

الجمهورية الجزائرية الديمقراطية الشعبية  
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي  
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البلدية  
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا  
Faculté de Technologie

قسم الإلكترونيك  
Département d'Electronique



# Mémoire de Projet de Fin d'Études

Présenté par

Beghdad Rania

Pour l'obtention du diplôme de Master en Electronique

Spécialité : Electronique des Systèmes Embarqués

## Thème

**Utilisation du Deep Learning pour la détection des défauts de soudure sur des images de radiographie de joints soudés**

**Promoteur:** Mr. KABIR Yacine

**Président:** Mme N.Boughrira

**Examineur:** Mme Z.Reguieg

Année Universitaire : 2022-2023

## Résumé

Cette thèse vise à tester plusieurs modèles basés sur des réseaux neuronaux convolutionnels pour analyser et détecter plusieurs défauts dans des joints soudés à partir d'images radiographiques. Différentes architectures de réseaux neuronaux convolutionnels seront construites, entraînées et testées sur une base de données comprenant des classes de défauts ainsi qu'une classe sans défaut. L'objectif est d'identifier l'architecture la plus efficace pour prédire plusieurs défauts.

Mots Clés : intelligence artificielle, CNN, images radiographiques, défauts de joints soudés, classification, automatisation, détection, précision.

## Abstract

This thesis aims to test several models based on convolutional neural networks to analyze and detect multiple defects in welded joints from radiographic images. Different architectures of convolutional neural networks will be built, trained, and tested on a database consisting of defect classes and a defect-free class. The goal is to identify the most effective architecture for predicting multiple defects.

Keywords: artificial intelligence, CNN, radiographic images, weld joint defects, classification, automation, detection, accuracy.

## ملخص

هذه الرسالة العلمية تهدف إلى اختبار عدة نماذج مبنية على شبكات عصبية تناقلية لتحليل وكشف العيوب المتعددة الموجودة في الوصلات الملحومة من خلال الصور الشعاعية. سيتم بناء هندسات مختلفة للشبكات العصبية التناقلية، وتدريبها، واختبارها على قاعدة بيانات تتضمن فئات العيوب وفئة خالية من العيوب. الهدف هو تحديد أكثر الهندسات فاعلية للتنبؤ بالعيوب المتعددة.

الكلمات المفتاحية: الذكاء الاصطناعي، شبكات الأعصاب المرتبطة بالتصوير العصبي، الصور الشعاعية، عيوب الوصلات الملحومة، التصنيف، التحكم التلقائي، الكشف، الدقة.

## ***Dédicace***

*À ma mère, avec toute mon affection,*

*À mon père, avec toute ma reconnaissance,*

*À ma sœur,*

*À mes frères,*

*À ma famille,*

*Et à tous mes amis.*

## Remerciements

Tout d'abord, je tiens à remercier Dieu pour tout le savoir que j'ai acquis. Je profite également de cette occasion pour adresser mes sincères remerciements à mon promoteur, Monsieur Kabir Yacine, qui m'a fait bénéficier de ses conseils et de ses connaissances. Il n'a ménagé aucun effort pour que ce mémoire puisse voir le jour. Je lui exprime ma gratitude de m'avoir dirigé, encouragé et surtout aidé à réaliser ce travail, soulignant ainsi l'intérêt constant qu'il porte à mon travail. Je le remercie pour la confiance qu'il a eue en moi, sa patience et sa disponibilité à chaque fois que j'avais besoin de lui.

Je tiens à remercier tous les membres du jury.

Je souhaite également exprimer ma reconnaissance à notre chef de spécialité, Mme Naceur Djamila, pour nous avoir accueillis dans la spécialité "électronique des systèmes embarqués". Sa confiance en mon potentiel m'a motivé à donner le meilleur de moi-même.

Je remercie enfin tous les enseignants du cycle Licence et Master, ainsi que toutes les personnes qui nous ont soutenus de près ou de loin dans la réalisation de ce travail.

J'adresse mes remerciements à l'ensemble du cadre administratif du département de génie électrique. Je tiens à remercier tous ceux qui ont contribué à l'aboutissement de ce travail, ainsi que toute la promotion "Électronique des systèmes embarqués" 2022/2023.

# Table des matières

## Contents

Introduction générale.....	11
Chapitre 1 : Contrôle de soudure par radiographie et système de vision par ordinateur ...	13
État de l'art .....	13
Introduction.....	15
1.1 Contrôle non destructif par radiographie .....	15
1.1.1 Aperçu sur le soudage, les défauts de soudures et le contrôle non destructif .....	15
1.1.2 Principe de la radiographie .....	19
1.1.3 Atténuation des rayons X et gamma : .....	22
1.1.4 Application de la radiographie à l'examen des soudures .....	24
1.1.5 Mode opératoire de la radiographie par rayons X ou gamma .....	25
1.1.6 Considérations liées à la qualité de l'image radiographique.....	26
1.1.7 Interprétation des radiographies de soudures.....	28
1.2 Système de vision par ordinateur dédié à la radiographie .....	30
1.2.1 Introduction.....	30
1.2.2 Schéma général du système de vision des radiogrammes.....	31
1.2.3 La numérisation des images radiographiques .....	33
1.2.4 Prétraitement.....	34
1.2.5 Segmentation, extraction de caractéristiques et interprétation.....	36
1.3. Conclusion.....	37
Chapitre 2: Généralité sur Les réseaux de neurones (Les réseaux de neurones convolutifs CNN) .....	39
2.1. Introduction .....	39

2.2. L'intelligence artificielle (IA) .....	39
2.2.1. Les origines de l'intelligence artificielle.....	40
2.2.2. L'importance de l'intelligence artificielle .....	40
2.2.3. Les applications de l'IA .....	41
2.3. Le Machine Learning .....	42
2.3.1. Définition du Machine Learning.....	42
2.3.2. Fonctionnement du Machine Learning .....	43
2.3.3. Les différents types d'algorithmes de Machine Learning .....	43
2.3.4. L'utilité du Machine Learning .....	46
2.4. Introduction au Deep Learning .....	47
2.4.1. Définition du Deep Learning.....	47
2.4.2. Domaine d'application .....	48
2.5. Les Réseaux de neurones .....	49
2.5.1. Principe de Fonctionnement des réseaux de neurones.....	51
2.5.2. Les principaux composants du réseau de neurones .....	52
2.5.3. Le perceptron.....	54
2.5.4. Les différents types de réseaux de neurones .....	56
2.6. Convolution Neural Network (CNN).....	57
2.6.1 Le principe de la CNN .....	58
2.6.2. Les dimensions de la CNN .....	59
2.6.3. Les principaux composants du CNN .....	59
2.7. Conclusion.....	68
Chapitre 3 : Expérimentation et Résultats .....	70
3.1. Introduction .....	70
3.2. Logiciels et Bibliothèques .....	70
3.2.1. Google Colab .....	70

3.2.2. TensorFlow.....	71
3.2 .3. Keras .....	72
3.3. La base de données .....	73
3.4. Architecture .....	74
3.4.1. Choix de l'architecture .....	74
3.4.2. Architectures utilisées .....	75
3.5. Résultats Obtenus et discussion : .....	84
3.5.1. Résultats obtenus pour le 1er Modèle (CNN).....	85
3.5.2. Résultats obtenus pour le 2ème Modèle(LeNet).....	88
3.5.3 Résultats obtenus pour le 2ème Modèle(AlexNet).....	88
3.5.4. Résultats obtenus pour le 4ème Modèle (VGG19) .....	92
3.5.5. Résultats obtenus pour le 5ème Modèle (Efficient Net).....	94
3.6. Comparaison des résultats .....	96
3.7. Conclusion : .....	97
Conclusion générale.....	99
Références bibliographiques .....	100

## **Liste des abréviations**

CND : Contrôle Non Destructif

CNN : convolutional Neural Network

DL : deep learning

End : essai non destructif

END : Les essais non destructifs

IA : Intelligence Artificiel

GPU : Graphics processing unit

ML : machine learning

ReLU : the rectified linear unit



## Table des figures

Figure 1 Quelques types de défauts de soudage .....	17
Figure 2 Schéma représentatif du principe de la radiographie .....	21
Figure 3 Dispositif expérimental pour étudier l'absorption .....	22
Figure 4 Porosité.....	28
Figure 5 Manque de pénétration .....	29
Figure 6 Fissure .....	29
Figure 7 Description générale d'une chaîne de vision par ordinateur.....	31
Figure 8 Défaut de soudure et région d'intérêt .....	35
Figure 9 Différence entre AI, Machine Learning et le deep Learning .....	40
Figure 10 La différence entre la classification et la régression.....	44
Figure 11 la Différence entre AI, Machine Learning et le deep Learning.....	45
Figure 12 La différence entre l'apprentissage supervisé et non-supervisé.....	46
Figure 13 Représentation du réseau de neurones humain .....	50
Figure 14 Représentation du réseau de neurones artificiel .....	50
Figure 15 Représentation d'un simple réseau de neurones perceptron .....	55
Figure 16 exemple d'un filtre de convolution 1D .....	60
Figure 17 Les fonctions D'activation .....	61
Figure 18 Exemple sur le Maxpooling .....	62
Figure 19 Représentation des fully-connected Layers .....	62
Figure 20 exemple sur le fonctionnement des Dropout Layers .....	63
Figure 21 Logo de Google Colab.....	71
Figure 22 Logo de TensorFlox .....	72
Figure 23 Logo de Keras.....	73
Figure 24 Base de données .....	74
Figure 25 Architecture du modèle 1 .....	76
Figure 26 Architecture du modèle 2 .....	79
Figure 27 Architecture du modèle 3 .....	81
Figure 28 Architecture du modèle 4.....	83
Figure 29 Architecture du modèle 5.....	84
Figure 30 Figure : Courbes de Précision pour le 1er modèle.....	85

Figure 31 Figure : Courbes d'Erreur pour le 1er modèle.....	86
Figure 32 Courbes de Précision et d'Erreur pour le 2ème modèle.....	88
Figure 33 les valeurs des Précisions et d'Erreur avec le nombre d'époque du 2ème modèle.	89
Figure 34 Courbe d'Erreur pour le 3ème modèle .....	90
Figure 35 Courbe de Précision pour le 3ème modèle .....	91
Figure 36 les valeurs des Précisions et d'Erreur avec le nombre d'époque du 3ème modèle.	92
Figure 37 Courbe de Précision pour le 4ème modèle .....	92
Figure 38 Courbe d'Erreur pour le 4ème modèle .....	93
Figure 39 les valeurs des Précisions et d'Erreur avec le nombre d'époque du 4ème modèle.	94
Figure 40 Courbes de Précision et d'Erreur pour le 5ème modèle.....	94
Figure 41 les valeurs des Précisions et d'Erreur avec le nombre d'époque du 5ème modèle.	95

**Liste des tableaux**

Tableau 1 Comparaison des précisions et erreurs d'apprentissage entre les modèles.....	97
Tableau 2 comparaison métriques d'évaluation de data set .....	97

## Introduction générale

L'utilisation du deep Learning pour l'analyse des images radiographiques de joints soudés est devenue une approche prometteuse dans le domaine du Contrôle Non Destructif (CND). Le CND est une méthode d'inspection largement utilisée pour détecter les défauts potentiels dans les structures sans les endommager.

Lorsqu'il s'agit de joints soudés, l'inspection radiographique est couramment utilisée pour détecter les défauts potentiels tels que les porosités, les fissures ou les inclusions.

Traditionnellement, l'inspection radiographique a été une technique couramment utilisée dans le CND pour évaluer les joints soudés. Cependant, l'interprétation des images radiographiques dépendait principalement de l'expertise humaine, ce qui pouvait entraîner des erreurs dues à la subjectivité et à la fatigue des opérateurs.

Le deep learning offre une alternative prometteuse en permettant aux ordinateurs d'apprendre à détecter automatiquement et de manière précise les défauts dans les images radiographiques de joints soudés. Cela implique la création d'un modèle d'apprentissage profond qui est formé sur de grandes quantités d'images radiographiques annotées, où les défauts sont identifiés et étiquetés.

Une fois le modèle entraîné, il peut être utilisé pour analyser de nouvelles images radiographiques et identifier automatiquement les défauts, contribuant ainsi à la détection précoce des problèmes et à la prévention de défaillances potentielles. Cette approche présente plusieurs avantages, notamment une plus grande précision, une rapidité d'analyse accrue et la possibilité de détecter des défauts subtils qui pourraient être manqués par les opérateurs humains.

Cependant, il est important de souligner que l'utilisation du deep learning pour l'analyse des images radiographiques de joints soudés dans le cadre du CND nécessite des ensembles de données de haute qualité et bien annotés, ainsi que des efforts significatifs pour entraîner et

valider les modèles. De plus, l'expertise humaine reste essentielle pour valider et interpréter les résultats obtenus par les modèles de deep learning.

Mon objectif à travers ce mémoire est de développer une technique basée sur les réseaux de neurones convolutifs, qui font partie de l'intelligence artificielle, capable d'analyser et de détecter les défauts multiples présents dans les joints soudés à partir d'images radiographiques.

Dans cette technique, nous allons construire différentes architectures de réseaux de neurones convolutifs avec des paramètres différents. Ces architectures seront entraînées et testées sur une base de données comprenant trois classes de défauts et une classe sans défaut. Ensuite, nous évaluerons quelle architecture parmi celles précédemment mentionnées est la plus performante pour prédire les défauts multiples.

Pour cela, nous avons structuré notre mémoire en trois chapitres :

Chapitre 1 : Introduction au Contrôle de soudure par radiographie et système de vision par ordinateur, le CND (Contrôle Non Destructif), et la radiographie en générale.

Chapitre 2 : Ce chapitre décrit toutes les notions et techniques des réseaux de neurones convolutionnels.

Chapitre 3 : Présentation des architectures des réseaux de neurones convolutionnels que nous avons proposées dans ce travail. Ce chapitre étudie et discute tous les résultats obtenus, et présente également la base de données.

Nous concluons ce mémoire par une conclusion générale.

## **Chapitre 1 : Contrôle de soudure par radiographie et système de vision par ordinateur**

### **État de l'art**

La détection des défauts de soudures sur les images radiographiques de joints soudés a connu une évolution significative au fil du temps. Les méthodes traditionnelles basées sur l'interprétation humaine ont été remplacées par des approches plus objectives et automatisées. La radiographie numérique a permis la conversion des films radiographiques en images numériques, facilitant ainsi leur manipulation et leur analyse. Avant la détection des défauts, les images radiographiques subissent souvent un prétraitement pour améliorer leur qualité. La détection des défauts implique l'utilisation d'algorithmes de traitement d'images pour extraire des caractéristiques pertinentes, telles que la forme, la taille et la texture des défauts. Une fois les défauts détectés, ils peuvent être classés en utilisant des techniques de classification basées sur des caractéristiques géométriques, de texture ou par l'utilisation de réseaux de neurones. L'apprentissage en profondeur, notamment les réseaux de neurones convolutifs, a révolutionné la détection et la classification des défauts de soudures, permettant d'apprendre automatiquement les caractéristiques à partir des images radiographiques. Ces avancées ont amélioré l'efficacité et la précision de la détection des défauts de soudures sur les images radiographiques de joints soudés.

