-padding' est le troisième hyper paramètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée.

Si le pas et la marge appliquée à l'image d'entrée permettent de contrôler le nombre de champs récepteurs à gérer (surface de traitement), la profondeur permet d'avoir une notion de volume de sortie, et de la même manière qu'une image peut avoir un volume, si on prend une profondeur de 3 pour les trois canaux RGB d'une image couleur, la couche de convolution va également présenter en sortie une profondeur. C'est pour cela que l'on parle plutôt de "volume de sortie" et de "volume d'entrée", car l'entrée d'une couche de convolution peut être soit une image soit la sortie d'une autre couche de convolution.[35]



**Figure 2.8** – Représentation de la fonctionnalité Convolution [22]

### La couche de Pooling (POOL)


Un autre outil très puissant utilisé par les CNNs s'appelle le Pooling, ce qui est une forme de sous-échantillonnage de l'image.

Le Pooling est une méthode permettant de prendre une large image et d'en réduire la taille tout en préservant les informations les plus importantes qu'elle contient. Le Pooling peut être de différents types : max, moyenne, somme, etc. En cas de Pooling max, on définit un voisinage spatial (par exemple, une fenêtre  $2 \times 2$ ) et de prendre le plus grand élément dans cette fenêtre. En pratique, le Pooling max a donné le meilleur résultat.[39]

### La couche de correction (Rectified Linear Unit (ReLU))

Une opération supplémentaire appelée ReLU a été utilisée après chaque opération de convolution.

Un ReLU applique la fonction  $y = \max(x, 0)$ , Cette fonction force les neurones à retourner des valeurs




**Figure 2.9** – Max Pooling avec un filtre  $2 \times 2$  et un pas de 2

positives telles-que les tailles d'entrée et de sortie de cette couche sont identiques. L'avantage d'un ReLU est que le réseau s'entraîne beaucoup plus rapidement.

### La couche entièrement connecté (Fully connected (FC))

La couche entièrement connectée utilisé après Après plusieurs couches de convolution, ReLU et de max-pooling. Les neurones dans une couche entièrement connectée ont des connexions vers toutes les sorties de la couche précédente.

Le but de la couche entièrement connectée est d'utiliser ces fonctions pour classer l'image d'entrée dans différentes classes en fonction de l'ensemble de données d'apprentissage.



**Figure 2.10** – Représentation de la fonctionnalité FC

### La couche de perte(LOSS)

La couche de perte spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et réel. Elle est normalement la dernière couche dans le réseau. Diverses fonctions de perte adaptées à différentes tâches peuvent y être utilisées. La fonction « Softmax » permet de calculer la distribution de probabilités sur les classes de sortie. [22]

## 4.2 Choix des paramètres

Les CNNs utilisent plus de paramètres qu'un MLP standard. Même si les règles habituelles pour les taux d'apprentissage et des constantes de régularisation s'appliquent toujours, il faut prendre en considération les notions de nombre de filtres, leur forme et la forme du max pooling.

### Nombre de filtres

Comme la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres tandis que les couches plus proches de la sortie peuvent en avoir davantage. Pour égaliser le calcul à chaque couche, le produit du nombre de caractéristiques et le nombre de pixels traités est généralement choisi pour être à peu près constant à travers les couches. Pour préserver l'information en entrée, il faudrait maintenir le nombre de sorties intermédiaires (nombre d'images intermédiaire multiplié par le nombre de positions de pixel) pour être croissante (au sens large) d'une couche à l'autre.

Le nombre d'images intermédiaires contrôle directement la puissance du système, dépend du nombre d'exemples disponibles et la complexité du traitement[22].

### Forme de Filtres


Les formes de filtre varient grandement dans la littérature. Ils sont généralement choisis en fonction de l'ensemble de données. Les meilleurs résultats sur les images de MNIST (28x28) sont habituellement dans la gamme de 5x5 sur la première couche, tandis que les ensembles de données d'images naturelles (souvent avec des centaines de pixels dans chaque dimension) ont tendance à utiliser de plus grands filtres de première couche de 12x12, voire 15x15. Le défi est donc de trouver le bon niveau de granularité de manière à créer des abstractions à l'échelle appropriée et adaptée à chaque cas.

### Forme de Max Pooling

Les valeurs typiques sont 2x2 (figure 8). De très grands volumes d'entrée peuvent justifier un pooling 4x4 dans les premières couches. Cependant, le choix de formes plus grandes va considérablement réduire la dimension du signal, et peut entraîner la perte de trop d'information.[22]

## 4.3 Avantages de CNNs

Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution. Cette méthode réduit l'empreinte mémoire,



**Figure 2.11** – Exemple de max pooling ( $2 \times 2$ ).

améliore les performances (13) et permet une invariance du traitement par translation. C'est le principal avantage du CNN par rapport au MLP, qui lui considère chaque neurone indépendant et donc affecte un poids différent à chaque signal entrant. Lorsque le volume d'entrée varie dans le temps (vidéo ou son), il devient intéressant de rajouter un paramètre de temporisation (delay) dans le paramétrage des neurones. On parlera dans ce cas de réseau neuronal à retard temporel (TDNN).

Comparés à d'autres algorithmes de classification de l'image, les réseaux de neurones convolutifs utilisent relativement peu de pré-traitement. Cela signifie que le réseau est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision), ce qui n'est pas le cas d'autres algorithmes plus traditionnels. L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN[22].

## 5 Deep Résiduel Learning

### 5.1 Apprentissage résiduel profond (Deep Residual Learning)

#### Résiduel

Le terme résiduel est utilisé dans plusieurs domaines comme l'économie, les mathématiques, la statistique, l'économétrie et la géomorphologie [40].


Le résidu est généralement une quantité restante à la fin d'un processus donc résiduel est l'erreur dans un résultat. Pour être précis, supposons que nous voulons trouver  $x$  tel que  $f(x) = y$ . Étant donné une approximation  $x_0$  de  $x$ , le résidu est  $y - f(x_0)$  Alors que l'erreur est  $x - x_0$

Si la valeur exacte de  $x$  n'est pas connue, le résidu peut être calculé, contrairement à l'erreur [41].

