

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

UNIVERSITÉ BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY



جامعة باجي مختار – عنابة

Faculté : TECHNOLOGIE
Département : ELECTRONIQUE
Domaine : SCIENCES ET TECHNOLOGIES
Filière : AUTOMATIQUE
Spécialité : AUTOMATIQUE SYSTEME

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème :

Détection et classification des défauts de surface de bandes en acier par les méthodes de Deep Learning

Présenté par :

- *Bellal Karim*
- *Atamnia Ahmed Hamza*

Encadrant : *Saadi Mohamed Nacer* *MCB* *UBM Annaba*

Jury de Soutenance :

Benouaret Mohamed	Professeur	UBM Annaba	Président
Saadi Mohamed Nacer	MCB	UBM Annaba	Encadrant
Boulebtatech Brahim	MCB	UBM Annaba	Examineur

Année Universitaire : 2022/2023

Remerciement

La première chose, on remercie Dieu le tout puissant de nous avoir donné le courage, la santé et la volonté pour terminer cette mémoire.

*Tout d'abord, nos remerciements à Monsieur **SAADI MOHAMED NACER***

De nous avoir encadré, et pour le temps qu'il a consacré à discuter de nos idées, à revoir nos écrits et à fournir des commentaires constructifs et précieux nous permet de perfectionner nos idées et de les présenter de manière claire et convaincante.

Mes salutations aux enseignants du département d'électronique qui ont contribué à notre formation

Nous n'oublions pas non plus de remercier toutes nos familles de nous avoir encouragés dans notre chemin d'études

Dédicaces

Nous dédions ce travail

*A nos chères parentes qui ont soutenu et encouragé durant ces
années d'études.*

*A tous nos amis dans notre équipe foot université d'Annaba qui
encouragent toujours, et à qui nous souhaitons plus de succès.*

*A nos familles, nos proches et à ceux qui nous donnent de
l'amour et de la vivacité.*

Résumé

Dans cette étude, nous avons exploré l'utilisation des réseaux de neurones convolutifs, qui sont des architectures multicouches spécialement conçues pour la reconnaissance de formes. Notre objectif était de classifier des images, et pour cela, nous avons effectué plusieurs optimisations en ajustant les paramètres de l'architecture du réseau convolutif. Afin de nous familiariser avec les avancées les plus récentes en matière de classification, et de pouvoir concevoir notre propre modèle.

Abstract

In this study, we explored the use of convolutional neural networks, which are multi-layered architectures specially designed for pattern recognition. Our goal was to classify images, and for this, we performed several optimizations by adjusting the parameters of the convolutional network architecture. in order to familiarize ourselves with the most recent advances in classification, and to be able to design our own model.

ملخص

في هذه الدراسة، اكتشفنا استخدام الشبكات العصبية التلافيفية، وهي هياكل متعددة الطبقات مصممة خصيصًا للتعرف على الأنماط. كان هدفنا هو تصنيف الصور، ولهذا، أجرينا العديد من التحسينات عن طريق ضبط معلمات بنية الشبكة التلافيفية. ومن أجل التعرف على أحدث التطورات في التصنيف، ولكي نكون قادرين على تصميم نموذجنا الخاص.

Tables des matières

Tables des matières	5
Table des figures	7
Liste D'abréviations	9
Introduction générale.....	10
1. Contexte et objectif :	10
2. Organisation du mémoire :.....	11
Chapitre I Laminage.....	12
I. Introduction.....	13
I.1.Procédé de Laminage	13
I.1.2. Le Laminage	15
I.1.3. Principe de laminage.....	15
I.1.4. La production de laminage.....	16
I.1.4.1. Le laminage à chaud :	16
I.1.4.2. Le laminage à froid :	17
I.3. Conclusion	20
Chapitre II Les Réseaux de neurones convolutifs.....	21
II Introduction	22
II.1. L'IA, Intelligence artificielle.....	23
II.2. Machine Learning.....	23
II.3. Deep Learning	24
II.4. Réseaux de neurones convolutifs	25
II.4.1. Définition.....	25

II.4.2. Architecture globale de CNN	25
II.4.4. Avantages des réseaux de neurones convolutifs.....	32
II.4.5. Exemples d'architecture CNN	33
II.5. Conclusion.....	33
Chapitre III Implémentation	34
III.1. Introduction.....	35
III.2. Méthodologie de diagnostic proposée.....	35
III.3. Description de la base de données.....	36
III.4. Architecture de la méthode proposé CNN	38
III.4.1. Architecture du modèle	38
III.5. Résultats obtenus et discussion	39
III.6. Conclusion.....	40
III.7. Conclusion générale	41
Bibliographies.....	42

Table des figures

Figure I. 1 : Schéma simplifié du processus sidérurgique, filière fonte.....	14
Figure I. 2 : Procédé de laminage.....	15
Figure I. 3 : Transformation mécanique en laminage.	16
Figure I. 4 : laminage à chaud.....	17
Figure I. 5 : laminage à froid.....	18
Figure II.1: Intelligence artificielle, machine Learning, Deep Learning et convolution neural network.....	22
Figure II.2: le processus typique du ML	24
Figure II.3 : a) Réseau de neurones simple b) Réseau de neurones profond	24
Figure II.4 : Réseau neuronal convolutif.....	25
Figure II.5 : exemple de convolution 2D	26
Figure II.6 : Le padding.....	27
Figure II.7 : pas de 2.....	27
Figure II.8 : courbe la fonction ReLU.....	28
Figure II.9 : courbes la fonction de tangente hyperbolique.....	28
Figure II.10 : courbes la fonction sigmoid	29
Figure II.11 : Exemple Maxpooling.....	30
Figure II.12 : Exemple Average pooling.....	30
Figure II.13 : La fonction softmax.	31
Figure II.14 : Un réseau de neurones convolutif.....	32
Figure III.1 : Phase d'apprentissage.....	35
Figure III.2 : Phase de classification	36
Figure III.3 : Exemples de catégories d'images de défauts de surface	38
Figure III.4 : Architecture du modèle.....	39
Figure III.5 : Courbes de précision de formation et de validation de la méthode CNN.....	39

Figure III.6 : Courbes de perte de formation et de validation de la méthode CNN40

Liste D'abréviations

- **CR** Crazing
- **PS** des piqûres
- **PA** Patches
- **IN** Inclusion
- **SC** Scratch
- **RS** Rolled-in scale
- **DL** Deep Learning
- **ML** Machine Learning
- **CNN** Convolution Neural Network
- **RELU** Rectified Linear Unit
- **FCL** Fully Connected Layers
- **MLP** Multi-layer Perceptron
- **OX** Oxydation

Introduction générale

1. Contexte et objectif :

La technologie d'automatisation pour le contrôle de la qualité de l'acier a attiré l'attention de la communauté des chercheurs car il s'agit d'un élément essentiel de la fabrication de l'acier. Un contrôle strict de la qualité de la surface est nécessaire lors de la création des produits finaux et il a plus d'importance lorsque ces produits vont être visibles, comme les pièces extérieures de la voiture par exemple. Pour une meilleure compréhension des causes des défauts superficiels, leur flux de fabrication est analysé.

Le processus de fabrication de l'acier moderne est généralement divisé en ces étapes : haut fourneau, fabrication d'acier primaire et secondaire, coulée de billettes et laminage à chaud ou à froid. Au cours de ce processus, plusieurs défauts peuvent apparaître tels que : des fissures (Cr), des piqûres (Ps), des taches (Pa), des inclusions (In), des rayures (Sc), des écailles (Rs), oxydation (Ox).

Les défauts sont encore plus critiques lorsque les produits manufacturés sont utilisés comme pièce mécanique où ces défauts de surface affectent ses performances fonctionnelles, ce qui entraîne une grande perte de temps et d'argent. Pour ces raisons, l'intérêt pour les techniques de détection et de classification des défauts superficiels est croissant.

Les systèmes de vision industrielle sont couramment utilisés dans les zones de production industrielle pour contrôler les produits de manière rapide, automatique, sans contact et très précise. Les nouvelles techniques d'apprentissage automatique, telles que l'apprentissage en profondeur, deviennent de plus en plus populaires pour cette tâche car elles peuvent capturer des situations larges et variables.

Dans ce travail, une nouvelle méthode basée sur l'apprentissage en profondeur (DL) est proposée pour la classification des défauts sur les surfaces en acier. Nous visons aussi à analyser le comportement des réseaux de neurones convolutifs pour la classification d'images en construisant un modèle avec une seule architecture et en appliquant ce modèle aux défauts de surface NEU basés sur des images [1].

2. Organisation du mémoire :

Notre travail est divisé en trois chapitres :

- Dans le premier chapitre, nous présentons le procédé de laminage et les différents défauts créés par ce dernier procédé.
- Le deuxième chapitre est consacré à la description des réseaux de neurones convolutifs ainsi qu'à leur intérêt dans le domaine de la classification d'images.
- Dans le troisième chapitre nous présentons la partie expérimentale de notre travail et nous discuterons les résultats obtenus et à la fin nous terminerons par une conclusion générale.

Chapitre I

Laminage

I. Introduction

Le fer est un élément très commun dans la nature. Il a une forme de minerai où il est combiné avec d'autres composés tels que divers oxydes, et depuis sa découverte, l'homme a appris à le préparer et à le traiter afin qu'il puisse être fondu pour obtenir de l'acier à usages multiples.

Les produits en acier sont largement utilisés dans de nombreux domaines tels que Centrales nucléaires, industries automobile et aérospatiale...etc. Alors n'importe qui Quels défauts des produits sidérurgiques peuvent être dangereux pour l'homme dans environnement de travail, cela peut également entraîner la perte d'équipements ainsi que perte de niveau de production. Pour ces raisons, le contrôle de la qualité des produits La sidérurgie est devenue un axe fondamental de développement et de recherche industrie. L'acier sous ses différentes formes reste le métal le plus utilisé et représente 95% des métaux mondialement produits.