Voici quelques méthodes déjà abordées :

1. La détection des défauts de soudure basée sur l'analyse des caractéristiques texturales locales de l'image. Un ensemble de filtres de Gabor et de caractéristiques de Haralick ont été utilisés pour calculer les caractéristiques texturales de l'image. Au total, 14 caractéristiques de Haralick ont été utilisées, notamment le contraste, la corrélation, l'entropie, la dispersion, etc. La méthode du plus proche voisin a été utilisée comme classificateur.
2. Dans une autre étude, les auteurs ont utilisé la segmentation spatiale de l'image pour détecter les défauts dans les joints soudés. La méthode se compose de trois étapes principales : la filtration, la correction de l'éclairage irrégulier et la segmentation. Pour réduire le bruit, un filtre de Wiener adaptatif local et un filtre numérique adaptatif avec logique floue ont été

utilisés. Pour la correction de l'éclairage, une filtration morphologique de l'image ainsi qu'un traitement dans le domaine fréquentiel à l'aide d'une transformée de Fourier discrète rapide ont été appliqués. À la dernière étape, l'image a été segmentée en utilisant la méthode du "triangle » pour détecter les défauts.

3. Une méthode de détection des défauts basée sur un traitement en plusieurs étapes de l'image, suivi d'une classification à l'aide d'un réseau neuronal, a été proposée dans l'étude. À l'étape initiale, l'image a été prétraitée en réduisant le bruit à l'aide du filtre de Wiener, en améliorant le contraste de l'image à l'aide d'une amélioration adaptative de l'histogramme (AHE) . Une transformée en ondelettes discrètes a été utilisée pour réduire la zone de traitement ultérieur. Après toutes les transformations, les pixels de l'image ont été classifiés à l'aide d'un réseau neuronal entièrement connecté. La skewness, les coefficients de kurtosis et les coefficients cepstraux de fréquence de Mel (MFCCs) ont été utilisés comme descripteurs

4. La méthode de détection des défauts proposée dans l'étude est basée sur le calcul d'un ensemble de descripteurs texturaux, suivie d'une classification à l'aide d'un réseau neuronal. Au total, vingt-deux caractéristiques texturales ont été utilisées, comprenant l'énergie, la corrélation, le contraste, et autres, basées sur les travaux de Clausi , Soh et Haralick .

5. Dans l'étude, les auteurs ont utilisé une architecture de réseau neuronal profond pour détecter les défauts dans les joints soudés. Pour réduire la complexité de calcul, la méthode de seuillage d'Otsu a été appliquée. Cette méthode permet de diviser l'image en deux composantes : l'arrière-plan (qui n'est pas utilisé lors de la classification) et le premier plan (tous les pixels de cette zone sont soumis à la classification).

Le principal inconvénient des travaux mentionnés ci-dessus est qu'il est nécessaire d'utiliser différents descripteurs texturaux pour détecter les fissures, ce qui entraîne une augmentation des coûts de calcul.

Dans ce mémoire, nous étudions différentes méthodes de détection des défauts dans les joints soudés. Les méthodes proposées sont basées sur l'apprentissage profond, suivie d'une détection précise des défauts[1].

## **Introduction**

Dans ce chapitre, nous mettrons l'accent sur le contrôle non destructif par radiographie, ainsi que sur différents types de défauts de soudage. Ensuite, nous introduirons le principe de la radiographie et son application, suivi du système par ordinateur, du prétraitement et de la segmentation.

### **1.1 Contrôle non destructif par radiographie**









#### **1.1.1 Aperçu sur le soudage, les défauts de soudures et le contrôle non destructif**

De nos jours, le soudage joue un rôle essentiel dans de nombreuses réalisations industrielles, offrant des avantages indéniables pour les assemblages soudés tels que la légèreté, la résistance aux sollicitations de service, la précision d'exécution et l'aspect esthétique [2]. Les soudures sont largement utilisées dans divers secteurs tels que la pétrochimie, l'industrie navale, l'automobile, les réacteurs nucléaires et l'électronique. Contrairement aux autres techniques d'assemblage telles que le boulonnage ou le rivetage, le soudage permet d'assurer une continuité métallique entre deux éléments à assembler. Il offre la possibilité d'assembler la quasi-totalité des métaux, dans différentes positions et environnements, en garantissant une bonne continuité de la matière, une transmission efficace des forces, une résistance solide et une étanchéité parfaite. Les métaux et alliages sont particulièrement adaptés à ce procédé en raison de leur capacité élevée de diffusion. Cependant, le soudage n'est pas toujours parfait et peut entraîner des discontinuités et des imperfections dans les structures soudées. Ces discontinuités sont généralement inhérentes aux procédés de soudage, dépendant de plusieurs facteurs tels que des exécutions incorrectes (surcharge, pression, durée d'application, etc.), la qualité des matériaux de base et/ou des produits d'apport, la propreté des zones à souder et le choix du procédé lui-même. Une classification détaillée des défauts de soudures est décrite dans [3], et quelques types de défauts sont récapitulés dans la Figure 1. Par conséquent, l'inspection des composants soudés est une étape essentielle. On utilise le terme de "contrôle non destructif" (CND) pour désigner les principales méthodes d'inspection permettant d'évaluer les soudures et les matériaux de soudage sans altérer leur utilité. Dans le cadre du CND, une discontinuité est considérée comme un défaut en fonction d'une spécification qui définit le type et les dimensions des discontinuités inacceptables [4]. Chaque méthode de CND est spécifique et vise à mesurer certaines propriétés ou à mettre en évidence

certains types de défauts. Le choix des méthodes d'inspection doit donc tenir compte du matériau examiné, de l'anomalie à détecter, des avantages et des limites de chaque méthode, des normes d'acceptation et des coûts associés.

Les méthodes couramment utilisées en contrôle non destructif sont les suivantes :

- Le contrôle visuel : Un aspect essentiel à ne pas négliger est le contrôle visuel, généralement effectué par le soudeur lui-même. Il permet d'évaluer la linéarité et la régularité du cordon de soudure, la présence d'épaisseur excessive, de fissures ou de caniveaux (manque de fusion du métal sur les bords de la soudure), ainsi que la bonne pénétration du métal d'apport, parmi d'autres critères.

GROUPE N° 1 – FISSURES			
			
FISSURE LONGITUDINALE	FISSURE TRANSVERSALE	FISSURES RAYONNANTES	FISSURES DE CRATÈRE
GROUPE N° 2 – CAVITÉS OU POROSITES			
			
SOUFFLURE SPHEROÏDALE	SOUFFLURES ALLIGNÉES	NID DE SOUFFLURES	SOUFFLURES ALLONGÉES





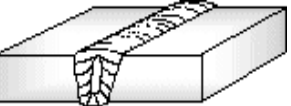




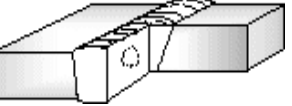

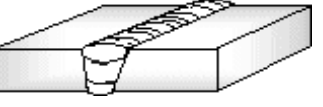
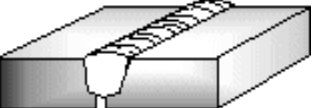
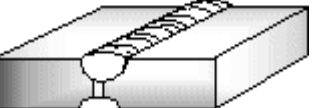
																															
<p><b>SOUFFLURE VERMICULAIRE</b></p>				<p><b>PIQÛRE</b></p>				<p><b>RETASSURE INTERDENTRITIQUE</b></p>				<p><b>RETASSURE DE CRATÈRE</b></p>																			
<p><b>GROUPE N° 3 - INCLUSIONS SOLIDES</b></p>																															
																															
<p><b>INCLUSION DE LAITIER</b></p>								<p><b>INCLUSION DE FLUX</b></p>								<p><b>INCLUSION D'OXYDE</b></p>								<p><b>INCLUSION MÉTALLIQUE</b></p>							
<p><b>GROUPE N° 4 - MANQUE DE FUSION</b></p>																															
																															
<p><b>MANQUE DE FUSION DES BORDS OU COLLAGE</b></p>								<p><b>MANQUE DE FUSION ENTRE PASSES</b></p>																							
<p><b>GROUPE N° 5 - MANQUE DE PÉNÉTRATION</b></p>																															
																															
<p><b>MANQUE DE PÉNÉTRATION</b></p>								<p><b>MANQUE D'INTERPÉNÉTRATION</b></p>																							

Figure 1 Quelques types de défauts de soudage[4]

- Le contrôle par ressuage :

Le contrôle par ressuage est une méthode utilisée pour détecter les défauts superficiels sur tous les métaux non poreux. Cette technique requiert l'utilisation d'un liquide appelé "pénétrant" qui s'infiltre dans la discontinuité, ainsi que d'un révélateur, généralement une fine poudre, qui permet de faire ressortir le pénétrant de la discontinuité en reproduisant sa forme et sa taille. Le pénétrant peut contenir soit un traceur rouge visible à la lumière naturelle, soit un traceur fluorescent pour un examen à la lumière ultraviolette.

- Le contrôle par magnétoscopie :

Le contrôle par magnétoscopie est une méthode qui permet de détecter les défauts présents à la surface des matériaux ferromagnétiques. Lorsqu'un champ magnétique est appliqué, les particules magnétiques présentes dans un liquide se concentrent au niveau des défauts, les rendant ainsi visibles. Cependant, cette méthode n'est utilisable que sur les matériaux ferromagnétiques.

- Le contrôle par ultrasons :

Le contrôle par ultrasons est une méthode qui utilise des ondes élastiques à haute fréquence, généralement de l'ordre du mégahertz. Ces ondes se propagent à travers le matériau en induisant des vibrations élastiques des particules constituant le matériau autour de leur position d'équilibre.

Dans l'inspection des soudures, on utilise généralement des ondes transversales qui vibrent perpendiculairement à la direction de leur propagation. Le contrôle des soudures peut être réalisé soit par transmission (avec deux sondes distinctes : une pour l'émission et une pour la réception des ultrasons), soit par réflexion ou échos (avec une seule sonde émettant et recevant les ultrasons).

- Le contrôle d'étanchéité :

Le contrôle d'étanchéité est une méthode qui permet de détecter les fuites causées par des défauts de dimensions microscopiques. Il implique de soumettre le conteneur à contrôler à une pression ou à une dépression à l'aide d'un gaz (comme l'hexafluorure de soufre, l'hélium,

l'ammoniac, etc.) ou d'un liquide. Cette pressurisation ou dépressurisation permet de mettre en évidence les fuites éventuelles en observant les variations de pression ou en utilisant des détecteurs spécifiques.

- Le contrôle par courant de Foucault :

Le contrôle par courant de Foucault est une méthode largement utilisée pour détecter les défauts de surface. Cette technique s'applique uniquement aux matériaux conducteurs d'électricité. Lorsqu'une bobine traversée par un courant alternatif est approchée de la pièce à contrôler, des courants de Foucault sont induits dans celle-ci par induction électromagnétique. L'amplitude des courants de Foucault induits dépend, entre autres, de la présence de discontinuités dans la pièce. Cette méthode permet donc de détecter les défauts de surface en mesurant les variations de courant induites par ces discontinuités.

- Le contrôle par radiographie :

Le contrôle par radiographie est principalement réalisé à l'aide de rayons X ou de rayons gamma. Ces rayonnements ont la capacité de pénétrer la matière et sont plus ou moins atténués en fonction de la densité et de l'épaisseur des matériaux traversés. Ils transportent une "image radiante" des objets, qui peut être convertie en une image visible sur un support approprié, tel qu'un film radiographique (utilisé en radiographie industrielle) ou un écran fluorescent (utilisé en radioscopie industrielle).

Les sections suivantes seront dédiées à cette dernière méthode. En effet, les images obtenues grâce à cette technique seront analysées dans les chapitres suivants.


### **1.1.2 Principe de la radiographie**

La radiographie est une méthode d'inspection des matériaux qui utilise des rayonnements ionisants tels que les rayons X ou les rayons gamma. Elle permet d'examiner l'intérieur des objets ou des assemblages qui sont opaques à la lumière. La radiographie est considérée comme une technique de contrôle non destructif car les objets examinés ne sont pas altérés lors du test et peuvent toujours être utilisés après l'inspection.

Lorsque les rayonnements traversent le matériau, une partie est absorbée ou transformée. La quantité d'absorption dépend de l'épaisseur, de la densité du matériau et du nombre atomique de l'atténuateur ou de l'écran. Des détecteurs tels que des films radiographiques peuvent être utilisés pour enregistrer les variations d'intensité du rayonnement incident sous forme d'images. Ainsi, les trois éléments essentiels pour produire une radiographie sont une source de rayonnement (rayons X ou gamma), l'objet à examiner et une cassette contenant le film.

La Figure 2 illustre les principaux éléments nécessaires pour obtenir une image radiographique. La source de rayonnement peut être un générateur de rayons X ou une capsule contenant un radio-isotope approprié, tel que le cobalt-60 ou l'iridium-192. Certains rayonnements émis par la source traversent l'objet, d'autres sont absorbés par l'objet, tandis que d'autres sont diffusés dans toutes les directions par l'objet. La quantité de rayonnement atteignant le film dans la cassette dépend de plusieurs facteurs liés à la nature du matériau irradié et à son épaisseur.

Prenons l'exemple d'une pièce en acier contenant une porosité gazeuse. L'épaisseur de l'acier est réduite à l'emplacement de la porosité, ce qui permettra à davantage de rayonnement de traverser cet endroit par rapport au reste de la pièce. Lorsque le film radiographique est développé, une tache foncée correspondant à la projection de la bulle apparaîtra. Les régions les plus sombres sur la radiographie représentent les parties de l'objet qui ont été plus facilement pénétrées par le rayonnement, et vice versa.



**Figure 2 Schéma représentatif du principe de la radiographie[5]**

Les rayons X et les rayons gamma possèdent les propriétés principales suivantes [6]:

- a. Ce sont des radiations électromagnétiques invisibles.
- b. Ils peuvent pénétrer dans la matière.
- c. Ils sont absorbés par la matière de manière différentielle.
- d. Ils produisent des effets photochimiques sur des émulsions photographiques.

Les rayons X et les rayons gamma sont tous deux des ondes électromagnétiques de même nature physique. Ils partagent les mêmes propriétés, mais ils sont produits différemment. Les rayons X sont générés à l'aide d'un équipement électrique, tandis que les rayons gamma proviennent de la désintégration des noyaux atomiques d'éléments radioactifs.

L'énergie des rayons gamma n'est pas réglable car elle dépend de la nature de la source radioactive. De même, l'intensité des rayons gamma n'est pas réglable car il n'est pas possible de modifier le taux de désintégration d'une substance radioactive. Comme les rayons X, les

rayons gamma sont partiellement absorbés lorsqu'ils traversent un matériau, ce qui permet leur utilisation pour obtenir une image radiographique.

### 1.1.3 Atténuation des rayons X et gamma

Exactement, l'utilisation des rayons X et gamma en radiographie est basée sur le principe de l'absorption différentielle. Cela signifie que ces rayonnements sont partiellement absorbés lorsqu'ils traversent un matériau, en fonction de la densité et de l'épaisseur de celui-ci. La Figure I.3 présente le dispositif expérimental utilisé pour mettre en évidence ce phénomène d'absorption des rayons par les matériaux. En mesurant l'intensité du rayonnement après son passage à travers un matériau, il est possible d'obtenir des informations sur la composition et la structure de l'objet examiné.