## Motivation

Une grande partie du succès des réseaux de neurones profonds a été accréditée aux couches supplémentaires. L'intuition derrière leur fonction est que ces couches apprennent progressivement des fonctionnalités plus complexes. La première couche apprend les bords, la deuxième couche apprend les formes, la troisième couche apprend les objets, la quatrième couche apprend les yeux, etc. [42]

He et al. [43] montrent empiriquement qu'il existe un seuil maximum de profondeur avec le modèle CNN traditionnel. Comme présenté dans la figure 4.1 :



**Figure 2.12** – Erreur d'apprentissage (à gauche) et erreur de test (à droite) sur CIFAR-10 Avec des réseaux "simples" à 20 et 56 couches. Le réseau plus profond a une erreur d'apprentissage plus importante, et donc une erreur de test, Des phénomènes similaires sur ImageNet sont présentés dans la Fig4.1

Lorsque des réseaux plus profonds peuvent commencer à converger, un problème de dégradation a été exposé: avec l'augmentation de la profondeur du réseau, la précision est saturée (ce qui n'est peut-être pas surprenant) puis se dégrade rapidement. De façon inattendue, une telle dégradation n'est pas causée par un sur-ajustement, et l'ajout de couches à un modèle suffisamment profond conduit à une erreur d'apprentissage plus élevée [43].

Les résultats d'expérimentations montrés dans la figure 1 défont notre croyance que l'ajout de couches créerait une fonction plus complexe.

Dans [43], les auteurs abordent le problème de la dégradation en introduisant un cadre d'apprentissage résiduel profond.

## 5.2 Apprentissage Résiduel

Le problème de la formation de réseaux très profonds a été atténué avec l'introduction d'une nouvelle couche de réseau neuronal - le bloc résiduel. Soit  $H(x) = y$  comme un mappage sous-jacent devant être ajusté par quelques couches empilées (pas nécessairement le réseau entier), avec  $x$  désignant les entrées de première couches. Si l'on émet l'hypothèse que plusieurs couches non linéaires peuvent approcher asymptotiquement des fonctions complexes<sup>2</sup>, alors cela équivaut à supposer qu'elles peuvent approximer asymptotiquement les fonctions résiduelles, c'est-à-dire  $H(x) - x$  (en supposant que l'entrée et la sortie sont de mêmes dimensions). Ainsi, plutôt que de nous attendre à ce que les couches empilées approchent  $H(x)$ , nous laissons explici tement ces couches approcher une fonction résiduelle  $F(x) = H(x) - x$ . La




Figure 2.13 – Residuel learning

fonction d’origine devient ainsi  $F(x) + x$ . Bien que les deux formes devraient être capables d’approximer asymptotiquement les fonctions souhaitées (comme cela a été supposé), la facilité d’apprentissage peut être différente.

La formulation de  $F(x) + x$  peut être réalisée par feedforward réseaux de neurones avec «connexions de raccourci»

**Connexions de raccourci**

Les connexions raccourcies (short-Cut Connections parfois aussi appelé skip-connections) sont des liens entre les couches des réseaux de neurones profonds (DNN) qui sautent au moins une couche intermédiaire [44] autrement-dit , ils permettent d’ajouter des extra connexions entre le couche courant et les couches suivantes (forward) . Ils permettent de former des réseaux très profonds en facilitant un flux d’informations plus direct entre des couches éloignées pendant la rétropropagation.

Dans [43], les connexions de raccourci effectuent simplement un mappage d’identité et leurs sorties sont ajoutées aux sorties des couches empilées (Figure 4.2). Les connexions de raccourci d’identité n’ajoutent ni paramètre supplémentaire ni complexité de calcul.

**5.3 Mappage D’identité par Raccourcis**

Le mappage d’identité est multiplié par une projection linéaire  $W$  pour élargir les canaux de raccourci pour correspondre au résiduel. Cela permet de combiner l’entrée  $x$  et  $F(x)$  comme entrée à la couche suivante.

$$y = \mathcal{F}(x, \{W_i\}) + x. \dots\dots\dots(1)$$

Les dimensions de  $x$  et  $F$  doivent être égales en équation (1).  
 Si ce n’est pas le cas (par exemple, lors du changement des canaux d’entrée/sortie), nous pouvons effectuer une projection linéaire  $W_s$  par les connexions de raccourci pour correspondre aux dimensions:

$$\mathbf{y} = \mathcal{F}(\mathbf{x}, \{W_i\}) + W_s \mathbf{x}. \quad \dots\dots\dots(2)$$

## 6 Conclusion

Dans ce chapitre on a présenté les notions importantes qui sont en relation avec l'apprentissage profond (définition, Architectures...etc). Aussi qu'une vision générale sur l'apprentissage profond, toute on donnant en détail la méthode choisie dans notre travail de recherche qui est le CNNs. Le prochain chapitre, nous allons voir les travaux antérieurs pour la vérification de la signature avec CNN.

## Chapter 3

# Etat de l'Art



Ce chapitre est dédié à la description de l'état de l'art dans le domaine de la vérification de la signature avec CNN. Quelques travaux de recherche en vérification de signature sont présentés. Quelques travaux de recherche en vérification de signature sont présentés et classés suivant un ordre chronologique. Et en fin, une comparaison de différentes méthodes est élaborée et articulée sur un ensemble de critères.

## 1 Vérification de signature (Etat de l'Art)

### 1.1 CNN basé VGG architecture pour la vérification de signature hors ligne

Alvarez et al [45] présentent un processus de vérification de signature hors ligne en utilisant des réseaux de neurones de convolution (CNN). Ils fondent leur travail sur l'architecture VGG16, et utilisent ICDAR 2011 SigComp dataset. En classifiant si une signature donnée est une falsification ou authentique, ils obtiennent un taux de vérification de 94 % pour les signatures néerlandaises et 88 % pour les Signatures chinoises.

Leur système de vérification de signature autonome utilise un Réseau Neuronal Convolutional afin de se concentrer sur la construction de systèmes formés sur des données avec différents degrés d'information, ainsi que sur l'expérimentation de différentes fonctions objectives pour obtenir des taux d'erreur optimaux.

Beaucoup d'expériences avec plusieurs variantes des tâches de vérification de signature sont présentés, les auteurs ont montré que les réseaux de neurones convolutionnels font un excellent travail de vérification des signatures lorsqu'ils sont autorisés à accéder pendant la formation à des exemples de signatures authentiques et falsifiées des mêmes personnes dont les signatures sont vues au moment du test.