Ce chapitre est donné sur les processus de laminage de l'acier pour la fabrication du produit plat qui est destiné aux différentes industries de transformation, et des défauts créés suite à ce procédé.

I.1.Procédé de Laminage

I.1.1. Matière première des laminoirs (L'acier)

La matière première utilisée dans les laminoirs pour produire de l'acier est généralement appelée "lingot" ou "brame". Voici les étapes principales du processus de fabrication de l'acier :

Extraction du minerai de fer : Le minerai de fer est extrait de mines à ciel ouvert ou souterraines.

Préparation du minerai : Le minerai de fer extrait est broyé en fines particules et concentré par divers procédés. Cela permet de séparer le minerai de fer des impuretés indésirables.

Réduction du minerai : Le minerai de fer concentré est ensuite réduit dans un haut fourneau, où il est chauffé à des températures élevées. Cette réaction chimique permet de réduire le minerai de fer en fer liquide, appelé "fonte".

Affinage de la fonte : La fonte obtenue à partir du haut fourneau contient généralement des impuretés telles que le carbone, le silicium, le soufre et le phosphore. Pour obtenir de l'acier de qualité, la fonte est affinée dans des convertisseurs.

Coulée continue : Une fois que la fonte a été affinée, elle est coulée en brames ou lingots dans une machine appelée "coulée continue".

Laminoir : Les brames ou lingots sont chauffés à haute température dans un four de réchauffage et ensuite envoyés dans le laminoir. Dans le laminoir, les brames ou lingots sont acheminés entre des cylindres lisses ou rainurés qui les compriment et les façonnent progressivement en feuilles, plaques, barres, fils ou autres formes d'acier.

Finition : Une fois que les produits d'acier ont été formés dans le laminoir, ils peuvent subir d'autres processus tels que le refroidissement contrôlé, le redressement, le traitement thermique, le revêtement, la découpe ou le pliage, en fonction de l'application finale de l'acier [2].

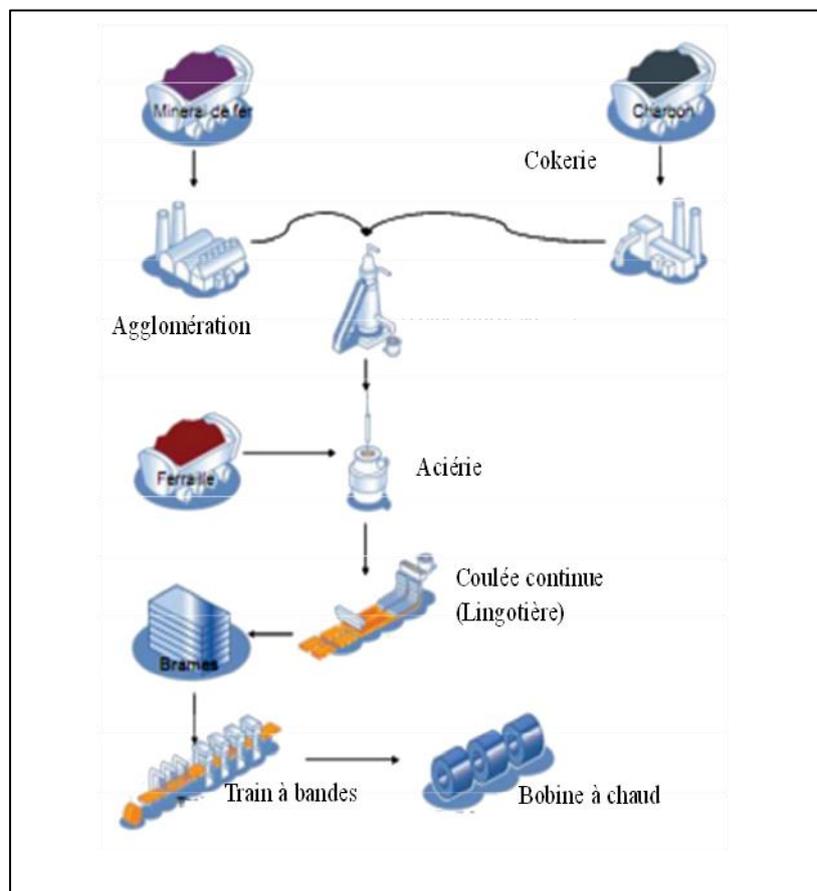


Figure I. 1 : Schéma simplifié du processus sidérurgique, filière fonte.

I.1.2. Le Laminage

Le laminage est une méthode de production de métaux par déformation plastique, largement utilisée pour divers matériaux métalliques, en particulier les aciers. Les produits obtenus grâce au laminage sont utilisés dans l'industrie automobile, l'électroménager, l'emballage alimentaire, etc.

L'objectif du laminage est de réduire la section d'un produit de grande longueur pour le rendre adapté à diverses utilisations. Cette méthode de fabrication par déformation plastique est applicable à différents matériaux tels que les métaux ou tout autre matériau sous forme pâteuse comme le papier ou les pâtes alimentaires [3].



Figure I. 2 : Procédé de laminage

I.1.3. Principe de laminage

Le processus de laminage est l'un des plus importants dans la fabrication de divers produits en métal. Il est utilisé pour déformer plastiquement un volume de matériau plus grand que ceux traités par n'importe quelle autre technique. Ce processus implique de faire passer un métal entre deux cylindres tournant en sens inverse.

Le laminage commence à chaud lorsqu'un produit de forte section doit être travaillé, ce qui nécessite une forte puissance de déformation pour assurer la rentabilité des opérations de coulée.

Chauffer le métal pour le ramollir permet de réduire ces puissances et la taille des installations nécessaires tout en conférant la ductilité nécessaire pour les très grandes déformations à réaliser.

De nombreux produits, tels que les produits longs, les tôles épaisses et les bandes à chaud, ne subissent qu'un laminage à chaud, puis des opérations de finition telles que le traitement thermique, le dressage, le décapage, le revêtement et l'usinage. En général, le passage à des opérations à froid est nécessaire pour obtenir des propriétés mécaniques élevées par écrouissage et un bon état de surface. Les bandes minces sont les seules à être pratiquement laminées à froid.

Le laminage des tôles et des produits plats en acier est assuré par des cylindres dont la table cylindrique lisse est légèrement concave ou convexe. Les profilés en acier courants et spéciaux sont laminés [4].

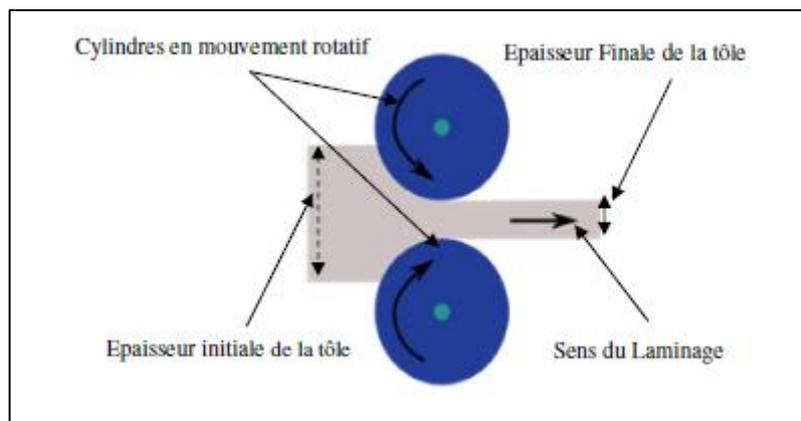


Figure I. 3 : Transformation mécanique en laminage.

I.1.4. La production de laminage

I.1.4.1. Le laminage à chaud :

Le laminage thermomécanique, qui est en réalité un processus mécanique à haute température, est une étape incontournable pour toutes les billettes produites par coulée continue. Ces billettes ont généralement des épaisseurs considérables (25cm) sur plusieurs mètres et peuvent peser jusqu'à 20 tonnes. Cette opération intervient immédiatement après la production d'acier.

Les billettes peuvent être considérées comme un produit intermédiaire : le métal, qui est figé chimiquement lors de sa solidification, n'a pas encore atteint son état final. En effet, ni sa géométrie (largeur, longueur, planéité...), ni sa structure métallurgique et ses propriétés mécaniques ne sont encore définies. Le laminage thermomécanique consiste à réduire l'épaisseur du métal en le faisant passer plusieurs fois entre deux cylindres en rotation opposée. La billette est ainsi amenée à une épaisseur finale de quelques millimètres (1 à 1,5 mm) et est réalisée à une température comprise

entre 1 200°C et 1 300°C. Cette opération est réalisée à chaud pour limiter les efforts de laminage nécessaires pour obtenir la plaque. Ensuite, la plaque est enroulée pour former une bobine.

Par exemple, à partir d'une billette de 10 m de long, 25 cm d'épaisseur et 2 m de large, on peut obtenir une bobine de tôle de plus d'un kilomètre de long et de 2 mm d'épaisseur [5].



Figure I. 4 : laminage à chaud

I.1.4.2. Le laminage à froid :

Le laminage à froid se fait à une température d'environ 100°C. c'est possible A partir d'une tôle préalablement laminée à chaud, l'épaisseur est réduite pour atteindre Une feuille mince avec l'épaisseur requise par le client. Un lot de bobines enroulées pèse moins de 10 tonnes. Le laminage à froid peut produire des tôles minces jusqu'à 0,1 mm Laminoirs indépendants ou multi-passes montés en tandem. Dans cette dernière étape, il faut toujours faire attention à la planéité et aux caractéristiques Mécanique des produits laminés. Les produits laminés peuvent être utilisés de plusieurs façons. Corps Automobiles (tôles d'une épaisseur moyenne de 0,5 à 1 mm), emballages (fer) blanc d'une épaisseur inférieure à 0,2 mm) [6].