Figure 3 Dispositif expérimental pour étudier l'absorption

Un faisceau homogène des rayons X ou gamma d'intensité  $I_0$ , traversant une épaisseur  $\Delta x$  d'un matériau, subit une diminution d'intensité  $\Delta I$  qui est proportionnelle à l'intensité du faisceau incident et à l'épaisseur du corps absorbant.

Dans le dispositif décrit dans la Figure 3, lorsque le détecteur est déplacé vers la droite ou vers la gauche, on observe un maximum de lecture lorsque le détecteur est placé en position moyenne. Cela s'explique par le phénomène de dispersion ou diffusion des rayons X ou

gamma émergents du corps absorbant dans des directions différentes de celles par lesquelles ils sont entrés.

La radiation dispersée, également appelée radiation diffusée, provient des interactions des rayons X ou gamma avec la matière. Lorsque l'échantillon d'essai a une épaisseur significative, la radiation peut être dispersée plusieurs fois. Le détecteur reçoit à la fois la radiation dispersée et la radiation principale, et il ne peut pas les distinguer clairement. Ainsi, le coefficient d'absorption mesuré est composé de deux composantes : l'absorption réelle et le coefficient de dispersion.

L'absorption réelle correspond à la disparition des quanta des rayons X ou gamma, avec transfert d'énergie à des électrons du matériau. La radiation dispersée implique un changement de direction par rapport au faisceau principal. Elle se compose d'une radiation modifiée qui subit une variation d'énergie, et d'une radiation non modifiée qui conserve son énergie initiale.

Quatre processus d'interaction se produisent lorsque les rayons X ou gamma traversent la matière, et leur prédominance dépend de l'énergie du rayonnement incident et du matériau irradié. Ces processus sont les suivants :

1. La diffusion Rayleigh : Il s'agit d'une diffusion élastique des rayons X ou gamma par les atomes du matériau, sans transfert significatif d'énergie. Ce processus est prédominant à de faibles énergies.
2. L'effet photoélectrique : Il se produit lorsque les rayons X ou gamma interagissent avec les électrons liés des atomes du matériau, provoquant leur éjection et la capture d'un photon. Ce processus est prédominant à des énergies moyennes.
3. La dispersion Compton : Il implique la diffusion inélastique des rayons X ou gamma par les électrons libres du matériau, entraînant une perte d'énergie et un changement de direction du photon. Ce processus est prédominant à des énergies élevées.
4. La production d'une paire d'électrons : Ce processus se produit à des énergies très élevées, où les rayons X ou gamma peuvent se convertir en une paire d'électrons (un électron et un positron) en interagissant avec le champ électrique du noyau atomique.

Ces processus d'interaction déterminent la manière dont les rayons X ou gamma sont absorbés, diffusés et dispersés lorsqu'ils traversent un matériau, et ils sont pris en compte lors de l'interprétation des images radiographiques.

#### **1.1.4 Application de la radiographie à l'examen des soudures**

Dans ce chapitre, l'application spécifique de la radiographie industrielle qui nous intéresse est le contrôle non destructif des joints soudés. L'objectif est de détecter un défaut particulier parmi d'autres défauts dans l'image radiographique obtenue. Le contrôle vise à mettre en évidence les caractéristiques et les dimensions du défaut afin de déterminer la qualité ou l'état du matériau. En d'autres termes, il s'agit de déterminer si un matériau ou une pièce répond de manière satisfaisante à sa fonction prévue, ce qui permet d'atteindre plusieurs objectifs industriels :

1. Augmentation de la productivité et des bénéfices : En identifiant et en éliminant les défauts des joints soudés, on s'assure que les produits finis sont conformes aux spécifications requises. Cela évite les retouches coûteuses ou les reprises de production, ce qui contribue à accroître la productivité et les bénéfices de l'entreprise.
2. Augmentation de la sécurité : Les joints soudés défectueux peuvent compromettre la sécurité des installations ou des structures. En détectant les défauts grâce à la radiographie industrielle, on peut prévenir les accidents potentiels dus à des défaillances structurales ou à des ruptures de joints soudés, assurant ainsi la sécurité des opérations et des personnes.
3. Augmentation de la durée de vie des installations : Les joints soudés de qualité inférieure peuvent entraîner des défaillances prématurées des équipements ou des structures, ce qui nécessite des réparations fréquentes ou le remplacement complet des pièces. En identifiant les défauts dès le contrôle initial par radiographie, on évite les problèmes de fonctionnement ultérieurs et on prolonge la durée de vie des installations.



En résumé, l'application de la radiographie industrielle dans le contrôle des joints soudés vise à assurer la qualité des produits, à garantir la sécurité des opérations et à prolonger la durée de vie des installations. Cela contribue à l'efficacité opérationnelle, à la réduction des coûts et à la satisfaction des exigences de performance et de sécurité.

### **1.1.5 Mode opératoire de la radiographie par rayons X ou gamma**

Dans le processus de radiographie par rayons X ou gamma, une source d'émission de rayonnement est positionnée d'un côté de la pièce à contrôler, et un film radiographique est placé de l'autre côté. Plusieurs paramètres sont pris en compte pour obtenir une image radiographique de qualité.

Le temps d'exposition de la pièce aux rayonnements est l'un de ces paramètres importants. Il est déterminé en fonction de l'épaisseur et de la densité du matériau, ainsi que des spécifications de la norme ou du code de référence. Un temps d'exposition adéquat est essentiel pour obtenir une image avec un contraste suffisant tout en évitant une surexposition ou une sous-exposition.

La nature de l'ouvrage à contrôler et les exigences de la norme ou du code de référence vont également influencer certains paramètres du processus de radiographie. Par exemple, la classe de films à utiliser peut-être spécifiée en fonction de la sensibilité et de la résolution requises. Les dimensions de la source de rayonnement sont choisies en fonction de l'objet à contrôler et des exigences de pénétration du rayonnement. Le flou géométrique, la densité du film et le contraste sont d'autres paramètres qui peuvent être définis selon les besoins spécifiques du contrôle.

Une fois les paramètres établis, le temps d'exposition est déterminé et la pièce est irradiée. Le film radiographique obtenu est ensuite développé et traité en chambre noire. Après séchage, le cliché est visualisé sur un négatoscope, et les résultats de l'interprétation sont consignés dans un rapport de contrôle. L'interprétation des images radiographiques est généralement effectuée conformément

Aux recommandations du code ou de la norme de référence, qui définissent les critères d'acceptabilité ou de rejet des pièces examinées.

Pour des informations plus détaillées sur les différents paramètres et le mode opératoire de la radiographie industrielle par rayons X ou gamma, il est recommandé de se référer à des ouvrages spécialisés tels que "Radiographie industrielle".

### **1.1.6 Considérations liées à la qualité de l'image radiographique**

Le détecteur le plus souvent utilisé en radiographie industrielle est le film. La sensibilité élevée à la radiation ionisante fournit d'excellents détails et sensibilités aux changements de densité lors de la production des images des matériaux industriels. La qualité d'image est déterminée par une combinaison des variables : contraste et définition radiographiques. Plusieurs variables affectant le contraste et la définition radiographiques sont récapitulées ci-dessous :

#### **Contraste radiographique**

Le contraste est déterminé par les variables suivantes :

- Absorption différentielle dans le spécimen irradié
- Longueur d'onde du rayonnement primaire
- Diffusion ou rayonnement secondaire

Le contraste du film est déterminé par ce qui suit :

- Taille des grains ou le type du film.
- Composition chimique et concentration des produits de développement.
- Temps du développement.
- Température.
- Degré d'agitation mécanique.

Densité du film radiographique :

- Une densité plus élevée fournira un plus grand contraste.
- Les écrans de plomb dont les épaisseurs varient entre 0,1 et 0,4 mm réduiront l'effet des radiations diffusées à des niveaux d'énergie inférieur à 150 kV. En plus, ils émettront des

électrons pour accroître l'exposition du film aux radiations ionisantes augmentant ainsi, la densité de la radiographie.

- Les écrans fluorescents ne fournissent aucun filtrage. Une fois exposés au rayonnement, ils émettent des rayons lumineux auxquels le film est sensible. Il en résulte une augmentation du contraste de l'image.

### **Définition radiographique**

Les facteurs géométriques incluent ce qui suit :

- La taille de la tache focale, qui est le point d'origine du rayonnement, devrait être presque une source ponctuelle à la mesure du possible.
- La distance entre la source et le film, devrait être maintenue au minimum.
- Le spécimen et le film doivent être en contact étroit.
- Les changements brusques de l'épaisseur du spécimen peuvent causer une déformation sur le film.
- Le mouvement du spécimen pendant l'exposition produira une déformation sur la radiographie.

Granulation de film :

- La vitesse d'imprégnation du film édictera la définition de la radiographie.
- La longueur d'onde du rayonnement influencera la granulation apparente. Pendant que la longueur d'onde diminue et la pénétration augmente, la granulation apparente du film augmentera.
- Un temps de développement du film plus grand augmentera la granulation apparente de la radiographie.

Le contraste et la définition sont des paramètres fondamentaux qui déterminent la qualité du film radiographique. L'essentiel de la technique visant à obtenir une radiographie de qualité satisfaisante se résume dans l'optimisation de ces deux facteurs et dans le contrôle de leur incidence sur la détectabilité des défauts présents dans un matériau [4].

### 1.1.7 Interprétation des radiographies de soudures

Dans le cadre de ce mémoire, les discontinuités examinées par radiographie peuvent inclure les éléments suivants :

Porosités, Fissures, les manques de pénétration.

Défauts de soudure : problèmes spécifiques liés aux joints soudés, tels que les manques de pénétration, les soudures incomplètes, les manques de fusion, les porosités, etc.

La capacité d'une radiographie à détecter ces discontinuités dépend de sa résolution visuelle pour percevoir les formes spatiales dans une image, ainsi que de son expérience pour identifier les caractéristiques des discontinuités. L'interprétation des radiographies se déroule en trois étapes : détection, interprétation et évaluation. Il est essentiel que le radiographe possède une bonne connaissance des différentes discontinuités afin de prendre des décisions appropriées quant à l'acceptabilité ou au rejet du matériau, conformément aux normes ou codes de référence applicables.

**La porosité** : est un défaut courant dans les matériaux résultant de l'emprisonnement de gaz pendant la solidification. Sur une radiographie, la porosité apparaît généralement sous la forme de taches foncées, de points ronds ou irréguliers. Elle peut se présenter individuellement, en groupes ou alignée. La porosité correspond à des vides dans le matériau, ce qui signifie qu'elle a une densité radiographique plus élevée que celle de son environnement immédiat.





Figure 4 Porosité

**Le manque de pénétration** : Le manque de pénétration se produit lorsque le fond de la rainure de soudure n'est pas complètement rempli avec le métal de soudage. Il s'agit d'une discontinuité de soudure très critique. Le manque de pénétration crée une zone de concentration des contraintes où une fissure peut se propager. Sur une radiographie, le manque de pénétration apparaît comme une zone foncée avec des contours bien définis et rectilignes, située au centre de la racine du joint soudé.




Figure 5 Manque de pénétration

**La fissure** Dans une radiographie, seules les fissures qui se propagent dans une direction perpendiculaire au faisceau du rayonnement peuvent être détectées. Les fissures apparaissent comme des lignes irrégulières et souvent très fines sur l'image radiographique. Cela est dû au fait que les fissures présentent une variation d'épaisseur dans le matériau, ce qui entraîne une diminution de l'absorption des rayons X ou gamma et se traduit par une zone plus claire sur la radiographie.



Figure 6 Fissure

## 1.2 Système de vision par ordinateur dédié à la radiographie

### 1.2.1 Introduction

Avec le progrès qu'a connu la technologie de l'ordinateur, on assiste actuellement à l'émergence des techniques de traitement numérique des images qui sont appliqués dans divers

domaines tels que l'imagerie spatiale et la recherche biomédicale.

Néanmoins, ces dernières années, ces techniques intéressent de plus en plus le domaine du contrôle non destructif par radiographie, où les images des films radiographiques peuvent être numérisées et leur être appliquées les techniques du traitement numérique des images et ce, dans le but d'améliorer leur visibilité et d'en extraire les paramètres pertinents pour effectuer une interprétation [7].

Plusieurs facteurs ont contribué au développement de la technologie du traitement d'image :

- La grande quantité d'informations supportée par une image digitale dans une forme compacte est facilement manipulable, le support d'implantation offert par l'ordinateur pour plusieurs techniques ne pouvant pas se traiter avec une technologie non digitale.
- Les performances atteintes par les systèmes d'acquisition d'images et la croissance des systèmes informatiques, la tendance vers les composants rapides et moins coûteux et la haute densité de stockage de l'information digitale. Les possibilités nettement accrues des systèmes vidéo ont permis le traitement, la manipulation et l'affichage de grands volumes de *l'imagerie numérique*.
- Les efforts mathématiques réalisés notamment dans le domaine du traitement numérique de signal ont permis la mise au point d'algorithmes de calcul rapide rendant possible de nombreuses opérations complexes sur les images.

Le traitement numérique des images recouvre l'ensemble des procédés d'amélioration et d'extraction d'informations qualitative des images numériques, selon les utilisateurs et les besoins requis, pour en donner, soit des nouvelles images ou bien des évaluations particulières.

L'expert radiographe a pour rôle d'inspecter chaque film afin d'y détecter la présence d'éventuels défauts qu'il doit alors identifier et mesurer. Ce travail est rendu particulièrement

délicat du fait de la faible dimension de certains défauts (une fissure peut avoir une épaisseur inférieure à  $200\mu\text{m}$ ), du manque de contraste et du caractère bruité de l'image du film. L'expert travaille souvent aux limites du système visuel où la part de subjectivité dans les mécanismes de détection et de mesure des défauts n'est pas négligeable.

L'emploi des techniques de traitement numérique d'image et de reconnaissance de formes a pour but non seulement de détecter et d'identifier automatiquement les défauts mais aussi, d'une part, d'offrir une meilleure visualisation de l'information et d'autre part de formaliser les méthodes d'expertise radiographique afin de les rendre robustes et systématiques [8].

### I.2.2 Schéma général du système de vision des radiogrammes

La division d'un système de vision par ordinateur des images en trois principaux domaines est la plus utilisée [6]. Ces domaines sont :

- a. Traitement bas-niveau,
- b. Traitement niveau intermédiaire
- c. Traitement haut-niveau.

Bien que ces subdivisions n'aient pas de frontières définitives, elles font promouvoir un fondement utile pour la catégorisation des divers processus qui sont des composantes inhérentes d'un système autonome de vision par ordinateur.