### 1.2 CNN pour la vérification de la signature dans le secteur bancaire

Dans [46], Cozzens et al a suggérée une méthode d'utilisation des CNN pour analyser les signatures des chèques afin de reconnaître les différences anormales.

L'architecture du CNN proposée est une architecture simple basée sur les réseaux de neurone convolutif, où le CNN est créé à l'aide de la bibliothèque Keras en Python et fondé TensorFlow pour modifier l'image afin de donner à la signature un aperçu plus clair. Ils ont utilisée le système de comparaison d'images, basée sur le système de classification d'images. Lorsqu'une signature est entrée dans le programme, celle-ci sera Comparée à d'autres caractéristiques de signature portant la même étiquette. La principale contribution de cette méthode est de détecter et de réduire la contrefaçon, en particulier dans le secteur bancaire. L'architecture proposée dans ce travail est constitué d'une seule couche de convolution, une couche redresseuse, une couche Max Pooling suivi d'une couche Fully Connected, et enfin une couche softmax.

La méthode de détection correcte de la signature était évaluée pour la base de données ICDAR 2011 SigComp qui donne un taux de 83,93% [46].

Layer	Size	Parameters
Input	150 x 230	None
Convolutional Layer	128 x 5 x 5	Stride =1, pad = 4
Activation (ReLU)	128 x 5 x 5	None
MaxPool	128 x 5 x 5	Pool = (2, 2) Stride =
Dropout	128 x 5 x 5	Drop = 0.50
Flatten	4416000	None
Dense	96	None
Activation (ReLU)	96	None
Dropout	96	Drop = 0.25
Dense	54	None
Activation (ReLU)	54	None
Dropout	54	Drop = 0.25
Dense	M	None
Activation (Softmax)	M	None

Figure 3.1 – Architecture Résumé de la couche

### 1.3 Vérification des signatures manuscrites à l'aide du Deep Learning

La table suivante présente l'architecture proposée dans [47].

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 510, 510, 32)	896
max_pooling2d_1 (MaxPooling2D)	(None, 255, 255, 32)	0
conv2d_2 (Conv2D)	(None, 253, 253, 64)	18496
max_pooling2d_2 (MaxPooling2D)	(None, 126, 126, 64)	0
conv2d_3 (Conv2D)	(None, 124, 124, 128)	73856
max_pooling2d_3 (MaxPooling2D)	(None, 62, 62, 128)	0
conv2d_4 (Conv2D)	(None, 60, 60, 256)	295168
max_pooling2d_4 (MaxPooling2D)	(None, 30, 30, 256)	0
conv2d_5 (Conv2D)	(None, 28, 28, 256)	590080
max_pooling2d_5 (MaxPooling2D)	(None, 14, 14, 256)	0
conv2d_6 (Conv2D)	(None, 12, 12, 512)	1180160
max_pooling2d_6 (MaxPooling2D)	(None, 6, 6, 512)	0
flatten_1 (Flatten)	(None, 18432)	0
dense_1 (Dense)	(None, 256)	4718848
dense_2 (Dense)	(None, 60)	15420

Figure 3.2 – Model Architecture

Il est clair que le CNN (ou ConvNet comme est nommé par les auteurs) est constitué de 12 couches, dont 06 sont de convolution en alternative avec 06 autres de pooling un par un.

Le CNN conçu a été implémenté dans le python en utilisant le Keras avec le TensorFlow

Le jeu de données qui a été utilisé dans ce travail de recherche est une collection spéciale de 30 signataires, dont pour chacun scripteur, 10 signatures, dont 5 authentiques et 5 falsifiées sont collectées. Soit en total 300 images (150 authentiques et 150 falsifiées) utilisées.

Plusieurs tests sont élaborés, dont la meilleure exactitude est de 99.70%.

## 1.4 Vérification de signature hors ligne à l'aide de DAG-CNN

Un DAG-CNN, un réseau qui se compose d'un CNN configuré avec un réseau de type DAG (Directed Acyclic Graph) [45], ce qui a pour avantage par rapport à un CNN configuré de façon linéaire d'utiliser plusieurs chemins ou branches afin de permettre au réseau d'augmenter sa profondeur (nombre de couches de convolution utilisées) sans avoir à l'allonger.

L'architecture proposée dans ce travail divise le réseau en deux branches avec des configurations différentes, la première branche a comme but d'engendrer suffisamment de descripteurs, donc la deuxième branche consiste à apprendre les caractéristiques plus générales des signatures.

L'architecture est mentionnée dans la table suivante. Contiens pour chacun des deux branches 05 couches de Convolution et 03 couches Pooling, finalement la couche Softmax pour agréger les résultats des deux branches[49].

		Input 171x276			
	Path 1		Path 2		
Convolution (ReLU+BN)	16x16	F = 32 S = 3 / P = 2	Convolution (ReLU+BN)	30x30	F = 16 S = 1 / P = 0
Convolution (ReLU+BN)	5x5	F = 64 S = 1 / P = 2	Convolution (ReLU+BN)	20x20	F = 16 S = 1 / P = 0
MaxPooling	2x3	S = 2 P = 1x0	MaxPooling	3x2	S = 2 P = 0
Convolution (ReLU+BN)	4x4	F = 96 S = 1 / P = 1	Convolution (ReLU+BN)	10x10	F = 32 S = 1 / P = 2
Convolution (ReLU+BN)	4x4	F = 128 S = 1 / P = 1	MaxPooling	2x3	S = 2 P = 0
MaxPooling	2x2	S = 2 P = 0	Convolution (ReLU+BN)	9x9	F = 32 S = 1 / P = 2
Convolution (ReLU+BN)	4x4	F = 256 S = 1 / P = 0	MaxPooling	2x2	S = 2 P = 0
MaxPooling	2x2	S = 2 P = 0	Convolution (ReLU+BN)	4x4	F = 64 S = 1 / P = 2
FC (ReLU+Dropout)	1024		MaxPooling	2x3	S = 2 P = 0
FC (ReLU+Dropout)	2048		FC (ReLU+Dropout)	256	
FC			FC (ReLU+Dropout)	2048	
			FC	7	
			SoftMax Classification		


**Figure 3.3** – Architecture proposé pour DAG-CNN

Pour tester le réseau, une base de données spéciale est construite, appelée Test dataset, qui se compose de 23 signatures authentiques et 23 falsifiées de chaque utilisateur. Un taux de réussite de 99.3% est achevé.