Figure I. 5 : laminage à froid

I.2.Problématique de la qualité des produits laminés

I.2.1. Objectifs qualité

L'objectif de qualité des produits laminés est de garantir que les produits finis répondent aux normes et aux attentes des clients en termes de performances, de durabilité et d'apparence. Voici quelques éléments clés qui contribuent à l'objectif de qualité des produits laminés :

Matériaux de haute qualité : Pour obtenir des produits laminés de qualité, il est essentiel d'utiliser des matériaux de haute qualité. Cela comprend à la fois les matériaux de base utilisés pour le laminage et les matériaux d'apprêt ou de revêtement. Des matières premières de qualité garantissent la solidité, la résistance à l'usure et l'aspect esthétique du produit final.

Processus de fabrication précis : Un contrôle rigoureux du processus de fabrication est essentiel pour maintenir la qualité des produits laminés. Cela inclut le contrôle des paramètres tels que la température, la pression, la vitesse de laminage, le temps de traitement, etc. Un suivi strict de ces paramètres garantit des produits laminés uniformes et de haute qualité.

Contrôle de la qualité tout au long du processus : Le contrôle de la qualité doit être effectué à chaque étape du processus de fabrication des produits laminés. Cela implique l'inspection des matières premières, des produits semi-finis et des produits finis pour détecter les défauts potentiels tels que les bulles, les fissures, les déformations, les défauts d'adhérence, etc. Les tests de laboratoire et les essais de performance sont également utilisés pour s'assurer que les produits répondent aux spécifications requises.

Formation et compétences des travailleurs : La formation adéquate des opérateurs et des travailleurs impliqués dans le processus de fabrication est essentielle pour maintenir la qualité des produits laminés. Ils doivent être formés aux bonnes pratiques de fabrication, à la manipulation des équipements, à l'identification des défauts et à la mise en œuvre des mesures correctives. Des compétences solides contribuent à réduire les erreurs humaines et à garantir des produits laminés de qualité supérieure.

En mettant en œuvre ces mesures et en accordant une attention particulière à la qualité à chaque étape du processus, il est possible de produire des produits laminés de haute qualité qui satisfont les clients et qui répondent aux exigences du marché [7].

I.2.2. Les défauts de fabrication

De l'étape de fusion à la fabrication du produit final, les nombreuses opérations réalisées sur les produits sidérurgiques, telles que la solidification, le refroidissement, la déformation, le traitement thermique et la manutention, peuvent engendrer de nombreux défauts,

I.2.2.1. Défauts de surface

L'expression de six défauts dans la bande acier :

- **Echelle roulée (RS) :** 'Rolled-in scale' Un défaut de calamine laminée se produit lorsque la calamine est laminée dans le métal pendant le processus de laminage. La calamine est le mélange feuilleté d'oxydes de fer qui se forme à la surface de l'acier chaud.
- **Patches (Pa) :** 'Patches' : surface oxydée pas complètement éliminée par un processus de décapage défectueux.
- **Craquelures (Cr) :** 'Crazing' un type de réseau de fissures fines.
- **Surface piquée (PS) :** 'Pitted Surface' fortes dépressions en surface liées à une attaque chimique.
- **Inclusion (In) :** 'Inclusion' particules non métalliques qui transparaissent à la surface de l'acier.
- **Rayures (Sc) :** 'Scratch' forte indentation dans la surface causée par une machine [8].

I.3. Conclusion

Dans le chapitre suivant, nous avons présenté diverses idées en rapport avec notre entreprise. Nous avons explicité la signification de laminage et sa base fondamentale ; exposé les phases de laminage, de même que les imperfections générées suite à cette procédure.

Chapitre II

Les Réseaux de neurones convolutifs

II Introduction

L'intelligence artificielle est vraiment un domaine qui se développe fortement ces derniers temps. De la découverte du visage, aux assistants vocaux, en passant par les véhicules autonomes et les systèmes de conseils d'achat sur Internet et le domaine du traitement, ces nouvelles technologies envahissent notre quotidien. Cette discipline fait appel à des algorithmes inspirés de la structure et du fonctionnement du cerveau, et peut apprendre plusieurs niveaux de représentation pour modéliser des relations complexes entre des données. Dans ce large domaine, un type de méthodes fait plus particulièrement parler de lui : le Deep Learning.

Le deep learning, ou apprentissage profond, par exemple, est la source du succès dans les médias. Le potentiel de ces technologies semble stupéfiant. Le Deep Learning représente une branche récente de la recherche ML, qui vise à la rapprocher de l'objectif final, intelligence artificielle.

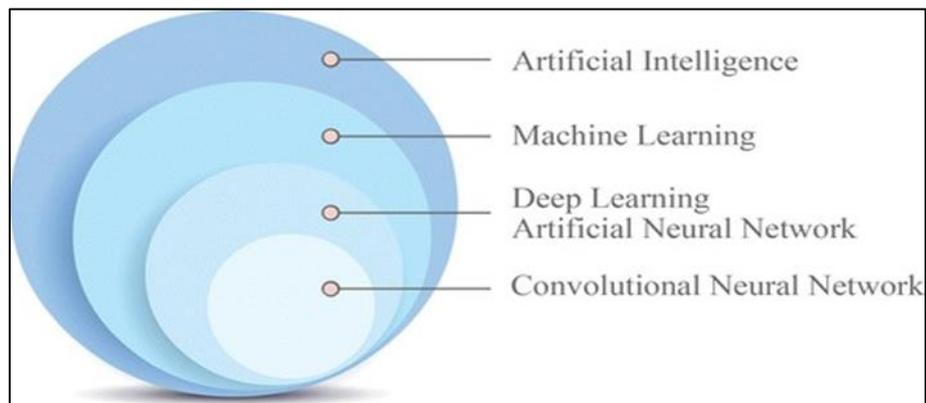


Figure II.1: Intelligence artificielle, machine Learning, Deep Learning et convolution neural network

Le schéma ci-dessus (Figure II.1) évoque les différentes zones de l'évolution l'intelligence artificielle(IA) on arrive au système le plus développé dans ce domaine Convolution Neural Network (CNN) cas de l'application utilisé de notre travail de mémoire, ce chapitre est dédié à la clarification des différents passages de l'apprentissage approfondi arrivant à la représentation de la méthode utilisée pour la réalisation classification des images et du traitement avec les réseaux de neurones convolutives.

II.1. L'IA, Intelligence artificielle

L'intelligence artificielle peut-être définie comme « l'ensemble de techniques permettant à des machines d'accomplir des tâches et de résoudre des problèmes normalement réservés aux humains et à certains animaux », un vaste domaine scientifique qui est apparu fin des années cinquante début des années soixante.

Il s'agit donc de techniques qui visent à reproduire, imiter, simuler l'intelligence, ou en tout cas les capacités que l'on peut associer à ce terme : capacité à percevoir son environnement, à interagir avec lui, à communiquer à l'aide d'un langage, à mettre en œuvre un raisonnement et à résoudre des problèmes, à planifier des actions pour atteindre un but, à représenter la connaissance. Comme mentionné précédemment, le domaine est très vaste et se divise en plusieurs domaines qui incluent les sciences cognitives, les mathématiques, l'électronique et l'informatique[9].

II.2. Machine Learning

L'apprentissage automatique (Machine Learning) est une branche de l'Intelligence Artificielle qui permet aux ordinateurs d'acquérir des connaissances à partir d'un groupe d'observations connu sous le nom d'ensemble d'apprentissage [10].

Voici quelques exemples d'utilisation du ML :

- Vision par ordinateur
- Détection de fraude
- Classification (images, texte, vidéo, son ...)
- Les publicités ciblées
- Diagnostic médical

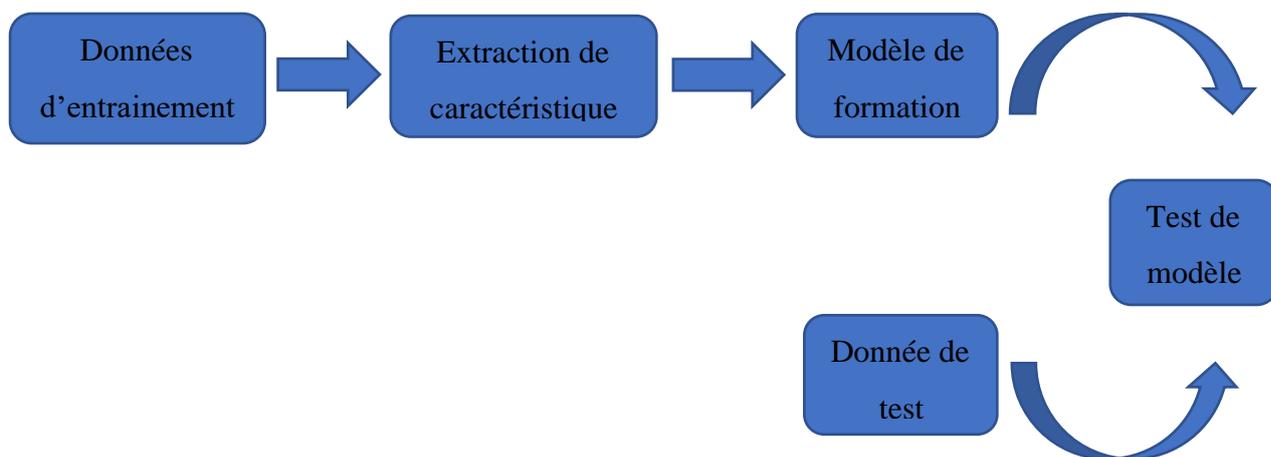


Figure II.2: le processus typique du ML

II.3. Deep Learning

Le Deep Learning peut être vu comme une sous-catégorie des « réseaux de neurones ». En effet, il s’agit d’un ensemble d’outils et de méthodes d’apprentissage automatique basés sur l’utilisation « avancée » de réseaux de neurones. On utilise les mots « deep » ou « profond » en référence au nombre de couches de neurones qui constituent ces réseaux : plus le nombre de couches est grand plus le réseau est profond (Figure II.3) et plus il permet de traiter des problèmes complexes. Les réseaux de neurones « simples », c’est-à-dire de profondeur plus délicate, sont eux nommés « Shallow Networks ».