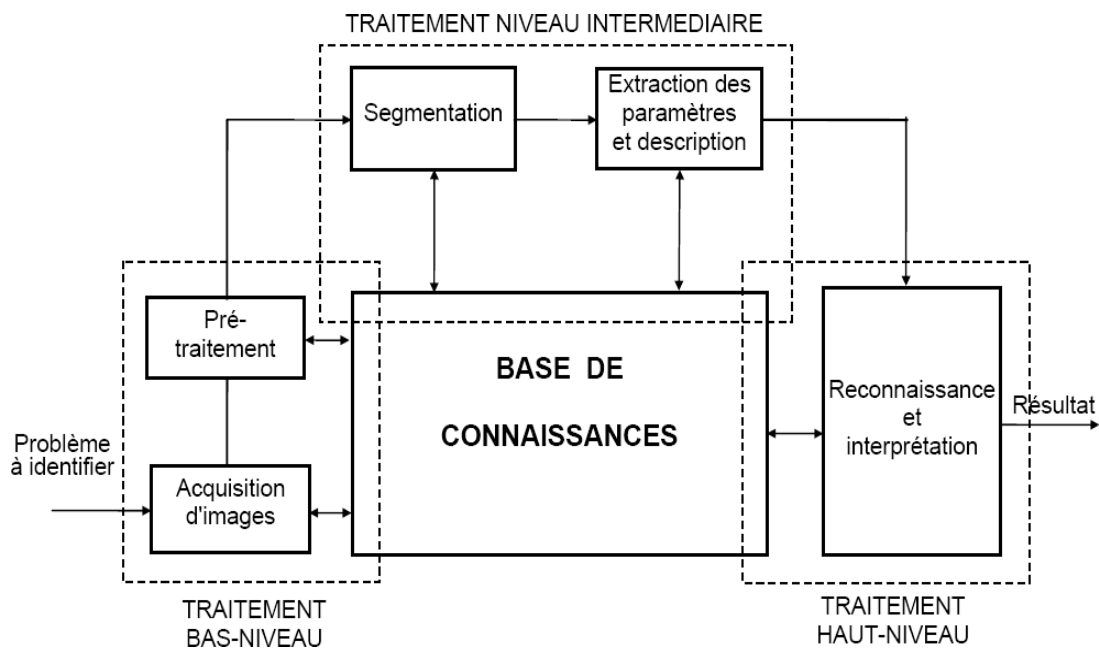


Figure 7 Description générale d'une chaîne de vision par ordinateur[9]

Il n'y a pas de limites précises entre les différents processus.

Par exemple, le seuillage peut être considéré comme un lissage (prétraitement) ou un outil de segmentation et ce, selon l'application.

Le traitement bas-niveau se sert des fonctions qui peuvent être considérées comme des réactions automatiques, ne demandant aucune intelligence de la part du système de vision. On considère l'acquisition et le prétraitement de l'image comme des fonctions de bas-niveau. Le niveau intermédiaire de traitement présente la tâche d'extraction des caractéristiques dans une image issue d'un traitement bas-niveau. Comme l'illustre la figure ci-dessus, le traitement niveau intermédiaire renferme la segmentation et l'extraction des traits descriptifs. Certaines capacités pour un comportement intelligent sont conférées par des procédures de segmentation.

Par exemple, la fermeture de contours dans les images segmentées implique des outils plus sophistiqués que pour l'accomplissement de cette tâche. Ce qui n'est pas le cas pour les traitements bas-niveau.

Enfin, le traitement haut-niveau implique la reconnaissance (dans notre application, il s'agit de la recherche d'images) et l'interprétation. Ces deux processus ont une forte ressemblance qui est généralement signifiée par le terme perception ou cognition intelligente. La majorité des techniques utilisées dans les traitements bas-niveau et niveau intermédiaire renferme un ensemble de formulations théoriques bien définies. Cependant, les problèmes de vision haut niveau concerne l'intégration d'information sémantique sur toute l'image à analyser (quel est le but poursuivi ? de quelles connaissances a-t-on besoin ? par exemple) en se servant à la fois d'une base de connaissances appropriées utilisant les techniques de l'intelligence artificielle et du niveau inférieur pour, éventuellement, lui demander des compléments d'informations. Cela implique l'existence d'une grande interaction entre ce niveau et le niveau intermédiaire [5]. Pour notre application, nous avons un système de vision par ordinateur dédié aux images des films radiographiques, comportant les parties suivantes :

- Numérisation du film : Acquisition
- Amélioration de la visibilité de l'image radiographique : Prétraitement



- Extraction de la zone du défaut : Segmentation et Post-traitement (si nécessaire).
- Indexation de la base des défauts : Extraction de caractéristiques.
- Identification des défauts : Classification / Recherche d'image par le contenu

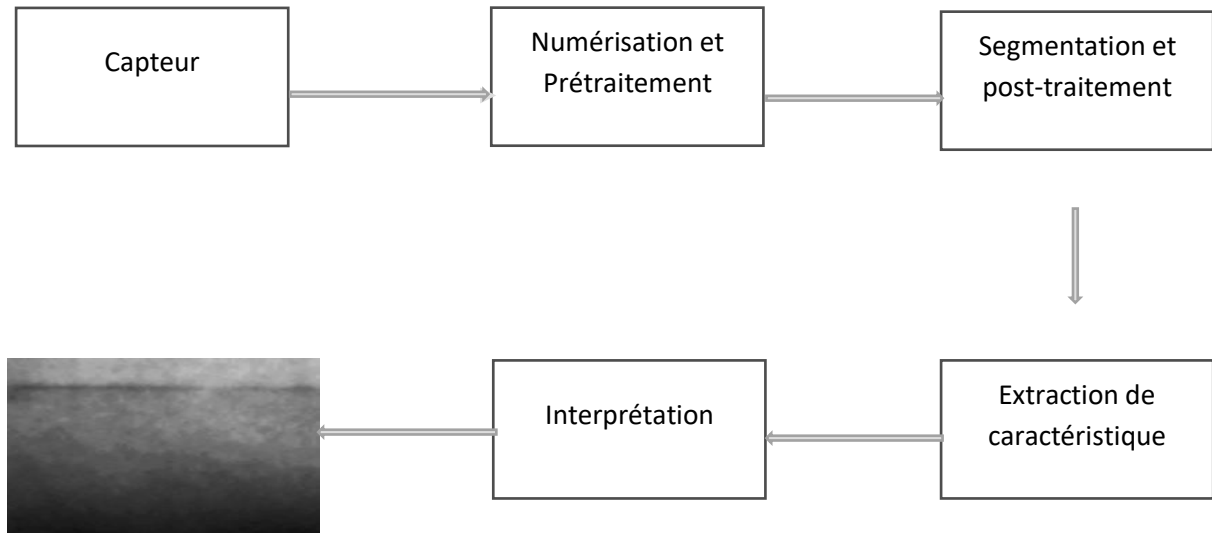


Figure 8 Schéma du système de vision dédié aux films radiographiques

### 1.2.3 La numérisation des images radiographiques

La première étape du processus consiste à numériser les films après leur exposition aux radiations. Cette étape implique la conversion des signaux analogiques en données numériques positives qui vont de 0 à 255, où 0 représente le noir, 255 représente le blanc, et les niveaux de gris se situent entre ces deux valeurs. Les films de radiographie ont généralement une densité élevée, ce qui les rend très sombres. Par conséquent, un scanner ordinaire ne peut pas fournir un éclairage suffisant à travers un radiogramme. Bien qu'il existe des scanners spécialisés appropriés pour obtenir des copies de radiogrammes de haute qualité, ils sont coûteux.

a. Un faible contraste entre le fond de l'image et les défauts de soudures. Les contours de ces défauts sont flous et peu marqués.

b. Une granularité élevée due à la numérisation et aux types de films utilisés en radiographie industrielle.

c. La présence d'un gradient dans le fond de l'image, qui indique la variation d'épaisseur de la pièce contrôlée.

#### **1.2.4 Prétraitement**

Le prétraitement se réfère aux opérations de traitement d'image au niveau le plus bas, où les images d'entrée et de sortie sont toutes deux des images en niveaux de gris. L'objectif du prétraitement est d'améliorer la visibilité des images en éliminant les déformations indésirables et en accentuant les aspects utiles de l'image pour les traitements ultérieurs. En raison des difficultés mentionnées précédemment, il est souvent difficile, voire aléatoire, de détecter la présence de petits défauts et de déterminer leur taille précise lors de la visualisation des radiogrammes. C'est pourquoi il est généralement nécessaire de commencer par l'étape de prétraitement afin de réduire ou d'éliminer le bruit et d'améliorer le contraste. Cette approche nous permet d'obtenir une image qui facilite l'identification ultérieure des défauts de soudure potentiels dans la jointure soudée. Cependant, la première tâche du prétraitement consiste à sélectionner la région où le défaut de soudure est susceptible de se trouver, ce qui peut être effectué de manière interactive après la visualisation du film radiographique. Cette région est appelée "région d'intérêt".

#### **1.Sélection interactive de la région d'intérêt**

Lors de l'évaluation interactive de la qualité d'une soudure à l'aide de radiographies, la première tâche de l'interpréteur consiste à marquer les parties de l'image où des imperfections sont suspectées. Pour ce faire, une région d'intérêt (ROI) est définie, qui correspond à une zone spécifique à l'intérieur de l'image que l'on souhaite étudier en profondeur. Cette région est mise en évidence en sélectionnant la partie de l'image qui nous intéresse et en la séparant du reste de l'image. Cela permet d'éviter de traiter les parties inutiles de l'image, ce qui réduit le temps de calcul nécessaire.

Un deuxième avantage de l'utilisation d'une région d'intérêt est que les traitements basés sur des approches globales n'ont pas besoin d'utiliser les niveaux de gris des régions non

pertinentes. Cela permet d'obtenir des résultats plus performants pour les traitements utilisant ce type d'approche. En se concentrant uniquement sur la région d'intérêt, les traitements peuvent être plus ciblés et plus efficaces dans l'analyse des imperfections de la soudure.




Figure 9 Défaut de soudure et région d'intérêt

## 2. Modèle du bruit et filtrage

Les images radiographiques obtenues à partir de systèmes d'imagerie à rayons X ou gamma sont sujettes à des fluctuations aléatoires résultant de l'absorption statistique des quanta de rayonnement. Ces variations peuvent compromettre la détection fiable de petites discontinuités. Lorsque les images sont numérisées à partir de films-écrans, d'autres sources de bruit, telles que le numériseur, la structure de l'écran fluorescent renforceur et la granularité de l'émulsion du film, contribuent à ce problème. Le bruit se traduit par une apparence tachetée, granuleuse, texturée ou neigeuse de l'image. Le bruit fondamental dû au rayonnement diffusé est causé par la nature discrète des photons de rayons X dans les systèmes d'imagerie, et il suit une distribution de loi de Poisson ou de Gauss. Le bruit résultant des grains du film peut être modélisé par une distribution gaussienne avec une moyenne nulle. Le bruit radiographique, qui combine ces deux types de bruit, peut être considéré comme un bruit multiplicatif ou dépendant du signal. Certains travaux ont proposé des modèles de bruit radiographique basés sur des mélanges de Gaussiennes, avec une moyenne nulle et une variance variable, permettant ainsi d'estimer la dispersion du bruit. En fonction des caractéristiques spécifiques du bruit radiographique, des filtres tels que des filtres gaussiens ou des filtres de Kalman peuvent être appliqués. Il convient également de noter que l'image du film peut présenter un bruit impulsif, parfois causé par l'interaction des produits chimiques de la solution de révélation avec le film. Dans ce cas, l'utilisation d'un filtre médian peut être appropriée.

### **3. Rehaussement du contraste**

Le but du rehaussement du contraste est d'améliorer la visibilité de l'image d'entrée en mettant en évidence les régions présentant des défauts. Cela permet à l'étape d'extraction des défauts de mieux détecter et représenter chaque défaut dans l'image.

Il existe différentes techniques visant à améliorer l'apparence des images numériques ou à les transformer de manière à les rendre plus adaptées aux traitements ultérieurs. Parmi ces techniques, le recadrage dynamique et l'égalisation de l'histogramme sont les plus couramment utilisées pour le rehaussement du contraste. Le recadrage dynamique consiste à appliquer une transformation visant à redistribuer les niveaux de gris de l'image afin d'occuper une plage de valeurs plus large. Cependant, il est largement reconnu que l'utilisation d'informations globales est souvent insuffisante pour obtenir un rehaussement de qualité. Pour remédier à cela, des techniques de rehaussement adaptatif ont été proposées dans cette application, telles que celles basées sur les propriétés statistiques de l'image telles que la moyenne et la variance, la mesure d'hétérogénéité, la morphologie mathématique, etc.

#### **1.2.5 Segmentation, extraction de caractéristiques et interprétation**

La segmentation, l'extraction de caractéristiques et l'interprétation sont des étapes clés dans le processus d'analyse des images.

La segmentation consiste à diviser une image en différentes régions ou objets d'intérêt. L'objectif est de regrouper les pixels ou les régions similaires tout en les séparant des autres parties de l'image. La segmentation peut être basée sur des critères tels que la couleur, l'intensité, la texture, les contours ou d'autres caractéristiques visuelles. En segmentant une image, on obtient des régions distinctes qui peuvent faciliter la détection et l'analyse des éléments souhaités, tels que les défauts de soudure dans le cas des images radiographiques.

Une fois que les régions d'intérêt sont identifiées, l'extraction de caractéristiques est effectuée. Cela implique de quantifier les propriétés visuelles des régions ou des objets détectés. Les caractéristiques peuvent inclure des mesures statistiques telles que la moyenne, la variance, l'énergie, l'asymétrie, ainsi que des descripteurs plus avancés tels que les histogrammes de gradient, les textures, les formes, etc. L'extraction de caractéristiques

permet de représenter les régions ou les objets de manière concise et significative, facilitant ainsi les étapes suivantes de l'analyse et de l'interprétation.

Enfin, l'interprétation consiste à donner un sens aux caractéristiques extraites et à prendre des décisions en fonction de ces informations. Dans le contexte des images radiographiques des défauts de soudure, l'interprétation peut impliquer la classification des régions en défaut ou en non-défaut, l'estimation de la gravité ou de l'étendue des défauts, ou encore la localisation précise des défauts dans l'image. L'interprétation peut être réalisée manuellement par des experts humains, ou automatiquement à l'aide de techniques d'apprentissage automatique ou de modèles prédictifs.

En résumé, la segmentation permet de diviser une image en régions d'intérêt, l'extraction de caractéristiques quantifie les propriétés visuelles de ces régions, et l'interprétation donne un sens aux caractéristiques extraites pour prendre des décisions ou obtenir des informations précieuses.

### **1.3. Conclusion**

Dans ce chapitre, nous avons abordé le sujet du soudage, du contrôle non destructif par radiographie et des discontinuités courantes dans le soudage. Nous avons également décrit l'apparence de certaines de ces discontinuités dans les images radiographiques industrielles. De plus, nous avons présenté le schéma général du système de vision par ordinateur utilisé pour la détection et l'identification des défauts de soudure.

Nous avons répertorié les opérations de prétraitement spécifiques aux images radiographiques. Après la numérisation du film, l'étape suivante est la sélection de la région d'intérêt où la présence du défaut est la plus probable. Ensuite, des opérations de rehaussement du contraste et de filtrage du bruit sont effectuées pour améliorer la visibilité de l'image de la région du défaut. Cette étape est souvent recommandée pour améliorer l'efficacité des méthodes de segmentation d'images, en particulier le seuillage.

L'objectif de ces opérations de prétraitement est d'améliorer la qualité de l'image radiographique et de mettre en évidence les détails pertinents pour la détection des défauts

de soudure. Un contraste amélioré et un bruit réduit facilitent les étapes ultérieures de segmentation d'images, en permettant une meilleure distinction entre les défauts et les autres régions de l'image.

En résumé, ce chapitre a fourni un aperçu général du domaine du soudage, du contrôle non destructif par radiographie et des discontinuités dans le soudage. Nous avons également présenté le schéma du système de vision par ordinateur utilisé pour la détection des défauts de soudure. De plus, nous avons énuméré les opérations de prétraitement spécifiques aux images radiographiques, en mettant l'accent sur l'importance du rehaussement de contraste et du filtrage du bruit pour faciliter la segmentation d'images.