## 1.5 Vérification des signatures hors ligne authentiques et falsifiées à l'aide de Siamese Neural Network (SNN)

Le réseau neuronal siamois est un réseau à deux branches ayant des CNN identiques qui partagent les mêmes paramètres et des poids partagés. Dans le même temps, deux images sont entrées au réseau SNN pour but de calculer la fonction de perte.

Le schéma suivant présente la technique proposée. L'architecture SNN comporte pour Chaque branche 09 couches dont 04 couches sont de convolution et 03 de max Pooling et enfin deux couches Fully con-



**Figure 3.4** – Architecture de Siamese Neural

nected, comme il est résumé dans Le schéma suivant. Trois célèbres bases de données sont utilisées pour

Layer	Size	Parameters
Convolution	$96 \times 11 \times 11$	Stride=1
Normalization	-	k=2, n=5
Pooling	$96 \times 3 \times 3$	Stride=1
Convolution	$256 \times 5 \times 5$	Stride=1, pad=2
Normalization	-	k=2, n=5
Pooling + Dropout	$256 \times 3 \times 3$	Stride=1, pad=0.3
Convolution	$384 \times 3 \times 3$	Stride=1, pad=1
Convolution	$256 \times 3 \times 3$	Stride=1, pad=1
Pooling + Dropout	$256 \times 3 \times 3$	Stride=2, pad=0.3
Fully Connected + Dropout	1024	pad=0.5
Fully Connected	132	

**Figure 3.5** – L'architecture outline des couches CNN

évaluations ; il s'agit de GPDS Synthetic, MCYT-75 et CEDAR dont les taux de vérification atteint sont respectivement : 77.48% ; 80.73% et 100% [50].

## 1.6 Détection des falsification à l'aide du Deep Learning

Dans [51] Jivesh Poddar et al propose :

Une Méthode de prétraitement pour faciliter la vérification de la signature.

Un CNN, et un modèle basé sur l'algorithme Crest-Trough pour le système de vérification de signature.

Un modèle basé sur Harris, et Surf pour la détection de la contrefaçon dans la signature.

L'architecture du système proposée est représentée sur la figure suivante, où la signature de test est reconnue avec l'ensemble d'apprentissage d'entrée donné en utilisant à la fois le CNN et la méthode Crest-Trough. Ensuite, des algorithmes de détection de contrefaçon (Harris Algorithmic puis Surf Algorithm) sont appliqués sur cette image classée. Le système proposé atteint une exactitude de 85-89 % pour la d'détection de falsification[51].

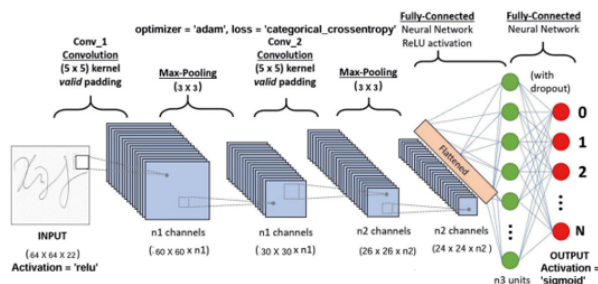


Figure 3.6 – Architecture de CNN

## 2 Comparaison des Travaux

Etude	Les travaux	Modèle du CNN	Nombre de couche	Base de données	Performance
01	Alvarez et al	VGG16	/	ICDAR 2011	Néerlandaises:94% Chinoises:88%
02	Cozzens et al	Ordinaire		ICDAR2011	83.93%
03	Alajrami et al	Ordinaire	12 Couches	spéciale	99.3%
04	Pinzón	DAG-CNN	05 Couches	spéciale	99%
05	Jagtap et al		09 couches	ICDAR	77.48%    80.73% 100%
06	Poddar et al		02 Couches	1320 images	85-89%

Table 3.1 – Principaux travaux de recherche dans le domaine vérification de la signature


## 3 Deep Résiduel Learning (Etat de l'Art)

### 3.1 Travaux William Du et al

Dans cette étude, William Du et al examiné des architectures de réseau neuronales convolutional siamoises pour vérifier la profession d'auteur de texte manuscrit. Nous avons d'abord examiné la longueur de texte exigé de faire une prédiction exacte et avons découvert que les lignes de mots jouaient beaucoup mieux que les mots simples. Sémantiquement, il permis de déterminer combien écrivains est nécessaire de créer un système de vérification d'auteur exact. Dans ce cas-là, chaque ligne contient de 5 à 10 mots en moyenne. Dans l'avenir, le pas logique suivant devra développer l'utilisation le accomplissez des images de pages plutôt que les lignes simples. Cela a dépendu sur la mémoire disponible sur notre Nuage Google machine. Ensuite, ils avent examiné de différentes architectures pour déterminer qu'architecture a fourni le fait d'encoder le plus instructif c'a été en mesure de faire la distinction entre des auteurs. ils explorons

VGGNet, GoogLeNet et dif grandeurs de ferent de ResNet. Le meilleur modèle d'exécution était a la version raccourcie de ResNet que ils avent forgé TinyResNet.

Un modèle de TinyResNet simple entraîné sur 25,000 échantillons était capable d'accomplir l'exactitude de 92.08 % sur un jeu tendu d'essai. Ensembling de 5 modèles de TinyResNet entraînés sur 10,000 datapoints chacun n'a pas de façon significative amélioré le modèle[52].



**Figure 3.7** – Architecture générale de notre modèle de ResNet[52]

### 3.2 Travaux Songtao Wu et al.2017

Songtao Wu et al a présenté un roman convolutional le modèle de réseau neuronal pour l'image steganaly-sis. Le modèle proposé a deux différences évidentes avec les travaux existants. D'abord, le réseau proposé a une relativement plus grande profondeur que CNN actuelle a basé des modèles. Deuxièmement, un mécanisme d'apprentissage original s'est appelé l'apprentissage restant est utilisé pour activement préserver le faible signal de stego.

Les expériences sur la norme dataset ont démontré que le réseau proposé a des contributions suivantes : CNN avec la grande profondeur montre une capacité supérieure de modeler des images naturelles. Il peut extraire des caractéristiques statistiques complexes pour classifier des images de couverture et des images de stego[53].