Il repose sur le principe des réseaux de neurones artificiels et est spécialement conçu pour traiter des volumes importants de données en ajoutant des couches au réseau. Un modèle de Deep Learning peut extraire des caractéristiques à partir de données brutes en passant par plusieurs couches de traitement qui comprennent des transformations linéaires et non linéaires. Il apprend progressivement à partir de ces caractéristiques à travers chaque couche, avec une intervention humaine minimale [11].

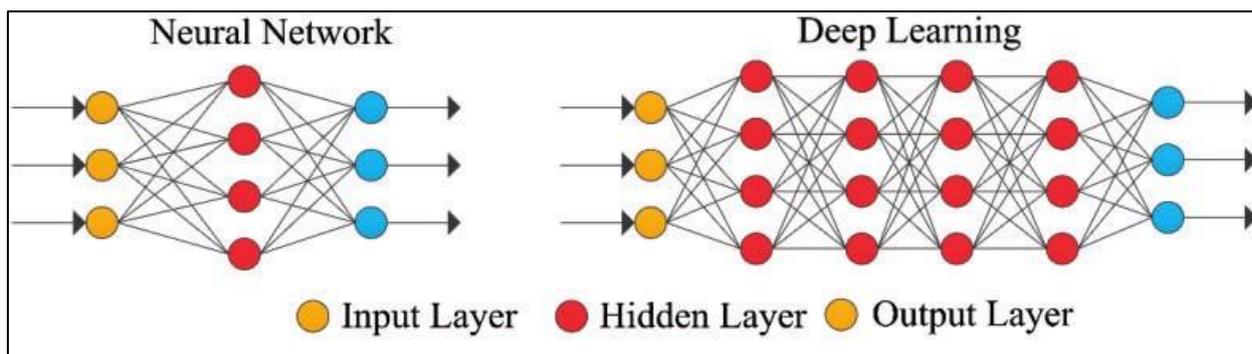


Figure II.3 : a) Réseau de neurones simple

b) Réseau de neurones profond

II.4. Réseaux de neurones convolutifs

II.4.1. Définition

Les réseaux convolutifs sont une forme particulière de réseau neuronal multicouches dont l'architecture des connexions est inspirée de celle du cortex visuel des mammifères, (feed-forward).

Leur conception est basée sur la découverte des mécanismes visuels chez les organismes vivants. Ce sont de loin les modèles les plus efficaces pour la classification des images. Indiqués par l'acronyme CNN, de l'anglais Convolutional Neural Network, ils se composent de deux parties bien distinctes Leur mode de fonctionnement à première vue est très simple : l'entrée utilisateur est une image sous la forme d'une matrice de pixels.

- Il existe en 2 dimensions pour Images bidimensionnelles en niveaux de gris.
- Troisième dimension, a une profondeur de 3 pour représenter les couleurs primaires (Rouge, Vert, Bleu) [12].

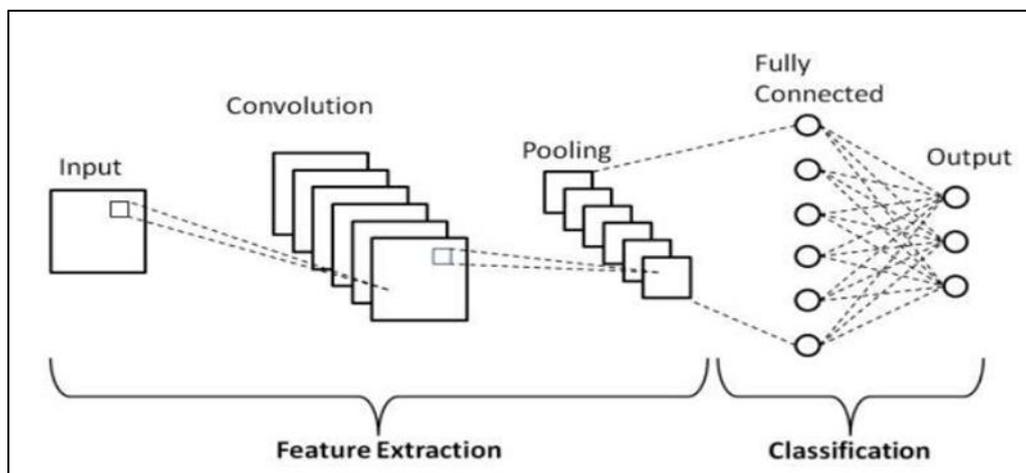


Figure II.4 : Réseau neuronal convolutif

II.4.2. Architecture globale de CNN

Un CNN se compose de plusieurs couches de convolution et (d'agrégation) qui peuvent être suivies de couches entièrement connectées. L'entrée de la couche convolutive est une image de taille $m \times m \times r$ où m est la hauteur et la largeur de l'image et r est le nombre de canaux, par exemple :

Une image RVB avec $r=3$. La couche de convolution aura k filtres (ou noyaux) de taille $n \times n \times q$ où n est inférieur à la taille de l'image et q peut être égal au nombre de canaux r ou moins et peut être différent pour chaque filtre. La taille des filtres donne lieu à une structure localement connectée, dont chacune est combinée avec l'image pour produire k cartes de caractéristiques de taille $m-n + 1$. Ensuite, chaque carte est généralement sous-échantillonnée avec un regroupement moyen ou maximal sur $p \times p$ régions contiguës où p varie entre 2 pour les petites images (par exemple MNIST) et généralement pas supérieur à 5 pour les éléments plus volumineux. Avant ou après la mise en commun [13].

II.4.2.1. Couche convolutive :

C'est la pierre angulaire d'un CNN. Dans la couche convolutive, des opérations de convolution 2D sont effectuées pour l'extraction de caractéristiques dans les images d'entrée. La sortie d'un neurone est obtenue à partir d'une combinaison linéaire des sorties des neurones des couches précédentes, puis le résultat est introduit dans une fonction d'activation non linéaire. Cette couche obtient des valeurs numériques élevées dans les caractéristiques d'image les plus dominantes [14].

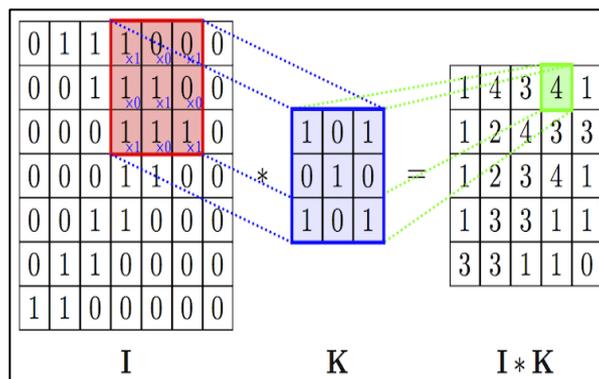


Figure II.5 : exemple de convolution 2D

Le padding :

Il peut être intéressant de garder certaines dimensions dans la taille de l'image de sortie du pli. Le rembourrage agrandit la matrice (image) en ajoutant des zéros autour d'elle.

Par exemple, le remplissage avec 2 dans une matrice 32×32 ajoute des 0 aux 2 colonnes de gauche, aux 2 colonnes de droite, aux 2 premières lignes et aux 2 dernières lignes.

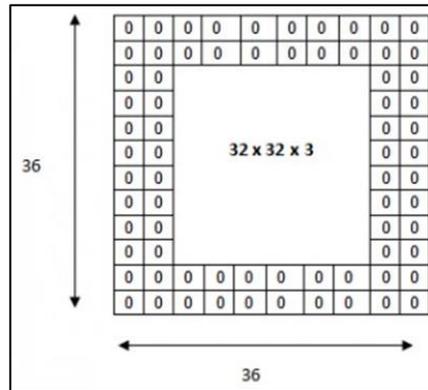


Figure II.6 : Le padding

Le pas (stride) :

Il contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs du récepteur se chevauchent et plus le volume de sortie est élevé.

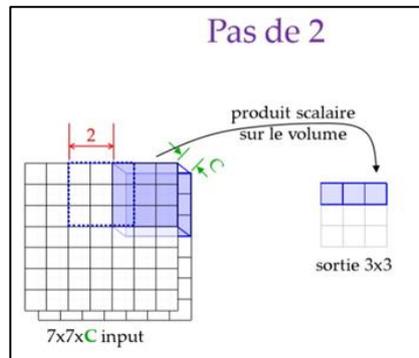


Figure II.7 : pas de 2

La formule de calcul du nombre de neurones du volume de sortie est :

$$wO = \frac{Wi - K + 2P}{s} + 1$$

II.4.2.2. La couche de correction ReLU :

Le but de cette couche est d'introduire la non-linéarité. Dans le même temps, ReLU a de bonnes propriétés de parcimonie, tout en limitant la saturation de la sortie et la diffusion du gradient pendant le processus d'apprentissage. D'autres fonctions telles que tanh ou sigmoïde peuvent également être utilisées. Cependant, ReLU obtient généralement de meilleurs résultats [15].