## **Chapitre 2:**

### **Généralité sur Les réseaux de neurones**

#### **(Les réseaux de neurones convolutifs CNN)**

### **2.1. Introduction**

L'intelligence artificielle est un domaine scientifique qui vise à trouver des méthodes pour résoudre des problèmes complexes sur le plan logique ou algorithmique. L'apprentissage automatique fait partie de l'intelligence artificielle et se concentre sur l'étude des méthodes permettant de modéliser des données avec un haut niveau d'abstraction en utilisant des architectures composées de transformations non linéaires. C'est dans ce contexte que l'apprentissage profond, également appelé deep learning, deep structured learning ou apprentissage hiérarchique, intervient.

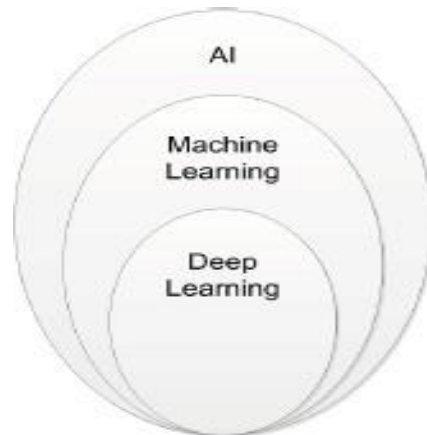
Dans ce chapitre, nous mettrons l'accent sur les réseaux de neurones, qui constituent une composante essentielle de l'apprentissage profond. Les réseaux de neurones font partie intégrante de l'intelligence artificielle et jouent un rôle clé dans la modélisation de données complexes grâce à leur capacité à effectuer des transformations non linéaires.

### **2.2. L'intelligence artificielle (IA)**

L'intelligence artificielle (IA), également connue sous le nom d'Intelligence Artificielle en anglais (Artificial Intelligence - AI), englobe diverses techniques utilisées pour permettre aux machines d'imiter une forme d'intelligence humaine. Cette notion a été introduite dans les années 1950 par Alan Turing, un mathématicien, dans son livre "Computing Machinery and Intelligence". Il a présenté le célèbre "Test de Turing", dans lequel un sujet interagit à l'aveugle avec un autre humain et une machine programmée pour fournir des réponses intelligentes. Si le sujet ne peut pas distinguer la machine de l'humain, alors la machine est considérée comme ayant réussi le test et est considérée comme "intelligente" selon Turing.

De nos jours, de nombreuses grandes entreprises informatiques telles que Google, Microsoft, Apple, IBM et Facebook se penchent sur les défis de l'intelligence artificielle et cherchent à l'appliquer à divers domaines spécifiques. Chacune de ces entreprises a mis en place des

réseaux de neurones artificiels composés de serveurs, permettant de traiter de lourdes tâches de calcul au sein de vastes bases de données. L'application de l'IA est de plus en plus répandue et trouve sa place dans de nombreux domaines.



**Figure 10** Différence entre AI, Machine Learning et le deep Learning[24]

### 2.2.1. Les origines de l'intelligence artificielle

Depuis environ le premier siècle avant notre ère, l'homme s'est intéressé à la création de machines capables de reproduire le raisonnement humain. Le terme "intelligence artificielle" a été introduit plus récemment en 1955 par John McCarthy. En 1956, McCarthy et ses collègues ont organisé une conférence intitulée "Dartmouth Summer Research Project on Artificial Intelligence", qui a donné naissance à des domaines tels que l'apprentissage automatique (machine learning), le deep learning, l'analyse prédictive et plus récemment, l'analyse prescriptive. Un nouveau domaine d'étude a également émergé : la science des données.

### 2.2.2. L'importance de l'intelligence artificielle



À l'heure actuelle, les êtres humains et les machines génèrent des données à un rythme plus rapide que ce que nous pouvons absorber et interpréter de manière humaine pour prendre des décisions complexes. L'intelligence artificielle constitue la base de tout apprentissage effectué par ordinateur et représente l'avenir des processus décisionnels complexes. Par exemple, la plupart des êtres humains peuvent apprendre à ne pas perdre au morpion, un jeu qui compte 255 168 actions possibles, dont 46 080 mènent à un match nul. En revanche, il est plus rare de trouver des champions dans le jeu de dames, qui comporte plus de  $500 \times 10^{18}$  (500 trillions) de coups possibles. Les ordinateurs sont capables de calculer ces combinaisons et les meilleures permutations de manière très efficace, leur permettant de prendre les bonnes décisions. L'IA (avec sa progression logique, le machine learning) et le deep learning représentent l'avenir de la prise de décisions.

### 2.2.3. Les applications de l'IA

Voici quelques exemples courants d'utilisation de l'intelligence artificielle dans notre vie quotidienne:

**Assistants virtuels** : Des assistants virtuels tels que Siri, Alexa et Google Assistant utilisent l'IA pour comprendre et répondre à nos demandes vocales, nous aidant ainsi à accomplir diverses tâches telles que la recherche d'informations, la gestion des calendriers et l'exécution de commandes.

**Reconnaissance faciale** : La reconnaissance faciale basée sur l'IA est utilisée dans les smartphones, les applications de sécurité et même dans les aéroports pour identifier et authentifier les individus.

**Recommandations de produits** : Les plateformes de commerce électronique, les services de streaming musical et vidéo utilisent l'IA pour analyser les préférences de l'utilisateur et lui recommander des produits, des chansons ou des films susceptibles de l'intéresser.

**Filtres anti-spam** : Les filtres anti-spam basés sur l'IA analysent les e-mails et les messages pour détecter les contenus indésirables et les classer en conséquence.

**Voitures autonomes :** Les voitures autonomes utilisent des techniques d'IA avancées telles que la vision par ordinateur et l'apprentissage profond pour percevoir l'environnement et prendre des décisions de conduite.

**Traduction automatique :** Les outils de traduction automatique utilisent l'IA pour analyser et traduire rapidement des textes dans différentes langues.

**Assistance médicale :** L'IA est utilisée dans des domaines tels que la détection précoce des maladies, l'assistance chirurgicale et l'analyse des données médicales pour fournir des informations et un soutien aux professionnels de la santé.

**Reconnaissance vocale :** Les systèmes de reconnaissance vocale utilisent des modèles d'IA pour convertir la parole en texte, facilitant ainsi la dictée, les commandes vocales et les interactions avec les appareils.

## **2.3. Le Machine Learning**

### **2.3.1. Définition du Machine Learning**

Le Machine Learning est une discipline moderne qui vise à découvrir des schémas et à effectuer des prédictions en utilisant des données, en se basant sur des statistiques, des analyses prédictives et la reconnaissance de motifs. Les premiers algorithmes ont émergé à la fin des années 1950, notamment le célèbre Perceptron. Cette technologie d'intelligence artificielle permet aux ordinateurs d'apprendre sans programmation explicite, mais ils ont besoin de données sur lesquelles s'entraîner pour se développer. Ainsi, le Big Data joue un rôle essentiel dans le Machine Learning en exploitant pleinement son potentiel. Le Machine Learning se révèle particulièrement efficace pour analyser de vastes ensembles de données diverses et changeantes, dépassant les méthodes traditionnelles en termes de précision et de rapidité. Par exemple, il peut détecter une fraude potentielle en une milliseconde en analysant des informations de transaction et des données historiques, surpassant ainsi les méthodes conventionnelles pour l'analyse de données transactionnelles, des réseaux sociaux ou des plateformes CRM. Le Machine Learning est une branche de l'intelligence artificielle qui englobe diverses méthodes permettant de créer automatiquement des modèles à partir des

données, ces méthodes étant en réalité des algorithmes. Contrairement aux programmes informatiques traditionnels qui suivent des instructions précises de manière systématique, un système basé sur le Machine Learning apprend de l'expérience et améliore ses performances à mesure qu'il est exposé à davantage de données.

### **2.3.2. Fonctionnement du Machine Learning**

Le Machine Learning présente un avantage certain dans l'exploration des opportunités cachées du Big Data. Cette technologie offre la possibilité d'extraire de la valeur à partir de vastes et diverses sources de données, sans dépendre exclusivement de l'intervention humaine. Elle est entièrement guidée par les données, ce qui la rend particulièrement adaptée à la complexité des immenses ensembles de données. Contrairement aux outils analytiques traditionnels, le Machine Learning peut également être appliqué à des ensembles de données en constante croissance. En effet, plus le volume de données intégré dans un système de Machine Learning est important, plus celui-ci est en mesure d'apprendre et de produire des résultats pertinents et de qualité supérieure. Par conséquent, le Machine Learning permet de découvrir avec une efficacité accrue les schémas et les motifs enfouis dans les données, surpassant ainsi les capacités de l'intelligence humaine. [6]

### **2.3.3. Les différents types d'algorithmes de Machine Learning**

On distingue différents types d'algorithmes Machine Learning. Généralement, ils peuvent être répartis en 3 catégories : supervisés, non supervisés et l'apprentissage renforcé

#### **L'apprentissage supervisé**

Les données utilisées pour l'entraînement sont déjà "étiquetées", ce qui signifie que le modèle de Machine Learning sait déjà ce qu'il doit rechercher, que ce soit des motifs, des éléments ou autres, dans ces données. Une fois l'apprentissage terminé, le modèle sera capable de retrouver les mêmes éléments dans des données non étiquetées. Parmi les algorithmes supervisés, on distingue les algorithmes de classification, qui effectuent des prédictions non-numériques, et les algorithmes de régression, qui effectuent des prédictions numériques. Le choix entre ces deux types d'algorithmes dépend du problème à résoudre.

La classification et la régression sont deux problèmes de prédiction couramment abordés lors de l'exploration de données. La modélisation prédictive consiste à développer un modèle ou

une fonction en utilisant des données historiques pour prédire de nouvelles données. La différence essentielle entre la classification et la régression réside dans le fait que la classification attribue des étiquettes discrètes à des objets de données d'entrée, tandis que la régression attribue des valeurs réelles continues à ces objets de données d'entrée. [6]

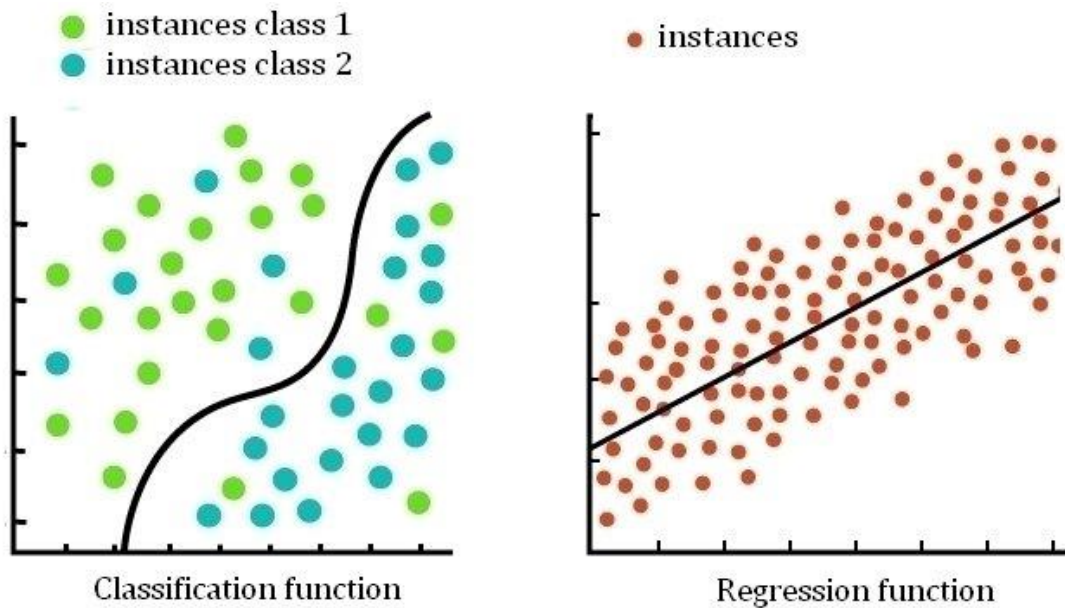


Figure 11 La différence entre la classification et la régression

[25]

### L'apprentissage non supervisé

Au contraire, consiste à entraîner le modèle sur des données sans étiquettes. La machine parcourt les données sans aucun indice, et tente d'y découvrir des motifs ou des tendances récurrentes. Cette approche est couramment utilisée dans certains domaines, comme cyber sécurité.

Parmi les modèles non-supervisés, on distingue les algorithmes de clustering (pour trouver des groupes d'objets similaires), d'association (pour trouver des liens entre des


objets) et de réduction dimensionnelle (pour choisir ou extraire des caractéristiques). Une troisième approche est celle de l'apprentissage par renforcement. [6]

### L'apprentissage renforcé

L'apprentissage par renforcement ou Reinforcement Learning est une méthode de Machine Learning. Elle consiste à entraîner des modèles d'intelligence artificielle d'une manière bien spécifique.

L'agent IA doit apprendre à atteindre un objectif au sein d'un environnement incertain et potentiellement complexe. Pour y parvenir, l'ordinateur essaye toutes les façons possibles et apprend de ses erreurs.

À chaque tentative, l'IA reçoit une récompense ou une punition en fonction des actions effectuées. Elle est programmée pour maximiser sa récompense, et tentera donc de trouver la méthode le lui permettant. [6]



**Figure 12 la Différence entre AI, Machine Learning et le deep Learning[10]**

En tentant d'obtenir le plus de récompenses possible, il s'améliore progressivement. En guise d'exemple, on peut citer le programme Alpha GO qui a triomphé du champion du monde de jeu de Go. Ce programme a été entraîné par renforcement.

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




Figure 13 La différence entre l'apprentissage supervisé et non-supervisé[11]

#### 2.3.4. L'utilité du Machine Learning

Le Machine Learning, ou apprentissage automatique, présente de nombreuses utilisations et est devenu une technologie essentielle dans de nombreux domaines. Voici quelques-unes de ses principales utilisations :

1. Prévisions et prédictions : Le Machine Learning est largement utilisé pour effectuer des prévisions et des prédictions basées sur des modèles statistiques. Il peut être utilisé pour prédire les tendances du marché, les comportements des utilisateurs, les résultats financiers, etc.
2. Reconnaissance de motifs : Le Machine Learning est efficace pour détecter des motifs et des structures complexes dans les données. Il peut être utilisé pour la reconnaissance vocale, la reconnaissance d'images, la détection d'anomalies, la classification de documents, etc.
3. Recommandations personnalisées : De nombreuses plateformes utilisent le Machine Learning pour fournir des recommandations personnalisées aux utilisateurs. Par exemple, les services de streaming de musique et de vidéo recommandent du contenu en fonction des préférences de l'utilisateur et de ses habitudes de consommation.
4. Automatisation des tâches : Le Machine Learning peut être utilisé pour automatiser des tâches complexes et répétitives. Par exemple, les chatbots utilisent le Machine Learning pour comprendre et répondre aux requêtes des utilisateurs de manière autonome.

5. Optimisation et prise de décision : Le Machine Learning permet d'optimiser les processus et de prendre des décisions basées sur des données. Par exemple, dans le domaine de la logistique, il peut être utilisé pour optimiser l'itinéraire des livraisons en fonction des conditions de circulation.