L'apprentissage restant s'avér être efficace de préserver le faible signal de stego, faire le modèle proposé capturer la différence entre coverimagesandstegoimages. Inaddition, les caractéristiques automatiquement apprises par le réseau proposé sont plus facilement classifiés que le modèle riche classique a basé des caractéristiques. Le travail actuel démontre qu'un réseau profond avec l'apprentissage restant peut découvrir le domaine spatial steganography efficacement. Nous étendrons ce travail pour découvrir le domaine comprimé steganographic les algorithmes[53].

### 3.3 Travaux Dongwook Lee et al.2017

Wang et al était le premier à appliquer profondément l'apprentissage à CSMRI (Compressed sensing (CS),Magnetic resonance imaging (MRI)). Ils ont entraîné le réseau neuronal profond des images de




Figure 3.8 – DRN for steganalysis

reconstruction downsampled à apprendre complètement essayé reconstruction. was le cerveau utilisé M. de l'image dataset, qui se compose de 81 images axiales totales du cerveau de 9 sujets. Les données ont été acquises dans la coordonnée cartésienne avec un 3T M. du scanner Alors, ils ont utilisé la production d'apprentissage profonde l'un ou l'autre comme Les résultats expérimentaux en utilisant le canal simple et multi-CS-MRI montrent l'amélioration significative de la performance sur M. existant de la reconstruction "l'état des " algorithmes d'art[54].

ils avent présenté une méthode de reconstruction MRI accélérée de l'uniforme downsampled M. des données du cerveau en utilisant l'apprentissage restant. En apprenant aliasing les objets fabriqués qui ont topology plus simple, le risque s'ensuivant de l'apprentissage restant proposé peut être réduit pour que nous puissions obtenir M. plus exact des images. Les travaux de méthode proposés pas les données de canal seulement multi-mais les données de canal aussi simples. Même avec les objets fabriqués aliasing cohérents sévères, le restant proposé l'apprentissage apprend avec succès les objets fabriqués aliasing, alors que le le parallèle existant et la reconstruction CS échouent. De plus, comparé aux algorithmes existants qui ont besoin lourd quantitatif le prix, le réseau proposé produit les résultats immédiatement[54].

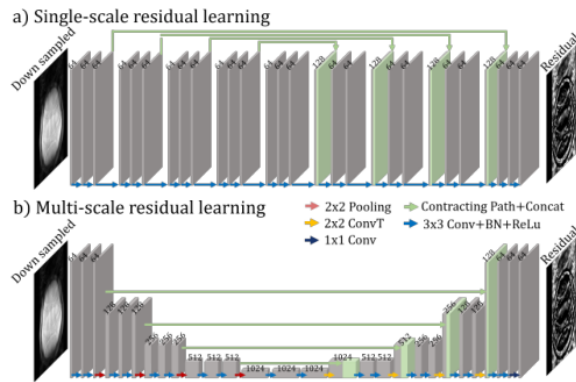


Figure 3.9 – L'échelle simple l'apprentissage restant avec un modifié le cadre de réseau de deconvolution [54]

## 4 Conclusion

Dans ce chapitre nous avons présenté un aperçu sur état de l'art dans le domaine de vérification de signature. Dans la première partie, nous nous concentrons sur la présentation des principaux travaux de recherche dans ce domaine et discutons les diverses compétitions.

Ensuite, nous avons présenté une comparaison des différents travaux du domaine en nous basant, comme critères de comparaison, les bases de données utilisées, le Modèle du CNN choisies et bien sur les taux de performance obtenu.

Dans la deuxième partie nous avons présenté des Travaux de Deep Résidual Learning.

Le chapitre suivant se consacre à la description l'architecture du CNN choisie et le résultat expérimental et le Deep Résidual Learning.



## Chapter 4

# Deep Résidual Learning Pour la Vérification des signatures

Ce chapitre présenter les résultats obtenus pour la validation du système vérification de signature. Où nous concevons la conception d'application en utilisant le langage Python.

Dans ce chapitre, nous utilisons l'apprentissage profond ResNet Pour vérification la signature, en utilisant la base de données ICDAR2011.

## 1 Présentation des outils de développement

### 1.1 Matériel

Le matériel réalisé est PC personnel hp proBook 4540s I3 avec un 4GB capacité mémoire, et un processeur Intel® Core™ i3 CPU M 370 @2.40 GHz 2.40 GHz, avec Windows 10, 64 bit type du système.

### 1.2 Python

Python est le langage de programmation le plus utilisé dans le domaine du Machine Learning, du Big Data et de la Data Science. Découvrez tout ce que vous savoir à son sujet : définition, avantages, cas d'usage... Créé en 1991, le langage de programmation Python apparu à l'époque comme une façon d'automatiser les éléments les plus ennuyeux de l'écriture de scripts ou de réaliser rapidement des prototypes d'applications.[55] Depuis quelques années, toutefois, ce langage de programmation s'est hissé parmi les plus utilisés dans le domaine du développement de logiciels, de gestion d'infrastructure et d'analyse de données. Il s'agit d'un élément moteur de l'explosion du Big Data.[55]

### 1.3 Google Colab

Google Colaboratory (Colab) est un service de cloud basé sur Jupyter Notebooks destiné à diffuser des informations et des formations en apprentissage automatique.

Colaboratory fournit des temps d'exécutions sur Python 2 et 3, préconfigurées avec les bibliothèques d'apprentissage automatique, en profondeur et d'intelligence artificielle essentielles telles que TensorFlow, Matplotlib, et Keras, et un accès gratuit à un GPU robuste.

De plus, les documents Colab sont enregistrés directement votre compte Google Drive.[22]

Google Colaboratory ou Colab, un outil Google simple et gratuit pour vous initier au Deep Learning ou collaborer avec vos collègues sur des projets en science des données. Colab permet :

- d'améliorer vos compétences de codage en langage de programmation Python.
- de développer des applications en Deep Learning en utilisant des bibliothèques Python populaires telles que Keras, TensorFlow, PyTorch et OpenCV.