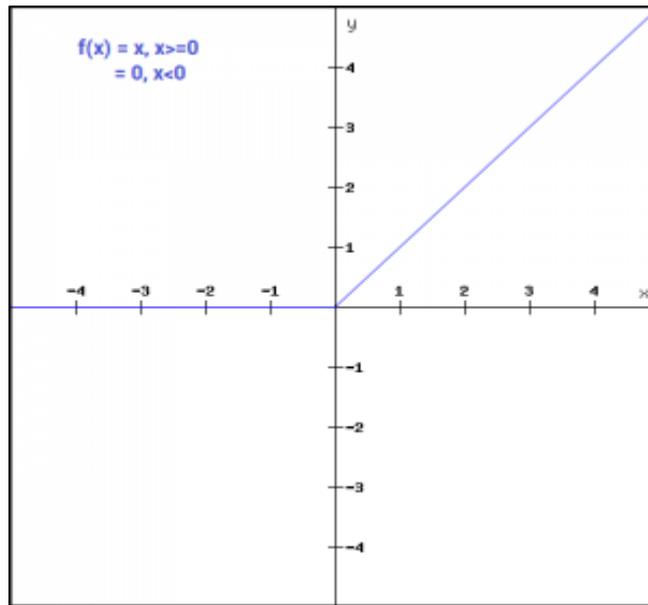


Figure II.8 : courbe la fonction ReLU

- La fonction d'activation : Non Linearity ReLU (Rectified Linear Units) ReLU :

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

- La correction par tangente hyperbolique :

$$f(x) = \tanh(x) = \frac{(1 - e^{-2x})}{(1 + e^{-2x})}$$

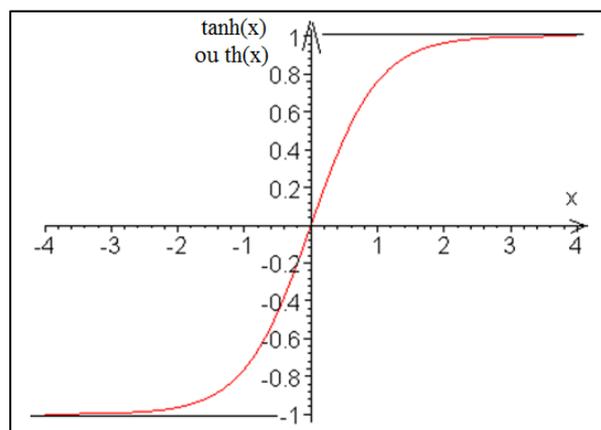


Figure II.9 : courbes la fonction de tangente hyperbolique

- La correction par la fonction sigmoïde :

$$F(x) = \frac{1}{(1 + e^{-x})}$$

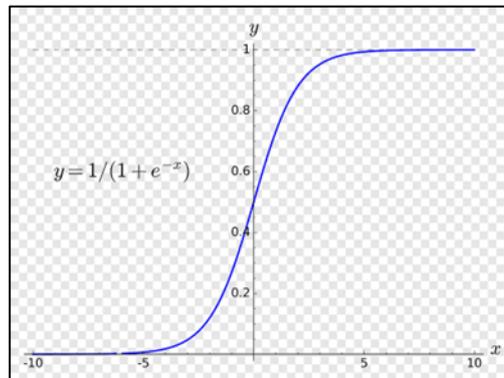


Figure II.10 : courbes la fonction sigmoïd

II.4.2.3. Couche de pooling :

Le pooling est une spécialité des réseaux de neurones convolutifs. Les deux manières les plus courantes d'appliquer cette opération sont les suivantes : Faire la moyenne des valeurs de zone (Pooling Average) ou extraire uniquement la valeur la plus élevée (Pooling Max). Sa fonction est de réduire progressivement la taille spatiale de la représentation afin de réduire le nombre de paramètres et de calculs dans le réseau sans perdre les informations les plus importantes, contrôlant ainsi également le surajustement. Le principal avantage de Pooling Average est qu'il est utile lorsque nous voulons détecter des signaux faibles, comme dans l'analyse des crêtes. La mise en commun maximale est efficace pour détecter des signaux forts, tels que des objets, et peut également rendre le modèle invariant aux transformations [16].

Exemple de max pooling :

Un exemple d'opération max pooling est donné par la figure suivante :

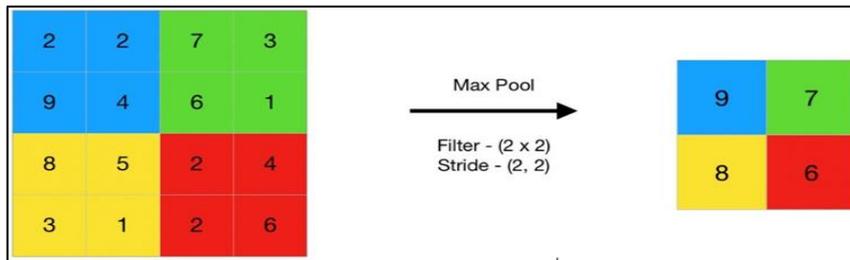


Figure II.11 : Exemple Maxpooling

Exemple de averagepooling :

Un deuxième exemple d'opération averagepooling est donné par la figure suivante :

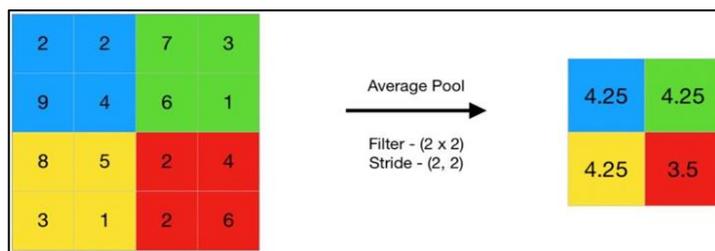


Figure II.12 : Exemple Average pooling

II.4.2.4. Couche entièrement connectée (FC) :

Après de multiples strates de convolution et de max-pooling, le niveau de raisonnement supérieur dans le réseau neuronal est accompli par le biais de couches entièrement connectées (fully connected layers). La couche entièrement connectée est nommée ainsi car elle est connectée intégralement à la sortie de la strate antérieure. Ces strates sont couramment employées dans les étapes ultimes du CNN pour établir une connexion avec la couche de sortie et produire le nombre désiré de résultats [17].

La fonction softmax :

Softmax est une fonction d'activation dédiée aux réseaux de classificateurs codés en un N. Il effectue une exponentielle normalisée (c'est-à-dire des sommes de sorties de sommes). Combiné avec la fonction d'erreur d'entropie croisée, il permet de modifier les réseaux de perceptrons multicouches pour estimer la probabilité de classe.

La fonction Softmax est définie par l'équation suivante :

$$\sigma(Z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \quad \text{For } j = 1, \dots, K$$

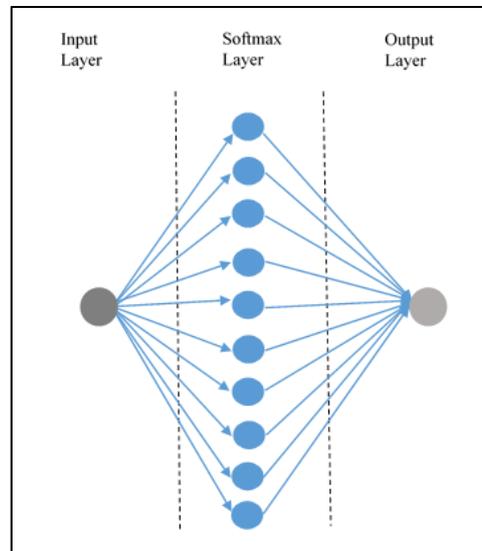


Figure II.13 : La fonction softmax.

II.4.3. Choix des paramètres

Les CNNs utilisent plus de paramètres qu'un MLP standard. 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 diminuent 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.

Taille du filtre : Comme la taille des images intermédiaires diminuent 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. Ils sont généralement choisis en fonction de l'ensemble de données.

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 [18].

Forme de pooling : Les valeurs typiques sont 2x2. 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.

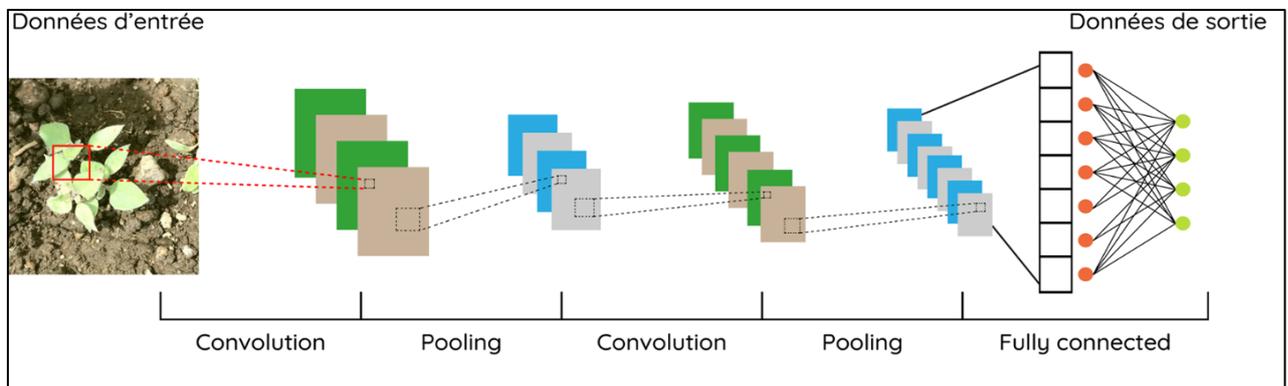


Figure II.14 : Un réseau de neurones convolutif

II.4.4. Avantages des réseaux de neurones convolutifs

Auto-apprentissage : C'est la principale caractéristique et l'avantage des réseaux de neurones artificiels, qui sont très populaires parmi les programmeurs et les hommes d'affaires du monde entier. Créez un algorithme de base, donnez un exemple pour l'entraîner (par exemple, une photo d'une personne si vous voulez que le réseau de neurones trouve des personnes sur une photo), et voyez les résultats. Dans le même temps, les algorithmes eux-mêmes décident comment atteindre l'objectif souhaité, trouvant souvent des solutions qui ne sont pas évidentes (pour les humains).