6. Médecine et soins de santé : Le Machine Learning est utilisé dans le domaine médical pour le diagnostic de maladies, la détection précoce de conditions médicales, la personnalisation des traitements et la recherche médicale.

7. Analyse de données et extraction de connaissances : Le Machine Learning permet d'analyser de grandes quantités de données pour en extraire des connaissances et des insights précieux. Cela peut aider les entreprises à prendre des décisions éclairées et à identifier de nouvelles opportunités.

### **2.4. Introduction au Deep Learning**

#### **2.4.1. Définition du Deep Learning**

Le Deep Learning, également connu sous le nom d'apprentissage profond, est une branche du Machine Learning qui se concentre sur l'apprentissage et la modélisation de représentations de données complexes. Il s'agit d'un ensemble de techniques basées sur des réseaux de neurones artificiels profonds, qui sont des architectures composées de plusieurs couches de neurones interconnectés.

Le Deep Learning vise à simuler le fonctionnement du cerveau humain en utilisant des réseaux de neurones artificiels avec plusieurs couches de traitement de l'information. Chaque couche traite des caractéristiques ou des abstractions de plus en plus complexes, permettant ainsi d'apprendre des représentations hiérarchiques des données. Ces représentations sont ensuite utilisées pour résoudre des tâches telles que la classification, la reconnaissance d'images, la traduction automatique, la génération de texte, etc.

Une des caractéristiques distinctives du Deep Learning est sa capacité à apprendre automatiquement des caractéristiques et des représentations à partir des données, au lieu de nécessiter une ingénierie manuelle de ces caractéristiques. Cela permet au modèle d'extraire

des informations pertinentes et de découvrir des motifs complexes dans les données, même lorsque ces motifs ne sont pas explicitement spécifiés.

Pour entraîner un modèle de Deep Learning, on utilise généralement de grandes quantités de données et des ressources de calcul puissantes, telles que les cartes graphiques (GPU). L'apprentissage se fait par rétropropagation de l'erreur, où le modèle ajuste les poids et les paramètres des neurones afin de minimiser l'écart entre les prédictions du modèle et les vérités terrain.

Le Deep Learning a connu un grand succès ces dernières années, notamment grâce aux avancées technologiques, à la disponibilité de grandes quantités de données et à la puissance de calcul accrue. Il a été utilisé avec succès dans de nombreux domaines, notamment la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale, la recommandation de contenu, la bioinformatique, la médecine, etc.

### **2.4.2. Domaine d'application**

Le Deep Learning trouve des applications dans de nombreux domaines. Voici quelques-uns des principaux domaines d'application du Deep Learning :

1. Vision par ordinateur : Le Deep Learning est utilisé pour la reconnaissance d'images, la détection d'objets, la segmentation d'images, la reconnaissance faciale, la vision nocturne, la surveillance vidéo, etc. Il permet aux machines de "voir" et d'interpréter des informations visuelles de manière similaire à l'être humain.

2. Traitement du langage naturel : Le Deep Learning est utilisé pour la traduction automatique, la génération de texte, la reconnaissance et la génération de la parole, la compréhension du langage naturel, la classification de documents, la détection des sentiments dans les textes, etc. Il permet aux machines de comprendre et de générer du langage humain.

3. Reconnaissance vocale : Le Deep Learning est utilisé pour la transcription automatique de la parole, la commande vocale, les assistants virtuels, la conversion texte-voix, etc. Il permet aux machines de comprendre et de répondre à la parole humaine.



4. Médecine et soins de santé : Le Deep Learning est utilisé pour la détection de maladies, le diagnostic médical, l'analyse d'imagerie médicale, la prédiction de résultats cliniques, la découverte de médicaments, la personnalisation des traitements, etc. Il aide les professionnels de la santé à prendre des décisions plus précises et à améliorer les soins aux patients.

5. Automobile autonome : Le Deep Learning est utilisé pour la perception et la compréhension de l'environnement, la détection d'obstacles, la reconnaissance des panneaux de signalisation, la prédiction des mouvements des véhicules, etc. Il permet aux véhicules autonomes de prendre des décisions en temps réel et de naviguer de manière sécurisée.

6. Finance : Le Deep Learning est utilisé pour l'analyse prédictive des marchés financiers, la détection de fraude, la gestion des risques, le trading automatisé, etc. Il aide les institutions financières à prendre des décisions basées sur des données et à gérer efficacement les risques.

7. Industrie : Le Deep Learning est utilisé pour l'optimisation des processus de fabrication, la maintenance prédictive, la détection d'anomalies dans les systèmes, la robotique, etc. Il améliore l'efficacité et la précision des opérations industrielles.

Ces domaines d'application ne sont qu'un échantillon des nombreux domaines dans lesquels le Deep Learning est utilisé. En général, là où il existe des données complexes et des problèmes nécessitant une compréhension et une interprétation sophistiquées, le Deep Learning peut apporter des solutions prometteuses.

### **2.5. Les Réseaux de neurones**

Tout d'abord, le réseau de neurones est un concept. Ce n'est pas physique. Le concept de réseaux de neurones artificiels (Artificial Neural Networks ANN) (figure 2.5) a été inspiré par les neurones biologiques (figure 13).

Dans un réseau de neurones biologiques, plusieurs neurones travaillent ensemble, reçoivent des signaux d'entrée, traitent des informations et déclenchent un signal de

sortie.

Il s'agit là d'une variété de technologie Deep Learning (apprentissage profond), qui fait elle-même partie de la sous-catégorie d'intelligence artificielle du Machine Learning




Figure 14 Représentation du réseau de neurones humain[12]




Figure 15 Représentation du réseau de neurones artificiel [13]

### 2.5.1. Principe de Fonctionnement des réseaux de neurones

En général, un réseau de neurones repose sur un grand nombre de processeurs fonctionnant en parallèle et organisés en couches. La première couche reçoit les données brutes, semblable aux nerfs optiques chez les êtres humains lorsqu'ils traitent des signaux visuels. Ensuite, chaque couche reçoit les sorties de la couche précédente, reproduisant ainsi le processus chez l'Homme où les neurones reçoivent des signaux des neurones proches du nerf optique. Enfin, la dernière couche produit les résultats du système.

Les réseaux de neurones apprennent à travers un algorithme, permettant à un ordinateur d'apprendre à partir de nouvelles données. Un ordinateur équipé d'un réseau de neurones apprend à effectuer une tâche en analysant des exemples pour s'entraîner. Ces exemples sont préalablement étiquetés afin que le réseau puisse comprendre leur nature.

Par exemple, un réseau de neurones peut être utilisé pour apprendre à un ordinateur à reconnaître des objets. Un grand nombre d'objets d'une même catégorie est présenté au réseau de neurones, et l'ordinateur apprend à reconnaître cet objet sur de nouvelles images en analysant les motifs récurrents dans les images d'exemple. Ainsi, en analysant des milliers de photos de chats, le réseau de neurones apprendra à reconnaître un chat sur n'importe quelle photo.

Contrairement à d'autres types d'algorithmes, les réseaux de neurones ne peuvent pas être programmés directement pour effectuer une tâche. Comme le cerveau en développement d'un enfant, leur seule instruction est d'apprendre.

Il existe cependant trois méthodes d'apprentissage distinctes. Dans le cas de l'apprentissage supervisé, l'algorithme s'entraîne sur un ensemble de données étiquetées et se modifie jusqu'à être capable de traiter le jeu de données pour obtenir le résultat souhaité.

Dans le cas de l'apprentissage non supervisé, les données ne sont pas étiquetées. Le réseau de neurones analyse l'ensemble des données, et une fonction de coût indique dans quelle

mesure il s'éloigne du résultat souhaité. Le réseau s'adapte ensuite pour améliorer la précision de l'algorithme.

Enfin, avec la méthode de l'apprentissage renforcé, le réseau de neurones est renforcé pour les résultats positifs et pénalisé pour les résultats négatifs. Cela lui permet d'apprendre au fil du temps, de la même manière qu'un être humain apprend progressivement de ses erreurs[14].

### **2.5.2. Les principaux composants du réseau de neurones**

Le réseau de neurones est composé des composants principaux suivants :

#### **Neurones : ensemble de fonctions**

Ils prennent une donnée d'entrée et produisent une donnée de sortie. Un certain nombre de neurones sont groupés en couches (ou layers). Tous les neurones du même groupe remplissent un type de fonction similaire.

Les neurones d'entrée reçoivent des données d'entrée, les traitent et les transmettent aux neurones dans la couche suivante. Les neurones cachés prennent les données de sortie des précédents neurones en entrée, calculent de nouvelles données de sortie et les transmettent à des couches successives.

Dans un réseau de neurones à plus de 3 couches (voir schéma ci-dessus), les neurones de la dernière couche cachée (hidden layer) transmettent les données de sortie en entrée des neurones de la couche de sortie (output layer). A partir de cela les neurones de la couche de sortie produisent les données de sortie finales[15].

### **Couches : groupement de neurones**

Les couches (ou layers) contiennent des neurones et aident à faire circuler l'information. Il existe au moins deux couches dans un réseau de neurones : la couche d'entrée (input layer) et la couche de sortie (output layer).

Il est tout à fait possible d'avoir un (très) grand nombre de couches dans un réseau de neurones complexe. Plus il y aura de couches, plus le réseau sera profond (deep learning). Les couches, autres que les couches d'entrée et de sortie, sont appelées les couches cachées (ou hidden layers)[15].

### **Poids et biais : valeurs numériques**

Les poids et biais sont des variables du modèle qui sont mises à jour pour améliorer la précision du réseau. Un poids est appliqué à l'entrée de chacun des neurones pour calculer une donnée de sortie.

Les réseaux de neurones mettent à jour ces poids de manière continue. Il existe donc une boucle de rétro-action mise en œuvre dans la plupart des réseaux de neurones. Les biais sont également des valeurs numériques qui sont ajoutées une fois que les poids sont appliqués aux valeurs d'entrée. Les poids et les biais sont donc en quelque sorte des valeurs d'auto-apprentissage de nos réseaux de neurones[15].

### **Fonction d'activation :**

Algorithmes mathématiques appliqués aux valeurs de sortie Les fonctions d'activation lissent ou normalisent la donnée de sortie avant qu'elle ne soit transmise aux neurones suivants. Ces fonctions aident les réseaux de neurones à apprendre et à s'améliorer. [15]

### **2.5.3. Le perceptron**

Le Perceptron est en effet une fonction mathématique qui effectue des calculs sur les données d'entrée en multipliant les coefficients de poids correspondants. Le résultat obtenu est une valeur, et en fonction de cette valeur, le neurone artificiel s'active ou ne s'active pas.

L'algorithme du Perceptron est utilisé pour l'apprentissage supervisé de classificateurs binaires. Les poids du Perceptron sont ajustés itérativement en fonction des erreurs de classification commises sur les exemples d'entraînement. L'objectif est de minimiser l'erreur en modifiant les poids de manière appropriée.

Lorsqu'une nouvelle donnée est présentée au Perceptron, le résultat prédit est comparé à la valeur connue (la classe réelle). Si une différence est observée, une rétropropagation de l'erreur est effectuée pour ajuster les poids et améliorer les prédictions futures.


Le Perceptron joue un rôle essentiel dans les projets de Machine Learning, car il est utilisé pour classifier les données et peut être utilisé comme algorithme de base pour améliorer les capacités d'apprentissage des classificateurs binaires [16].

#### **L'apprentissage du Perceptron**

Selon la Perceptron Learning Rule (règle d'apprentissage du Perceptron), l'algorithme apprend automatiquement les coefficients de poids optimaux. Les caractéristiques des données d'entrée sont multipliées par ces poids, afin de déterminer si un neurone "s'allume" ou non.

Le Perceptron reçoit de multiples signaux d'entrée. Si la somme des signaux excède un certain seuil, un signal est produit ou au contraire aucun résultat n'est émis.

Dans le cadre de la méthode d'apprentissage supervisé de Machine Learning, c'est ce qui permet de prédire la catégorie d'un échantillon de données. Il s'agit donc d'un élément essentiel[17].



**Figure 16 Représentation d'un simple réseau de neurones perceptron[18]**

### **Le fonctionnement du Perceptron**

le Perceptron est en effet une fonction mathématique qui effectue des calculs sur les données d'entrée en multipliant les coefficients de poids correspondants. Le résultat obtenu est une valeur, et en fonction de cette valeur, le neurone artificiel s'active ou ne s'active pas.

L'algorithme du Perceptron est utilisé pour l'apprentissage supervisé de classificateurs binaires. Les poids du Perceptron sont ajustés itérativement en fonction des erreurs de classification commises sur les exemples d'entraînement. L'objectif est de minimiser l'erreur en modifiant les poids de manière appropriée.

Lorsqu'une nouvelle donnée est présentée au Perceptron, le résultat prédit est comparé à la valeur connue (la classe réelle). Si une différence est observée, une rétropropagation de l'erreur est effectuée pour ajuster les poids et améliorer les prédictions futures.

Le Perceptron joue un rôle essentiel dans les projets de Machine Learning, car il est utilisé pour classifier les données et peut être utilisé comme algorithme de base pour améliorer les capacités d'apprentissage des classificateurs binaires [16].

### **Perceptron à couche unique vs multicouches**

On distingue deux types de Perceptron : À couche unique et multicouches.

→ Un Perceptron à couche unique peut apprendre uniquement des fonctions linéaires séparables.

→ Un Perceptron à couches multiples, aussi appelé réseau neuronal " feed-forward ", permet de surmonter cette limite et offrent une puissance de calcul supérieure. Il est aussi possible de combiner plusieurs Perceptron pour créer un puissant mécanisme

### **Perceptron et réseaux de neurones**

En résumé, un réseau de neurones est un ensemble de Perceptrons interconnectés. Son fonctionnement repose sur des opérations de multiplication entre deux composants importants : les entrées de données (input) et le poids. La somme de cette multiplication est transmise à une fonction d'activation, déterminant une valeur binaire de 0 ou 1. C'est ce qui permet de classifier les données[16].

#### **2.5.4. Les différents types de réseaux de neurones**

Il existe différents types de réseaux de neurones. Les deux réseaux de neurones les plus populaires sont :

#### **Réseau de neurones récurrent – Recurrent Neural Network (RNN):**

Ce sont des réseaux de neurones spécialisés qui utilisent le contexte des entrées lors du calcul de la sortie. La sortie dépend des entrées et des sorties calculées précédemment. Ainsi, les RNN conviennent aux applications où les informations historiques sont importantes. Ces réseaux nous aident à prévoir les séries chronologiques dans les applications commerciales et à prévoir les mots dans les applications de type chatbot. Ils



peuvent fonctionner avec différentes longueurs d'entrée et de sortie et nécessitent une grande quantité de données[15].

### **Réseau de neurones convolutif – Convolution Neural Network (CNN):**

Ces réseaux reposent sur des filtres de convolution (matrices numériques). Les filtres sont appliqués aux entrées avant que celles-ci ne soient transmises aux neurones. Ces réseaux de neurones sont utiles pour le traitement et la prévision des signaux et d'images.

Comparés à d'autres algorithmes de classification, les réseaux de neurones convolutifs utilisent relativement peu de prétraitement. 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 [15].