- d'utiliser un environnement de développement (Jupyter Notebook) qui ne nécessite aucune configuration.[56]

## 2 Architecture du système proposé

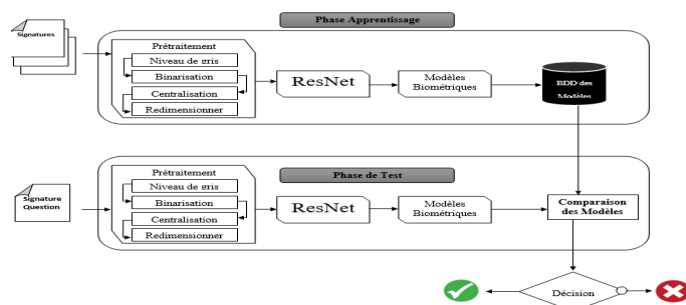


Figure 4.1 – L'architecture de système Proposé

### 2.1 Prétraitement

Puisque les signatures sont des images acquises par un scanner, ils ont des tailles différentes et ils sont représentés en RVB, donc, l'étape de prétraitement est primordiale. Le prétraitement regroupe l'ensemble des processus visant à améliorer les caractéristiques des signatures de la base de données. Cette étape consiste à préparer les données qui seront fournies au module d'authentification. Plusieurs traitements sont nécessaires, les deux suivants sont utilisés.

#### Conversion en monochrome

Après l'acquisition numérique d'une signature, nous disposons d'une image RGB (à 16 millions couleurs). Utiliser des images en niveau de gris est plus fiable dans les systèmes de vérification de signature. Donc il faut calculer la valeur d'intensité lumineuse d'un pixel (valeur entre 0 et 255) au lieu de sont couleur (valeur de 0 à 16 millions).

#### Centralisation


Nous avons mis la partie importante de l'image au milieu et ajouté le reste en tant que bords blancs

## Redimensionnement

Suite à différentes tailles d'images contenant les signatures et afin de normaliser la taille des images d'entrées du réseau de neurone convolutif, un processus de redimensionnement est effectué. Les images sont d'abord recadrées dans une image de taille 3663\*800 (la plus grande image), en suite les images de résultats sont redimensionnées en taille standard 600\*200.

## 2.2 Structure de Residual Learning (ResNet)

Avant tout, nous devons définir l'architecture du réseau ResNet:



**Figure 4.2** – Structure de Residual Learning (ResNet)

Dans notre expérience, nous avons construit une architecture CNN pour la classification avec un backend Tensorflow en Python. Le CNN proposé qui est représenté sur la Table 4.1 Prend une image de signature brute de taille 600\*200 pixels en entrée. Les images d'entrée sont normalisées entre 0 et 1 et sont transmises à un CNN. Le CNN est composé de 10 couches : 04 couches convolutives, 04 couches de max pooling et et enfin deux couches Fully connected.

la couche entièrement connecté est lié avec la couche de sortie pour donnée les résultats. La dernière couche qui est la cible du réseau. Les cibles 01 et 10 signifient respectivement la signature originale et la signature falsifiée.

Couch	Taille	Paramètres
Input-layer	600*200*1	0
Conv2d-1	600*200*28	56
Conv2d-2	600*200*28	7084
Conv2d-3	600*200*28	7084
add-1	600*22*28	0
Maxpooling-1	300*100*28	0
Conv2d-4	300*100*56	1624
Conv2d-5	300*100*56	28280
Conv2d-6	300*100*56	28280
add-2	300*100*56	0
Maxpooling-2	150*50*56	0
Conv2d-7	150*50*84	4788
Conv2d-8	150*50*84	63588
Conv2d-9	150*50*84	63588
add-3	150*50*84	0
Maxpooling-3	75*25*84	0
Conv2d-10	75*25*112	9520
Conv2d-11	75*25*112	113008
Conv2d-12	75*25*112	113008
add-4	75*25*112	0
Maxpooling-4	37*12*112	0
Flatten-1	49728	0
dropout-1	128	0
dropout-2	128	0
dense-3	2	258

Table 4.1 – Couches du CNN

### 3 Résultats et comparaison les travaux

#### 3.1 Présentation de la base de données


la base de données ICDAR 2011 provient du concours international SigComp de vérification des signatures de la Conférence internationale sur l'analyse et la reconnaissance des documents.

La base de données comprend des signatures en ligne et hors ligne pour les signataires chinois et néerlandais. L'ensemble de données est divisé en un ensemble d'apprentissage et un ensemble de tests de personnes non imbriqué.

L'ensemble d'apprentissage néerlandais comprend un total de 362 images pour 16 personnes, avec environ 24 signatures authentiques et 4 signatures falsifiées pour chaque personne, par contre l'ensemble d'apprentissage en chinois contient 575 images pour 10 personnes, avec environ 24 signatures authentiques et 12 contrefaçons pour chaque personne.

L'ensemble de test comprend un ensemble de "référence" et "question", les références étant des signatures originales connues et les signatures contestables étant originales ou falsifiées.

Le test néerlandais composé de 54 personnes, chacun personne comportant 12 signatures de référence et environ 3 signatures en vérification (en question), par contre le test chinois composé de 10 personnes, avec environ 12 signatures de référence et environ 3 signatures en question.



**Figure 4.3** – Exemples de signatures de la base de données ICDAR 2011. Rangée du haut: signatures du sous-ensemble chinois, rangée du bas: signatures du sous-ensemble néerlandais.

### 3.2 Résultats

Dans notre travail, nous avons utilisé CNN comme méthode de classification. Dans la signature Néerlandais nous avons obtenu un pourcentage 93.47% pour le test. Par contre, pour la signature Chinois nous avons obtenu 68.07% l'expérience sont effectuées plusieurs fois pour 785 époques sur la base de données ICDAR2011 sigcomp. Nous comparons notre travail avec les travaux précédents dans ce domaine dans le tableau ci-dessous:

Etude	Les travaux	L'année	BDD	Taux (%)
01	Alvarez et al	2016	ICDAR 2011	Néerlandaises:94% Chinoises:88%
02	Méthode Proposé	2020	ICDAR2011	Néerlandaises:93.47% Chinoises:68.07%
03	Cozzens et al	2017	ICDAR201	99.3%

**Table 4.2** – Principaux travaux de recherche dans le domaine vérification de la signature

## 4 Conclusion

Dans ce chapitre, après avoir achevé notre conception nous avons donné les outils des développements nécessaires pour la réalisation de notre travail. A la fin nous avons présenté notre approche de classification basée sur les réseaux de neurones convolutifs en donnant quelques explications du fonctionnement de notre travail, ainsi que les résultats obtenus.