De plus, les réseaux de neurones sont conçus non seulement pour s'auto-apprendre, mais aussi pour s'auto-apprendre continuellement et améliorer leurs résultats. Une fois le système formé, l'utilisation de n'importe quel programme ou application deviendra plus facile à utiliser. C'est pourquoi les systèmes de recommandation Google Translate, Netflix ou TikTok s'améliorent chaque année.

Vitesse de travail : Un autre avantage clé des réseaux de neurones est leur vitesse incroyable, à la fois par rapport aux algorithmes informatiques traditionnels et par rapport au cerveau humain. Les réseaux de neurones artificiels ne se fatiguent pas et il n'y a pas de pause déjeuner. Leur vitesse de travail n'est déterminée que par la puissance de calcul dont ils disposent (carte

graphique, serveur cloud ou centre de données). Cela signifie généralement qu'ils fournissent une solution presque immédiatement [19].

II.4.5. Exemples d'architecture CNN

- AlexNet
- GoogLeNet
- LeNet
- ZFnet
- ResNet

II.5. Conclusion

Au cours de ce chapitre, nous avons amorcé une présentation des réseaux de neurones profonds afin de mieux appréhender les réseaux de neurones convolutifs et leur mode de fonctionnement. Nous avons également exposé leurs bénéfices majeurs et clôturé cette section en exposant quelques exemples de réseaux convolutifs connus. Dans le prochain chapitre, nous soumettrons notre propre modèle et procéderons ensuite à l'analyse et à l'évaluation des résultats obtenus durant les phases d'apprentissage et de test, avant de les examiner et de les critiquer.

Chapitre III

Implémentation

III.1. Introduction

Dans ce chapitre, nous allons implémenter une méthode basée sur les réseaux de neurones convolutifs pour la classification des défauts des bandes en acier. La première phase est de construire l'architecture du modèle et l'entraînement de ce dernier. Dans cette phase nous avons utilisé la base de données de défauts de surface NEU [20] pour simuler à l'aide du logiciel Matlab l'apprentissage du modèle. Ce modèle présente des six types de classes. Par la suite, une deuxième phase sera consacrée à la validation du modèle pour la classification des défauts.

III.2. Méthodologie de diagnostic proposée

Un système de reconnaissance d'images a été conçu pour la classification des défauts à partir de la base de données NEU. Cette base de données sera décrite dans la section suivante.

Les principales phases et étapes de notre méthode peuvent être résumées par (la figure III .1 et III.2).

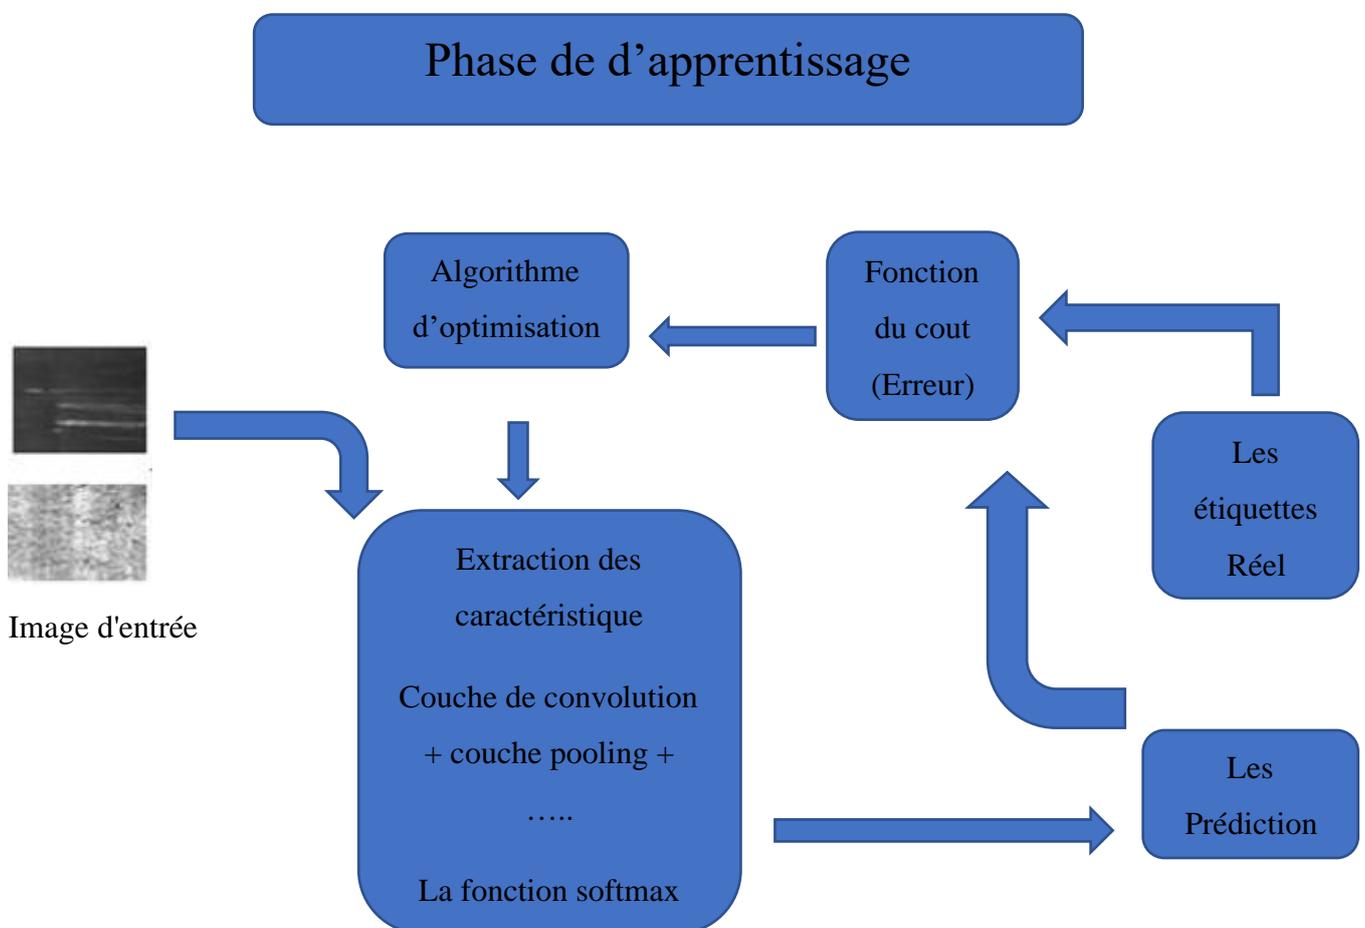


Figure III.1 : Phase d'apprentissage

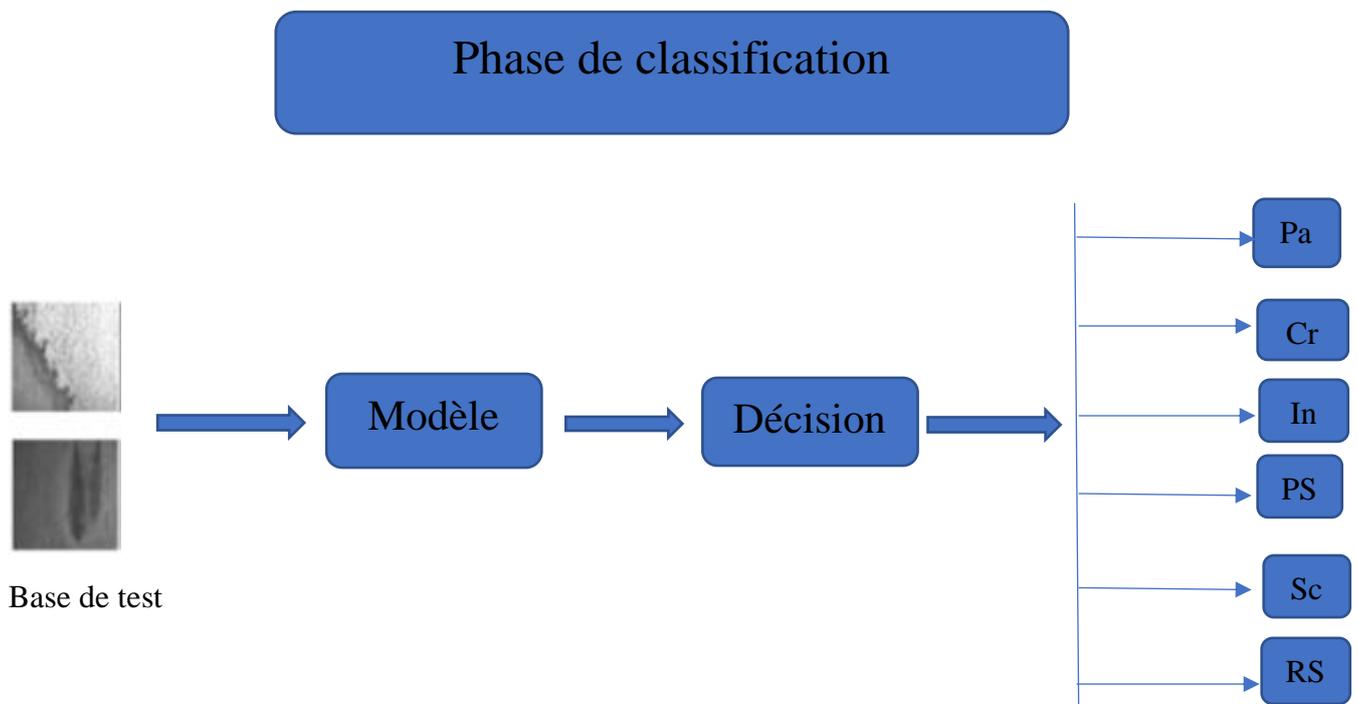


Figure III.2 : Phase de classification

III.3. Description de la base de données

Pour l'application de l'approche proposée et son évaluation, la base d'images de défauts de "NothEastern University: NEU[20], illustré à la (figure III.3), a été employée. Elle est composée d'images en niveau de gris représentant six types de défauts, parmi les plus fréquents en processus de laminage à chaud, et avec 300 variantes de chaque défaut.