À la recherche d'une architecture de réseau robuste et indépendante des techniques d'extraction de caractéristiques, avec de bonnes performances pour la classification des signaux bruyants, Nauman Munir, ingénieur du département de Mécanique à l'Université Sungkyunkwan et chercheur à l'Institut nucléaire en Corée, a réalisé une comparaison dans son article [16] entre la convolution des réseaux de neurones (CNN) et d'autres architectures pour la classification des défauts de soudures. L'ingénieur a conclu que les CNN ont donné de meilleurs résultats dans des conditions bruyantes.

Cette conclusion nous a conduits à choisir les réseaux de neurones CNN pour notre application.

## **2.6. Convolution Neural Network (CNN)**

Les réseaux de neurones convolutifs (CNN ou ConvNet - Convolutional Neural Network) sont un type spécifique de réseaux de neurones à plusieurs couches, souvent utilisés dans le traitement d'images. Ils ont été initialement introduits par Fukushima en 1980 pour la reconnaissance de formes, en s'inspirant de l'architecture du cortex visuel des animaux. Les CNNs ont ensuite gagné en popularité pour la reconnaissance de caractères. Aujourd'hui, les

CNNs sont largement utilisés dans diverses applications d'intelligence artificielle dans le domaine du traitement automatique des langues, notamment pour la classification de texte, la classification de musique et d'environnements sonores, ainsi que le traitement du signal[16].

### **2.6.1 Le principe de la CNN**

Le réseau neuronal convolutionnel (CNN) est un type de réseau neuronal profond qui comprend des couches convolutionnelles et des couches entièrement connectées. La convolution est une opération mathématique largement utilisée dans le traitement du signal. Dans un réseau neuronal convolutif, les couches convolutionnelles utilisent en réalité la corrélation croisée, qui est techniquement très similaire à la convolution.

Un réseau neuronal convolutif comporte deux couches importantes : les couches d'extraction de caractéristiques et les couches de classification. Les couches convolutionnelles et les couches de mise en commun sont des couches d'extraction de caractéristiques, tandis que les couches de classification sont entièrement connectées.

Contrairement aux couches entièrement connectées, les couches convolutionnelles ne sont pas connectées à tous les nœuds de la couche d'entrée, mais seulement à des régions locales spécifiques basées sur les filtres/convolutions définis. Cette architecture permet au réseau de se concentrer sur les caractéristiques de bas niveau, qui sont ensuite combinées pour former des caractéristiques de haut niveau. Le CNN est également capable d'apprendre des motifs [19].

Nous utiliserons un CNN pour la classification des défauts détectés par le contrôle non destructif par ultrasons.

## 6-2. Les dimensions de la CNN

Il existe 3 types d'opérations de convolution avec différentes dimensions 1D, 2D et 3D. La différence entre ces types de convolution s'exprime essentiellement au niveau des tailles des filtres, du nombre de direction de mouvement des filtres sur l'entrée A ainsi que de la dimension de la carte de caractéristiques produite en sortie. [19]

**CNN 1 dimensionnel | Conv1D** : elle est utilisée sur les séries temporelles, les données audio et textuelles car nous pouvons également représenter le son et les textes comme des données de séries temporelles.

**CNN à 2 dimensions | Conv2D** : Il s'agit du réseau neuronal à convolution standard qui a été introduit pour la première fois dans l'architecture LeNet-5. Conv2D est généralement utilisé sur des données d'image. Il est appelé CNN bidimensionnel parce que le noyau glisse le long de deux dimensions sur les données.

**CNN tridimensionnel | Conv3D** : elle est utilisée avec des données d'images 3D. Comme les données d'imagerie par résonance magnétique (IRM). Les données IRM sont largement utilisées pour examiner le cerveau, la moelle épinière, les organes internes, etc.

### 2.6.3. Les principaux composants du CNN

Le CNN est composé de trois types de couches (ou "layers" en anglais) : les couches convolutionnelles (convolutional layers), les couches de pooling (pooling layers) et les couches entièrement connectées (fully-connected layers ou FC). Lorsqu'elles sont empilées, ces couches forment l'architecture du CNN. En plus de ces trois types de couches, il existe trois autres paramètres importants : les couches d'élimination aléatoire (dropout layers), la fonction d'activation (activation function) et la fonction de perte (loss function). Ces paramètres sont définis comme suit [20].

### 1D Convolutional layers

Cette couche est la première couche qui est utilisée pour extraire les différentes caractéristiques du Data d'entrée. Dans cette couche, l'opération mathématique de convolution est effectuée entre le Data d'entrée et un filtre d'une taille particulière  $M \times M$ . En faisant glisser le filtre sur le Data, le produit scalaire est pris entre le filtre et les parties du




Figure 17 exemple d'un filtre de convolution 1D[21]

Data d'entrée par rapport à la taille du filtre ( $M \times M$ )[20].

Pour chaque couche de convolution il existe une fonction d'activation L'un des paramètres les plus importants du modèle CNN. Elles sont utilisées pour apprendre et approximer tout type de relation continue et complexe entre les variables du réseau. En d'autres termes, elle décide quelles informations du modèle doivent être tirées dans la direction avant et lesquelles ne doivent pas l'être à la fin du réseau. Elle ajoute une non-linéarité au réseau. Il existe plusieurs fonctions d'activation couramment utilisées, telles que les fonctions ReLU, Softmax, Linear, TanH et Sigmoid (figure 17) [20].

Chacune de ces fonctions à un usage spécifique. Pour un modèle CNN de classification binaire, les fonctions sigmoïdes et softmax sont préférées et pour une classification multi-classes, on utilise généralement softmax.

A la fin La sortie est appelée carte de caractéristiques qui nous donne des informations sur le Data. Plus tard, cette est introduite dans d'autres couches pour apprendre plusieurs autres caractéristiques du Data d'entrée.




Figure 18 Les fonctions D'activation[22]

### Pooling layers

Une couche convolutive est généralement suivie d'une couche de mise en commun. Cette dernière a pour objectif principal de réduire la taille de la carte de caractéristiques obtenue après la convolution, ce qui permet de réduire les coûts de calcul. Pour ce faire, les connexions entre les couches sont réduites et des opérations indépendantes sont appliquées sur chaque carte de caractéristiques. Selon la méthode utilisée, il existe plusieurs types d'opérations de pooling. [20]

Dans le cas du Maxpooling, l'élément le plus grand de la carte de caractéristiques est extrait. Le pooling moyen calcule la moyenne des éléments dans une section d'image de taille prédéfinie. Le Sum Pooling, quant à lui, calcule la somme totale des éléments dans la section

prédéfinie. La couche de pooling joue généralement le rôle de liaison entre la couche convolutive et la couche entièrement connectée (FC). [23]




Figure 19 Exemple sur le Maxpooling[24]

### Fully-connected layers(FC)

La couche entièrement connectée (FC) est constituée de poids, de biais et de neurones, et elle est utilisée pour établir des connexions entre les neurones de deux couches différentes. Ces couches sont généralement positionnées avant la couche de sortie et constituent les dernières couches d'une architecture CNN .

Dans cette couche, les données des couches précédentes sont aplaties et transmises à la couche FC. Le vecteur aplati passe ensuite par plusieurs couches FC supplémentaires où des opérations mathématiques sont généralement effectuées. À ce stade, le processus de classification commence à se dérouler. [13]




Figure 20 Représentation des fully-connected Layers [24]

## Dropout layers

Lorsque toutes les caractéristiques sont connectées à la couche FC, cela peut souvent conduire à un surajustement des données d'apprentissage. Le surajustement se produit lorsque le modèle fonctionne si bien sur les données d'apprentissage qu'il a un impact négatif sur ses performances lorsqu'il est utilisé avec de nouvelles données [23].

Pour surmonter ce problème, une technique couramment utilisée est l'utilisation d'une couche de dropout (exclusion), où certains neurones sont temporairement supprimés du réseau neuronal pendant le processus d'entraînement. Cela permet de réduire la taille du modèle. Lorsque le taux de dropout est fixé à 0,3, par exemple, cela signifie que 30 % des nœuds sont aléatoirement éliminés du réseau neuronal.




Figure 21 exemple sur le fonctionnement des Dropout Layers[24]

## Loss function

Une fonction de perte, ou Loss function, est une fonction qui évalue l'écart entre les prédictions réalisées par le réseau de neurones et les valeurs réelles des observations utilisées pendant l'apprentissage. Plus le résultat de cette fonction est minimisé, plus le réseau de neurones est performant. Sa minimisation, c'est-à-dire réduire au minimum l'écart entre la

valeur prédite et la valeur réelle pour une observation donnée, se fait en ajustant les différents poids du réseau de neurones [13]

## **2.7. Description des modèles utilisés**

### **CNN**

Les Convolutional Neural Networks (CNN) sont un type de réseau neuronal profond qui a une histoire riche depuis leur proposition initiale dans les années 1980. Leur popularité a connu une croissance exponentielle grâce aux avancées technologiques, notamment l'abondance de données d'images, la puissance de calcul accrue et l'amélioration des architectures. L'évaluation d'un modèle CNN est un processus essentiel, impliquant l'entraînement sur un ensemble de données étiquetées, suivi de la validation sur un ensemble distinct pour éviter le surajustement, et enfin, l'évaluation sur un ensemble de test indépendant.

L'architecture d'un modèle CNN joue un rôle crucial dans son efficacité. Elle est composée de couches de convolution, qui extraient des caractéristiques spécifiques des images à l'aide de filtres, de couches de pooling pour réduire la dimension des caractéristiques et des couches entièrement connectées pour la classification finale. Diverses architectures populaires de CNN, telles que LeNet, AlexNet, VGG, GoogLeNet (Inception), ResNet, etc., ont vu le jour avec des différences de taille, de filtres et de techniques de régularisation.

Grâce à la recherche continue en intelligence artificielle et à l'utilisation de vastes ensembles de données d'images, les CNN ont considérablement progressé, devenant des outils essentiels pour le traitement des images, la reconnaissance de motifs visuels et d'autres tâches liées à la vision par ordinateur. Leur potentiel est de plus en plus exploité dans divers domaines, démontrant leur importance continue dans l'évolution de l'apprentissage automatique et de l'intelligence artificielle.

### **LeNet**

Le modèle LeNet est l'un des premiers Convolutional Neural Networks (CNN) développés par Yann LeCun et ses collègues dans les années 1990. Son histoire marque un jalon important dans le domaine du traitement des images par les réseaux neuronaux.



Pour évaluer le modèle LeNet, il passe par un processus d'entraînement sur un ensemble de données étiquetées, suivi d'une validation pour éviter le surajustement, et enfin une évaluation sur un ensemble de test indépendant. Cette approche permet de mesurer l'efficacité du modèle dans la reconnaissance de motifs visuels spécifiques.

Quant à l'architecture du modèle LeNet, elle est relativement simple mais novatrice pour son époque. Le modèle se compose de couches alternées de convolution et de pooling, permettant d'extraire progressivement les caractéristiques des images. Les couches de convolution utilisent des filtres pour détecter les motifs locaux, tandis que les couches de pooling réduisent les dimensions spatiales des caractéristiques extraites. Le modèle se termine par des couches entièrement connectées pour la classification finale.

LeNet a été initialement conçu pour la reconnaissance de chiffres manuscrits et a été largement utilisé dans le domaine de la reconnaissance optique de caractères (OCR). Bien que son architecture soit relativement simple par rapport aux modèles modernes, LeNet a ouvert la voie à des développements plus avancés dans le domaine des CNN et a jeté les bases des architectures de réseaux neuronaux utilisées aujourd'hui.

### **AlexNet**

Le modèle AlexNet est un autre jalon important dans l'histoire des Convolutional Neural Networks (CNN), développé par Alex Krizhevsky, Ilya Sutskever et Geoffrey Hinton en 2012. Son architecture novatrice et ses résultats exceptionnels ont révolutionné le domaine de la vision par ordinateur.

L'évaluation du modèle AlexNet suit un processus similaire aux autres CNN. Il est entraîné sur un vaste ensemble de données étiquetées, puis validé sur un ensemble distinct pour éviter le surajustement, et enfin évalué sur un ensemble de test indépendant pour mesurer ses performances réelles.

L'architecture du modèle AlexNet est plus profonde et complexe que celle du modèle LeNet. Elle comprend cinq couches de convolution, alternant avec des couches de pooling, pour extraire des caractéristiques à différentes échelles spatiales. Le modèle utilise également des couches entièrement connectées, suivies d'une couche softmax pour la classification.

Un élément clé qui a contribué au succès d'AlexNet est l'utilisation de la fonction d'activation ReLU (Rectified Linear Unit), qui a permis de surmonter le problème de la disparition du gradient et d'accélérer l'apprentissage du réseau.

En 2012, AlexNet a remporté le concours ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en obtenant une réduction significative de l'erreur de classification par rapport aux méthodes traditionnelles. Cela a marqué le début de l'ère moderne des CNN et a démontré leur puissance dans le traitement des images et la reconnaissance visuelle.

### **VGG19**

VGG19 est un autre modèle de Convolutional Neural Network (CNN) influent, développé par les chercheurs du Visual Geometry Group (VGG) de l'Université d'Oxford en 2014. Il fait partie de la série VGG, qui comprend différents modèles avec des architectures de plus en plus profondes.

L'évaluation de VGG19 suit le processus standard d'entraînement, de validation et de test sur des ensembles de données étiquetées. Comme d'autres CNN, il est entraîné sur un grand ensemble de données d'images, puis validé pour optimiser ses performances, et enfin testé sur un ensemble de test indépendant pour évaluer ses performances réelles.

L'architecture de VGG19 est remarquablement profonde avec 19 couches, d'où son nom "VGG19". Elle se compose principalement de couches de convolution de petite taille (filtres 3x3) et de couches de pooling pour extraire progressivement les caractéristiques de l'image. Le modèle comprend également des couches entièrement connectées pour la classification finale.

Une caractéristique notable de VGG19 est l'utilisation répétée de blocs de couches avec des convolutions de 3x3. Cela conduit à des modèles très profonds, mais également à une architecture simple et homogène, ce qui facilite leur implémentation et leur compréhension.

VGG19 a démontré des performances remarquables sur diverses tâches de reconnaissance d'images et a été très influent dans le domaine de la vision par ordinateur. Il a été l'un des premiers modèles à montrer que des réseaux plus profonds pouvaient obtenir de meilleures performances, stimulant ainsi la recherche sur les architectures de CNN plus profondes et plus sophistiquées.

Bien que de nombreux modèles CNN plus récents aient été développés depuis, VGG19 reste une référence dans le domaine et a inspiré de nombreuses autres architectures de réseau neuronal. Son impact se fait toujours sentir dans l'avancement de l'apprentissage profond et de l'intelligence artificielle en général.

### **Efficient Net**

EfficientNet est un modèle de Convolutional Neural Network (CNN) développé par Mingxing Tan et Quoc V. Le, des chercheurs de Google, en 2019. Ce modèle a été conçu pour être à la fois puissant et efficace en termes de performances et de taille.

L'évaluation du modèle EfficientNet suit également les étapes standard d'entraînement, de validation et de test sur des ensembles de données étiquetées. Comme pour les autres CNN, il est entraîné sur un grand ensemble de données d'images, puis validé pour optimiser ses performances, et finalement testé sur un ensemble de test indépendant pour évaluer ses performances réelles.