# Conclusion générale

Malgré le développement considérable des différentes modalités biométriques, les signatures sont restées le mécanisme d'authentification le plus largement accepté dans les documents juridiques et les transactions financières.

C'est dans ce cadre que s'inscrit notre travail, qui a pour objectif de proposer une application qui réalise et de renforcer la capacité de vérification de signature. Le système de vérification de signature hors ligne est développé pour distinguer les signatures authentiques ou falsifiées.

Pour réaliser notre travail de vérification on a utilisé l'apprentissage profond, la méthode d'apprentissage qui a montré ses performances ces dernières années et il est une partie supplémentaire des algorithmes d'apprentissage automatique et est donc classé dans une section plus large de l'intelligence artificielle, et nous avons choisi la méthode CNNs comme une méthode de classification pour la vérification de signature, ce choix est justifié par la simplicité et l'efficacité de la méthode et on peut s'attendre à ce que les CNN obtiennent des résultats nettement meilleurs que les autres réseaux pour de nombreuses tâches.

Dans ce travail, nous avons obtenu du taux 93.47% pour les signatures Néerlandais et 68.07% pour les signatures Chinoise sur la base de données ICDAR 2011 sigComp.



# Bibliography

- [1] **Peter Gregory** et **Michael A. Simon**: *Biometrics For Dummies*, Cisa, Cissp, 2008.
- [2] **BENCHENNANE Ibtissam** : *Etude et mise au point d'un procédé biométrique multimodale pour la reconnaissance des individus*, Diplôme de Doctorat en Sciences, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, 2016.
- [3] **ZITOUNI Sif Eddine** et **SACI Abdelmoumen**: *Authentification et Identification biométrique des personnes par les empreintes palmaires*,Mémoire MASTER ACADEMIQUE, UNIVERSITE KASDI MERBAH OUARGLA, 2016.
- [4] **Allano, L** : *La Biométrie multimodale, stratégies de fusion de scores et mesures de dépendance appliquées aux bases de personnes virtuelles (Doctoral dissertation, Evry, Institut national des télécommunications)*,2009.
- [5] **Florent PERRONNIN** et **Jean-Luc DUGE LAY**: *Introduction à la Biométrie Authentification des Individus par Traitement Audio-Vidéo*;Institut Eurécom, Multimédia Communications Department 2229,Traitement du Signal 2002 – Volume 19 – n°4.
- [6] **C. Fredouille** et **J. Mariethoz** et **C. Jaboulet** et **J. Hennebert** et **J.-F et Bonastre,C** et **Mokbel, F** et **F. Bimbot** : *Behavior of a Bayesian Adaptation Method for Incremental Enrollment in Speaker Verification*,International Conference on Acoustics, Speech, and Signal Processing, p. 1197-1200, Istanbul, Turquie, 5-9 Juin 2000.
- [7] **L. Heck** et **N. Mirghafori**: *On-Line Unsupervised Adaptation in Speaker Verification*,, International Conference on Spoken Language Processing, Vol. 2, p. 454-457, Pékin, Chine, 16-20 Octobre 2000.
- [8] **TOUKA FAISAL** : *Reconnaissance de la paume de la main*, Ecole nationale Supérieure d'Informatique (ESI) Oued-Smar, Alger, 2010.
- [9] **Anil K. Jain** et **Gilles Lacombe** et **Sharath Pankanti**: *BIOMETRICS Personal Identification in Networked Society*, Kluwer Academic Publishers New York, Boston, Dordrecht, London, Moscow, 2002.

- [10] **PJames L. Wayman et Anil K.Jain et Davide Maltoni:** *Da Biometric Systems.*
- [11] *Biometric système-IDTECK*, Document available at: <http://www.idteck.com/technology/biometrics.jsp>.
- [12] **Earprints et Forensic Evidence:** *Encyclopedia of Biometrics*, s.l.:Spring. 127, Champod, C., 2009.
- [13] **Claus Vielhauer :** *Biometric User Authentication for IT SECURITY Networked Society.*
- [14] **John D et woodward et Jr:** *Christopher Horn, Julius Gatune, and Arynthomas, Biometrics Alook at Facial Recongnition*, documented briefing by RAND public safety and Justice for the Virginia state crime commission, 2003.
- [15] **DANG Hoang :** *Biométrie pour l'Identification*, Rapport final.
- [16] **Noureddine Ali :** *Verification faciale de la parenté par un réseau de neurone à convolution*, mémoire de master, université de BISKRA, 2018.
- [17] **Walid BOUAMRA et Mohamed El Amine ZOGHBI:** *Vérification des signatures manuscrites et détection de falsification en utilisant des caractéristiques texturales*, Mémoire de Master, Université Larbi Tébessi –Tébessa, 2016.
- [18] **Fedias Meriem:** *Combinaisons de données d'espaces couleurs et de méthodes de vérification d'identité pour l'authentification de visages*, Université Mohamed Khider – Biskra.
- [19] **Nicolas MORIZET:** *Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris*, Thèse présentée pour obtenir le grade de Docteur, Ecole Nationale Supérieure des Télécommunications, Paris, 18 Mars 2009.
- [20] **R. Sabourin et G. Genest et F. J. Prêteux:** *Off-Line Signature Verification by Local Granulometric Size Distribution*, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 19, no. 9, pp. 976-988, 1997.
- [21] **C. Santos et E.J.R. Justino et F. Bortolozzi et R. Sabourin:** *An Off-Line Signature Verification Method based on the Questioned Document Expert's Approach and a Neural Network Classifier*, International Workshop On Frontiers in Handwriting Recognition (IWFHR), Tokyo (Japon), pp. 498-502., 2004. M. Wirotius, A. Seropian et N. Vincent, "Writer Identification from Gray Level Distribution", Proceedings of the International Conference on Document Analysis and Recognition (ICDAR'03), Edinburgh (Ecosse). pp. 1168-1172, 2003.
- [22] **Boughaba Mohammed et Boukhris Brahim:** *L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu*, Mémoire Master Professionnel, UNIVERSITE KASDI MERBAH-OUARGLA, 2016
- [23] **Youcef Djeriri:** *Les Réseaux de Neurones Artificiels*, University of Sidi-Bel-Abbes · Department of Electrical Engineering, 2017.