Les échantillons présentés concernent les défauts suivants : : « Voir la description de défaut surface sur le chapitre I ».

1. Cr : Crazing.
2. In : Inclusion.
3. Pa : Patches.
4. PS : Pitted Surface.
5. RS : Rolled in Scale.
6. Sc : Scratches.

Les images acquises avec une taille d'image de 1024x1024, et réduites à 200x200 pixels, (Figure III.3), comportent plusieurs variabilités, telles que l'orientation, la taille et le niveau

d'intensité qui peut être le résultat d'un éclairage hétérogène en milieu industriel. Le nombre et types de défauts, ainsi que leurs variantes, font de ces images une base de données très représentative du résultat de l'interaction de la machine de production (laminoir) et la matière première en entrée (brame).

Ainsi, ces défauts de surface peuvent être, comme montrés sur la figure ci-dessus, d'apparence compacte et localisés sur la surface du métal, avec des bords relativement marqués, tels que les défauts de calamine et griffes, ou minuscules, dispersés et affectant la surface entière, tels que les piqûres ou les fissures. Etant donné cet aspect hétérogène, l'image entière est considérée comme étant une zone d'intérêt. Il n'a pas été jugé nécessaire, ni de réduire davantage la taille des images, ni de supprimer de quelconques zones de l'image, supposées inutiles. Dans notre application, la taille de 200x200 des images représente un bon compromis l'entre la quantité d'information et les temps de réponse. Avec ces propriétés, elle représente, également, une bonne base de comparaison. Le tableau 1 discret la base de données citez dans notre travail.

Tableau III.1 : Description d'ensemble des données

Description de la classe	Nombre d'échantillons	Dimension
Crazing	300	200x200
Inclusion	300	200x200
Patches	300	200x200
Pitted Surface	300	200x200
Rolled in Scale	300	200x200
Scraches	300	200x200

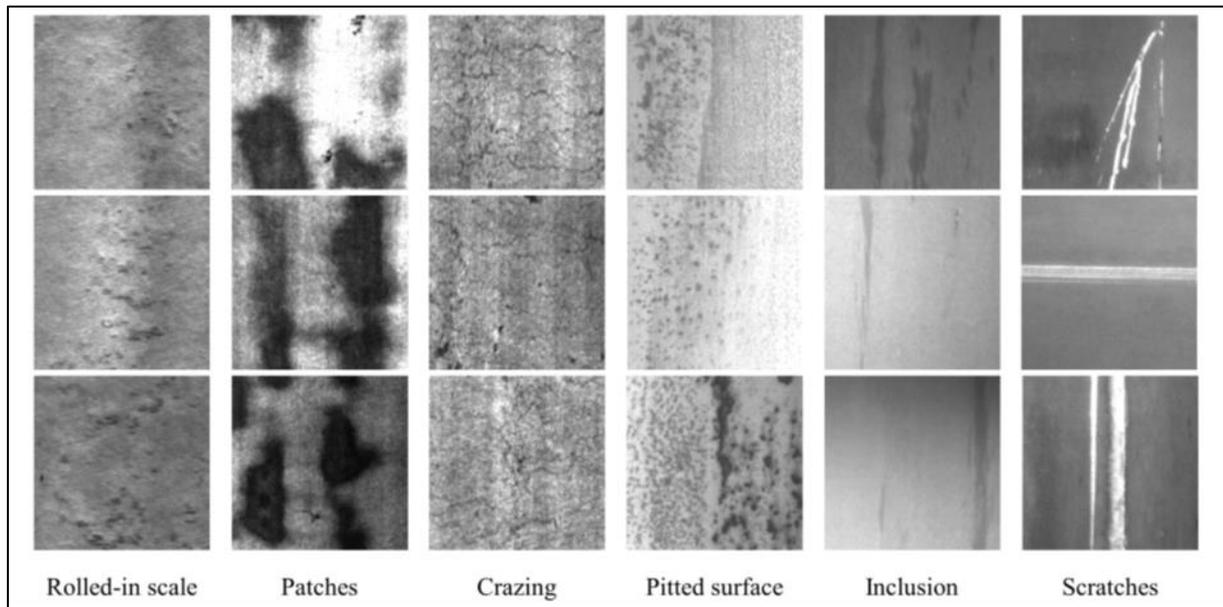


Figure III.3 : Exemples de catégories d'images de défauts de surface

III.4. Architecture de la méthode proposé CNN

Au cours de nos expériences, nous avons créé un modèle avec une seul architecture.

III.4.1. Architecture du modèle

Le CNN qui a été utilisé pour la classification avait 3 couches convolutives. Les première et deuxième couches convolutives avaient 32 filtres de taille 3x3 tandis que la troisième couche convolutive avait 32 filtres de taille 3x3. La fonction d'activation de l'unité linéaire rectifiée (ReLU) a été utilisée pour toutes les couches. La couche entièrement connectée comptait 256 neurones. Le modèle a été entraîné pour des images en couleur au niveau gris. Dans le CNN, l'optimiseur Adam est utilisé avec l'entropie croisée softmax avec les logs comme fonction de coût. L'optimiseur avait un taux d'apprentissage de 0,0001. Pour la formation et la validation, une répartition train-test de 1440 images pour l'apprentissage (80%) et 360 images pour la validation (20%) ,1800 images respectivement a été utilisée tout en gardant les classes équilibrées. Pendant la période de test, le même ensemble de validation a été utilisé pour toutes les expériences. Les données sont constituées de 6 classes avec la cartographie : Cr : 1, In 2, PS : 3, Pa : 4, RS : 5, Sc : 6 qui a été utilisée pour la classification. L'apprentissage du modèle s'est fait par lots de taille 150 pour 20 époques.

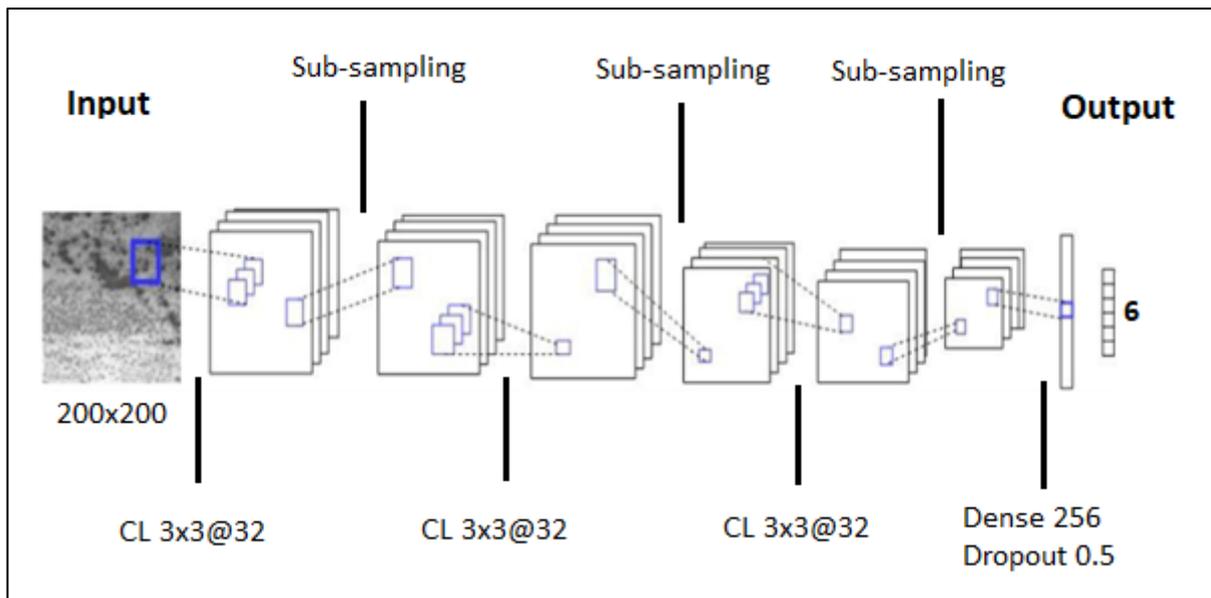


Figure III.4 : Architecture du modèle

III.5. Résultats obtenus et discussion

Les résultats obtenus montrent le taux de précision moyen obtenu, après 180 itérations, est égal à 89.72 %, tandis que le taux de perte atteint 0.31 %. Ces résultats sont illustrés dans les figures III.5 et III.6 %. Ces résultats montrent que les performances obtenues de la méthode proposée sont appréciables et prometteuses.