- [24] **C. Touzet**: *Les réseaux de neurones artificiels : introduction au connexionnisme*, 150 pages, Edition EC2, Paris. 1992, pp.6-35.
- [25] **N. Benahmed**: *Optimisation des réseaux de neurones pour la reconnaissance de chiffres manuscrits isolés : Sélection et pondération des primitives par algorithmes génétiques*, Thèse de Master, École de technologie supérieure, MONTRÉAL, pp.4-70.
- [26] :[https://www.college-de-france.fr/media/yann-lecun/UPL4485925235409209505\\_Intelligence\\_Artificielle\\_Y.\\_LeCun.pdf](https://www.college-de-france.fr/media/yann-lecun/UPL4485925235409209505_Intelligence_Artificielle_Y._LeCun.pdf)
- [27] :<https://ia-data-analytics.fr/intelligence-artificielle/>
- [28] **Nuri Kasimov** Responsable Technique chez OQTOR : *Quelle est la différence entre l'intelligence artificielle, l'apprentissage machine, l'apprentissage profond et le traitement du langage naturel ?*, Université de Grenoble Alpes (2012), Mis à jour 18 mai 2017.
- [29] <https://digitalinsiders.feelandclic.com/construire/definition-quest-machine-learning>.
- [30] **W Gerstner** et **WM Kistler**: *Spiking neuron models: Single neurons, populations, plasticity*, Cambridge university press, 2002.
- [31] **McCulloch** et **W. S** et **Pitts**: *A Logical Calculus of the Ideas Immanent in Nervous Activity* *Bulletin of Mathematical Biophysics*, 1943.
- [32] **Pierre Buysens** : *Fusion de différents modes de capture pour la reconnaissance du visage appliquée aux e transactions*, DOCTORAT de l'UNIVERSITÉ de CAEN Le 4 Janvier 2011.
- [33] **I. Arel** et **D. C. Rose** et **T. P. Karnowski**: *Deep machine learning-a new frontier in artificial intelligence research [research frontier]*, IEEE Computational Intelligence Magazine, vol. 5, no. 4, pp. 13–18, 2010.
- [34] **I. Aizenberg** et **N. N. Aizenberg** et **J. P. Vandewalle**, *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*. Springer Science Business Media, 2013.
- [35] **Mokri Mohammed Zakaria**: *Classification des images avec les réseaux de neurones convolutionnels*, Mémoire de fin d'études Pour l'obtention du diplôme de Master en informatique, Université Abou Bakr Belkaid Tlemcen, 2017.
- [36] Voir Wikipédia [http://en.wikipedia.org/wiki/Deep\\_learning](http://en.wikipedia.org/wiki/Deep_learning) on "Deep Learning" à partir de cette dernière mise à jour en octobre 2013 .
- [37] **A. Van den Oord** et **S. Dieleman** et **B. Schrauwen**: *Deep content-based music recommendation*, in *Advances in neural information processing systems*, pp. 2643–2651, 2013.

- [38] **R. Collobert** et **J. Weston**: *A unified architecture for natural language processing : Deep neural networks with multitask learning*, in Proceedings of the 25th international conference on Machine learning, pp. 160–167, ACM, 2008.
- [39] [http:// www.qingpingshan.com/bc/jsp/163284.html](http://www.qingpingshan.com/bc/jsp/163284.html)
- [40] *Contributeurs de Wikipédia. "Residual (numerical analysis)". Wikipédia, l'encyclopédie libre. Wikipédia, L'encyclopédie libre, 08 Juin. 2020. Web. 08Juin.2020<<https://en.wikipedia.org/wiki/Residual>>*.
- [41] <https://towardsdatascience.com/introduction-to-resnets-c0a830a288a4>
- [42] **He, Kaiming** et **Zhang, Xiangyu** et **Ren, Shaoqing** et **Sun, Jian** : *Deep Residual Learning for Image Recognition* (PDF). Proc. Computer Vision and Pattern Recognition (CVPR), IEEE. Retrieved 2020-04-23.
- [43] **Oñoro-Rubio, D** et **Niepert, M** et **López-Sastre, R.J** : *Learning Short-Cut Connections for Object Counting* . arXiv 2018, arXiv:1805.02919.
- [44] **Gabe Alvarez** et **Blue Sheffer** et **Morgan Bryant**: *Offline Signature Verification with Convolutional Neural Networks*, 2016.
- [45] **Brittany Cozzens** et **Richard Huanget Maxwell Jayet Felix Zhanet Mark Zhang**: *OCNN pour détecter et réduire la falsification des signatures*, 2017.
- [46] **Eman Alajrami** et **Belal A. M. AshqaretBassem S. Abu-NasseretAhmed J. Khalil** : *and-written Signature Verification using Deep Learning*.December,2019.
- [47] **K. Thulasiraman** et **M. N. Swamy** et **César G. Pachón-Suescún** : *theory and algorithms*, John Wiley and Sons,2011.
- [48] **Javier O. Pinzón-Arenas** et **Robinson Jiménez-Moreno** et **César G. Pachón-Suescún** : *Offline signature verification using DAG-CNN*,2019.
- [49] **Jagtap AB** et **Hegadi RS**: *Verification of genuine and forged off line signatures using Siamese Neural Network(SNN)*,2020.
- [50] **Jivesh Poddar** et **Vinanti Parikh** et **Santosh Kumar Bharti**: *Offline Signature Recognition and Forgery Detection using Deep Learning*,2020.
- [51] **William Du** et **Michael Fang** et **Margaret Shen** : *Siamese Convolutional Neural Networks for Authorship Verification*.
- [52] **Songtao Wu** et **Shenghua Zhong** et **Yan Liu**:*Deep residual learning for image steganalysis*,2017.
- [53] **Dongwook Lee** et **Jaejun Yoo** et **Jong Chul Ye**:*DEEP RESIDUAL LEARNING FOR COMPRESSED SENSING MRIBio Imaging and Signal Processing Lab., Dep. of Bio and Brain Engineering, KAIST*,2017.

[54] *Contributeurs de Wikipédia. "Residual". Wikipédia, l'encyclopédie libre. Wikipédia, L'encyclopédie libre, 08 Juin. 2020. Web. 08 Juin. 2020* [<https://en.wikipedia.org/wiki/Residual>](https://en.wikipedia.org/wiki/Residual).

[55] <https://www.lebigdata.fr/python-langage-definition>

[56] <https://moov.ai/fr/blog/deep-learning-avec-google-colab/>