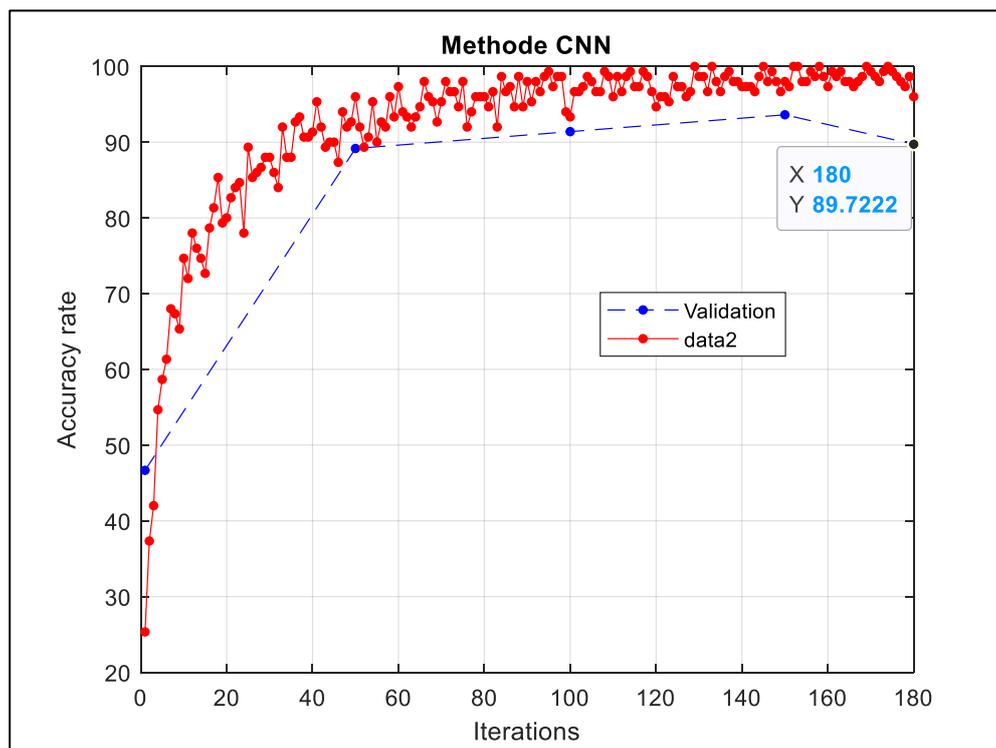


Figure III.5 : Courbes de précision de formation et de validation de la méthode CNN

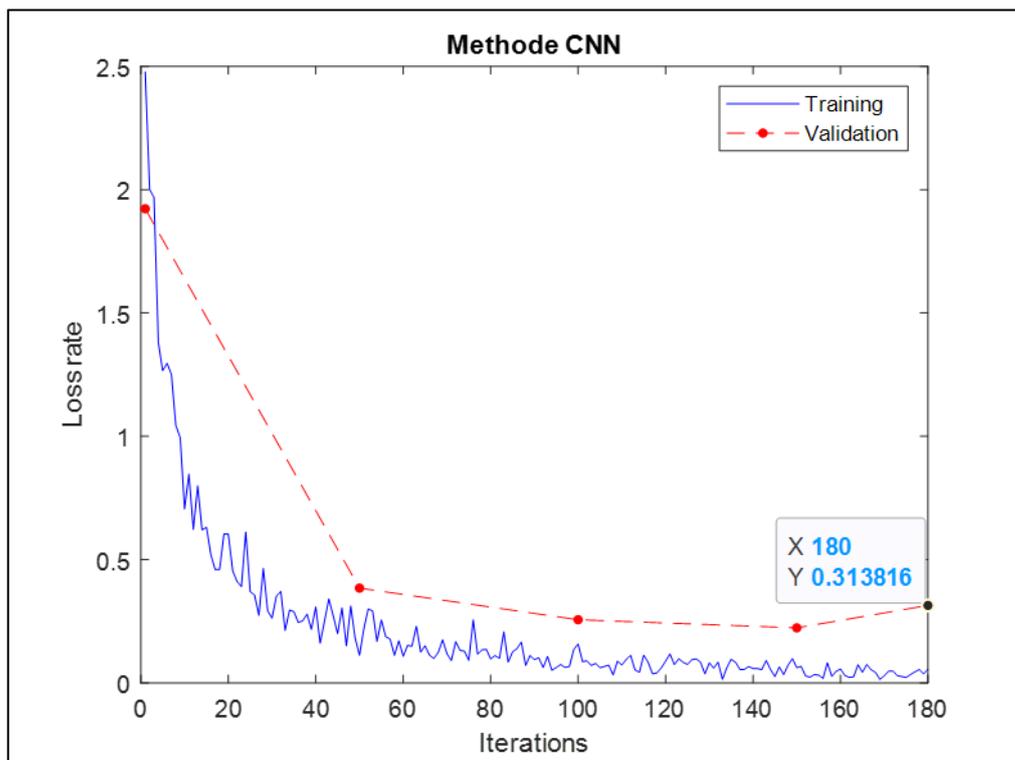


Figure III.6 : Courbes de perte de formation et de validation de la méthode CNN

III.6. Conclusion

Dans cette partie, nous avons présenté une méthode de classification basée sur l'utilisation de réseaux de neurones convolutifs. Pour ce faire, nous avons proposé un modèle et exploré les performances de ce modèle. En conclusion, nous pouvons dire que ce modèle a présenté de bons résultats, ce qui est très prometteur pour d'autres applications.

III.7. Conclusion générale

Les réseaux de neurones convolutifs, également connus sous le nom de CNN (Convolutional Neural Network) en anglais, sont largement reconnus comme les modèles de classification les plus performants pour l'analyse et la détection d'images.

Pour parvenir à ces résultats, nous avons consacré un temps considérable à la lecture et à l'étude de publications et d'articles, afin de nous familiariser avec les avancées les plus récentes en matière de classification, et de pouvoir concevoir notre propre modèle.

Il est important de noter que la définition des paramètres du réseau est une tâche complexe qui ne peut être établie a priori.

Bibliographies

- [1] Zarifian, Philippe. Qualification collective et automatisation : Le cas de la sidérurgie. Formation Emploi, 1983, vol. 1, no 1, p. 37-51.
- [2] Hennous, R. (2022). *Elaboration et étude des propriétés de l'acier de l'entreprise (AQS)* (Doctoral dissertation, université de jijel).
- [3] Amara Korba, H. E. (2019). *Le Laminage Contrôlé (Précipitation-Calamine)* (Doctoral dissertation, Ecole Nationale Supérieure des Mines et de la Métallurgie. Amar Laskri. Annaba).
- [4] Frémont, C. (1908). Origine du laminoir. *Revue de métallurgie*, 5(8), 505-508.
- [5] Et, Microaillie au Niobium. Mécaniques de l'acier.
- Berruti, U., Michelucci, S., et Odone, G. Phénomènes structuraux liés au laminage à chaud des tôles en acier effervescent. *Revue de Métallurgie*, 1960, vol. 57, no 11, p. 1019-1031.
- [6] Gascuel, L. Laminage à froid et traitement des feuillards en acier. *La Pratique des Industries Mécaniques*, 1951, vol. 34, no 5, p. 131-137.
- [7] (1) - Yun (I.S.), Wilson (W.R.D.), Ehmann (K.F.) - Review of chatter studies in cold rolling. - *Int. J. Mach. Tools & Manuf.* 38 (1998), 1499-1530.
- [8] Mentouri, Zoheir. *Détection et Identification des défauts de surface des produits plats dans les processus de laminage par vision artificielle et algorithmes intelligents*. 2018. Thèse de doctorat.
- [9] Paster, Dominique. *L'intelligence artificielle définition - Généralistes -Historique -Domaine*. 2000.
- [10] BEAM, Andrew L. et Kohane, Isaac S. Big data and machine learning in health care. *Jama*, 2018, vol. 319, no 13, p. 1317-1318.
- [11] RAVÌ, Daniele, Wong, Charence, Deligianni, Fani, *et al.* Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 2016, vol. 21, no 1, p. 4-21.
- [12] https://fr.wikipedia.org/wiki/R%C3%A9seau_de_neurones_artificiels/
- [13] Kalfaoglu, M. Esat, Kalkan, Sinan, et Alatan, A. Aydin. Late temporal modeling in 3d cnn architectures with bert for action recognition. In: *Computer Vision—ECCV 2020 Workshops: Glasgow, UK, August 23–28, 2020, Proceedings, Part V 16*. Springer International Publishing, 2020. p. 731-747.
- [14] Akodad, Sara, Bombrun, Lionel, Berthoumieu, Yannick, et al. Modèle d'ensemble d'apprentissage profond basé sur la représentation au second ordre de descripteurs multi-couches d'un CNN.
- [15] <https://datascientest.com/convolutional-neural-network>
- [16] <https://datascientest.com/convolutional-neural-network>
- [17] <https://datascientest.com/convolutional-neural-network>

[18] Sofie Tilborghs, Jan Bogaert, Frederik Maes, October 2022, 102533, Shape constrained CNN for segmentation guided prediction of myocardial shape and pose parameters in cardiac MRI

[19] Gendrot, Cédric, Ferragne, Emmanuel, et Chanclu, Anaïs. Analyse phonétique de la variation inter-locuteurs au moyen de réseaux de neurones convolutifs : voyelles seules et séquences courtes de parole. In : Journées d'étude de la parole 2022 (JEP 2022). 2022.

[20] http://faculty.neu.edu.cn/yunhyan/NEU_surface_defect_database.html