L'architecture d'EfficientNet se distingue par l'utilisation d'un mécanisme d'optimisation composé de trois paramètres : la largeur du modèle, la profondeur du modèle et la résolution d'entrée. Les concepteurs d'EfficientNet ont utilisé une approche d'échelle uniforme pour augmenter la taille du modèle de manière équilibrée en utilisant ces trois paramètres, ce qui a permis d'obtenir une architecture performante avec un bon équilibre entre précision et efficacité.

Grâce à cette approche, EfficientNet a obtenu des performances de pointe sur plusieurs tâches de vision par ordinateur tout en étant plus léger que certains autres modèles de pointe. Cette légèreté rend EfficientNet plus facile à déployer sur des dispositifs avec des ressources limitées, tels que les appareils mobiles et les systèmes embarqués.

EfficientNet a eu un impact significatif dans le domaine de la vision par ordinateur et a suscité un grand intérêt pour l'optimisation de l'efficacité des modèles CNN. Depuis sa publication, de nombreux autres modèles "efficients" ont été développés, basés sur des principes similaires d'optimisation des performances et de la taille du modèle. Cela montre l'importance d'EfficientNet en tant que référence et source d'inspiration pour la recherche continue en apprentissage profond et en intelligence artificielle.

## 2.8. Conclusion

Dans ce chapitre, notre objectif était d'explorer l'utilisation des réseaux de neurones convolutifs pour proposer une nouvelle approche de classification des défauts de soudure. Nous avons commencé par introduire l'intelligence artificielle et l'apprentissage automatique (machine learning). Ensuite, nous avons présenté les réseaux de neurones et leurs différents types, ainsi que les choix d'architecture et le fonctionnement de base d'un réseau de neurones convolutif. Nous avons détaillé les différents blocs de construction, notamment l'entrée du réseau, l'opération de convolution, l'opération de pooling, ainsi que les fonctions d'activation et de perte qui permettent d'adapter la sortie du réseau en fonction de la tâche de classification visée.

## **Chapitre 3 : Expérimentation et Résultats**

### **3.1. Introduction**

Dans ce chapitre, nous allons procéder à l'étude des résultats obtenus. Tout d'abord, nous allons présenter les logiciels et bibliothèques utilisés dans l'implémentation, ainsi que la base de données. Ensuite, nous allons introduire les différentes architectures utilisées. Après l'exécution de tous les modèles, nous passerons à la discussion des résultats

### **3.2. Logiciels et Bibliothèques**

#### **3.2.1. Google Colab**

Colab, également connu sous le nom complet de Google Colaboratory, est une plateforme en ligne gratuite basée sur le cloud qui permet l'exécution de code Python. Elle est principalement utilisée pour le développement et l'exécution de projets de Data Science et de Machine Learning.

Colab fournit un environnement de développement intégré (IDE) dans lequel vous pouvez écrire et exécuter du code Python, notamment des blocs-notes Jupyter. Il offre également un accès gratuit à des ressources de calcul, y compris des processeurs graphiques (GPU) et des unités de traitement tensoriel (TPU) pour accélérer les calculs intensifs.

Une caractéristique notable de Colab est qu'il permet la collaboration en temps réel. Plusieurs utilisateurs peuvent travailler sur un même bloc-notes, ce qui facilite le partage et la collaboration sur des projets de Data Science.

Colab est populaire en raison de sa facilité d'utilisation, de son intégration avec d'autres outils et services Google, et de sa prise en charge de nombreuses bibliothèques populaires de Python utilisées dans le domaine de l'apprentissage automatique.



**Figure 22 Logo de Google Colab[25]**

### **3.2.2. TensorFlow**

TensorFlow est une bibliothèque de logiciels gratuits et à code source ouvert pour le flux de données et la programmation différentiable dans diverses tâches. C'est une bibliothèque mathématique symbolique, qui est également utilisée pour des applications d'apprentissage automatique telles que les réseaux de neurones. Il est utilisé à la fois pour la recherche et la production chez Google.

Son nom est notamment inspiré du fait que les opérations courantes sur des réseaux de neurones sont principalement faites via des tables de données multidimensionnelles, appelées Tenseurs (Tensor). Un Tensor à deux dimensions est l'équivalent d'une matrice. Aujourd'hui, les principaux produits de Google sont basés sur TensorFlow : Gmail, Google Photos, Reconnaissance de voix.



**Figure 23** Logo de TensorFlow[26]

### 3.2 .3. Keras

Keras est une bibliothèque de réseau de neurones open source écrite en Python. Il est capable de fonctionner sur TensorFlow, Microsoft Cognitive Toolkit, Theano ou PlaidML. Conçu pour permettre une expérimentation rapide avec des réseaux de neurones profonds, il se veut convivial, modulaire et extensible. Il a été développé dans le cadre des efforts de recherche du projet ONEIROS (système d'exploitation de robot intelligent neuroélectronique à extrémité ouverte), et son auteur et responsable principal est François Chollet, ingénieur chez Google.

En 2017, l'équipe TensorFlow de Google a décidé de prendre en charge Keras dans la bibliothèque principale de TensorFlow. Chollet a expliqué que Keras avait été conçu pour être une interface plutôt qu'un cadre autonome d'apprentissage automatique. Il offre un ensemble d'abstractions de niveau supérieur et plus intuitif facilitant le développement de modèles d'apprentissage en profondeur, quel que soit le système de traitement utilisés.






**Figure 24 Logo de Keras[27]**

### 3.3. La base de données

Ensemble de données RIAWELC, disponible gratuitement sur <https://github.com/stefyste/RIAWELC>. Dans sa première version, il contient 24 407 images radiographiques de taille 224x224 pixels, couvrant quatre classes (3 défaut + absence de défaut) :

- Manque de pénétration (LP),
- Fissures (CR),
- Porosité (PO)
- Absence de défaut (ND).

Bien entendu, cet ensemble de données peut être étendu pour inclure d'autres défauts d'intérêt. Le nombre d'images collectées dans l'ensemble de données RIAWELC permet de soutenir les méthodes d'identification et de classification automatiques des défauts de soudage, ce qui est essentiel pour réaliser des inspections et des contrôles qualité fiables. [14]



**Figure 25 Base de données [37]**

### **3.4. Architecture**

#### **3.4.1. Choix de l'architecture**

Le problème majeur dans les réseaux CNN réside dans le choix d'une architecture adaptée à la base de données afin d'obtenir un taux de précision élevé en sortie. Le défi consiste à sélectionner les hyperparamètres qui définissent le réseau choisi, tels que :

- Le nombre et la taille des couches de convolution, avec le pas de progression "Stride" et le remplissage par zéro "Padding".
- La taille des couches de pooling.
- Le nombre de couches entièrement connectées (FC) et le nombre de neurones utilisés dans chacune.
- Le pourcentage de dropout et le type d'activation sélectionné (ReLU, Softmax, etc.).

Il est également important de noter que le nombre d'images constituant la base de données joue un rôle essentiel dans l'entraînement du réseau. En effet, plus le nombre d'images est important, meilleure sera la précision atteinte après la phase d'apprentissage. Dans le cas où le nombre d'images de la base de données est limité, il est nécessaire d'utiliser des techniques d'augmentation de données afin d'augmenter le nombre d'images présentées en entrée du réseau. Ce processus est expliqué dans le chapitre précédent.

Tous les paramètres mentionnés requièrent une bonne connaissance des réseaux CNN pour les appliquer correctement et choisir leurs valeurs de manière à améliorer la précision du réseau entraîné en sortie. Il est peu probable d'atteindre la précision maximale dès le premier

entraînement, il est donc recommandé de modifier les paramètres, ce qui fait la différence entre différentes architectures.

### **3.4.2. Architectures utilisées**

Au cours de nos expérimentations, nous avons divisé notre travail en deux étapes. La première consiste à utiliser des architectures simples avec des paramètres différents, puis à lancer l'entraînement pour observer le comportement du réseau avec la base de données et déterminer quelle architecture offre la meilleure précision.

La deuxième étape consiste à sélectionner l'architecture la plus performante en fonction des résultats de la première étape, ainsi que d'autres paramètres, afin d'obtenir un niveau de précision maximal.

En suivant cette approche, nous avons pu évaluer différentes architectures et leurs performances, ce qui nous a permis de prendre des décisions éclairées pour optimiser la précision de notre réseau.

#### **Modèle 1(CNN)**

L'architecture du modèle que nous avons fournie est un réseau de neurones convolutif (CNN) avec les couches suivantes :

1. Couche Conv2D : Cette couche contient 32 filtres de taille 3x3 et utilise la fonction d'activation ReLU. Elle prend en entrée des données de forme (256, 256, 1), où 1 représente un canal unique (image en niveaux de gris).
2. Couche MaxPooling2D : Cette couche effectue un max pooling avec une taille de pool de 2x2, ce qui réduit les dimensions spatiales de moitié.
3. Couche Conv2D : Cette couche contient 64 filtres de taille 3x3 et utilise la fonction d'activation ReLU.

4. Couche MaxPooling2D : Cette couche effectue un max pooling avec une taille de pool de 2x2, réduisant davantage les dimensions spatiales de moitié.

5. Couche Flatten : Cette couche aplatit la sortie de la couche précédente en un vecteur unidimensionnel.

6. Couche Dense : Cette couche contient 64 unités et utilise la fonction d'activation ReLU.

7. Couche Dense : Il s'agit de la couche de sortie avec 4 unités, représentant le nombre de classes dans votre problème de classification. Elle utilise la fonction d'activation softmax pour produire les probabilités de classe.

Cette architecture typique de CNN est couramment utilisée pour des tâches de classification d'images. Cependant, il est important de noter que l'architecture optimale peut varier en fonction de la nature spécifique du problème et de l'ensemble de données. Il est souvent nécessaire d'expérimenter avec différentes architectures et hyperparamètres pour obtenir les meilleurs résultats.

=

```
# Define the model architecture
model = Sequential() # Crée un objet de modèle séquentiel

model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(256, 256, 1)))
# Ajoute une couche de convolution avec 32 filtres, une taille de noyau de 3x3 et une fonction d'activation ReLU.
# L'entrée de cette couche est de forme (256, 256, 1).

model.add(MaxPooling2D((2, 2)))
# Ajoute une couche de pooling max avec une fenêtre de pooling de taille 2x2.

model.add(Conv2D(64, (3, 3), activation='relu'))
# Ajoute une deuxième couche de convolution avec 64 filtres, une taille de noyau de 3x3 et une fonction d'activation ReLU.

model.add(MaxPooling2D((2, 2)))
# Ajoute une deuxième couche de pooling max avec une fenêtre de pooling de taille 2x2.

model.add(Flatten())
# Ajoute une couche de mise à plat (flatten) pour convertir les activations en un vecteur unidimensionnel.

model.add(Dense(64, activation='relu'))
# Ajoute une couche dense (entièrement connectée) avec 64 neurones et une fonction d'activation ReLU.

model.add(Dense(4, activation='softmax'))
# Ajoute une dernière couche dense avec 4 neurones (correspondant aux 4 classes possibles) et une fonction d'activation softmax
# pour la classification multi-classes.
```

**Figure 26 Architecture du modèle 1 .**

## Modèle 2 (LeNet)

L'architecture LeNet est un modèle de réseau de neurones convolutifs (CNN) pionnier dans le domaine de la reconnaissance d'images. Elle a été proposée par Yann LeCun dans les années 1990 et a jeté les bases des CNN modernes. LeNet a été utilisée avec succès pour la reconnaissance de chiffres manuscrits.

L'architecture du modèle comprend les couches suivantes :

1. Couche d'entrée (InputLayer) : Cette couche attend des données d'entrée de forme (None, 256, 256, 3), indiquant des images de taille 256x256 avec 3 canaux de couleur (Rouge, Vert, Bleu).
2. Couche de normalisation des pixels (Rescaling) : Cette couche est utilisée pour normaliser les valeurs des pixels de l'image entre 0 et 1 en divisant chaque pixel par 255.
3. Couches de convolution (Conv2D) : Les deux couches Conv2D appliquent chacune une convolution avec des filtres de taille 3x3 et utilisent la fonction d'activation ReLU pour introduire de la non-linéarité.
4. Couche de pooling (MaxPooling2D) : La première couche de pooling réduit les dimensions spatiales de l'image en prenant le maximum dans chaque région de taille 2x2.
5. Couche de dropout (Dropout) : Cette couche désactive aléatoirement 20% des neurones pour prévenir le surapprentissage.
6. Couche de normalisation par lots (BatchNormalization) : Cette couche normalise les activations de la couche précédente pour accélérer l'apprentissage et améliorer la stabilité du modèle.
7. Couche de bruit gaussien (GaussianNoise) : Cette couche ajoute du bruit gaussien avec une variance de 0.1 pour régulariser le modèle et le rendre plus robuste aux variations.

8. Autres couches de convolution (Conv2D) : Les deux couches Conv2D suivantes appliquent une autre série de convolutions avec des filtres de taille 3x3, suivies de la fonction d'activation ReLU.

9. Deuxième couche de pooling (MaxPooling2D) : Cette couche réduit à nouveau les dimensions spatiales en prenant le maximum dans chaque région de taille 2x2.

10. Couche de dropout spatiale (SpatialDropout2D) : Cette couche désactive aléatoirement 20% des canaux d'activation entiers au lieu des neurones individuels, préservant ainsi les informations spatiales pour prévenir le surapprentissage.

11. Couche de normalisation par lots (BatchNormalization) : Une autre couche de normalisation par lots est appliquée pour normaliser les activations.

12. Dernière couche de convolution (Conv2D) : Cette couche applique une autre convolution avec des filtres de taille 3x3 et une activation ReLU.

13. Couche d'aplatissement (Flatten) : Cette couche transforme la représentation spatiale des données en un vecteur unidimensionnel pour être utilisée comme entrée dans les couches denses.

14. Couches denses (Dense) : Les trois couches Dense suivantes introduisent de la complexité et des interactions non linéaires dans le modèle. Elles utilisent la fonction d'activation ReLU.

15. Couches de dropout (Dropout) : Les couches Dropout désactivent aléatoirement 30% des neurones pour prévenir le surapprentissage.

16. Couche de sortie (Dense) : La dernière couche Dense est la couche de sortie qui produit les prédictions finales. Elle utilise la fonction d'activation softmax pour donner des probabilités pour chaque classe de sortie.

Ces différentes couches et activations sont conçues pour extraire progressivement les caractéristiques des images en entrée et effectuer une classification précise.

```

model = models.Sequential() # Crée un objet de modèle séquentiel

# Input layer
model.add(keras.Input(shape=image_size + (3,))) # Couche d'entrée avec la forme spécifiée
model.add(layers.experimental.preprocessing.Rescaling(1./255)) # Rééchelle les valeurs des pixels entre 0 et 1

# Convolutional layers
model.add(layers.Conv2D(32, (3,3), padding='SAME', activation='relu')) # Couche de convolution avec 32 filtres et une taille de noyau de 3x3
model.add(layers.Conv2D(32, (3,3), padding='SAME', activation='relu')) # Couche de convolution avec 32 filtres et une taille de noyau de 3x3
model.add(layers.MaxPool2D()) # Couche de pooling max
model.add(layers.Dropout(0.2)) # Couche de dropout pour régulariser et prévenir le surapprentissage
model.add(layers.BatchNormalization()) # Couche de normalisation des lots
model.add(layers.GaussianNoise(0.1)) # Couche d'ajout de bruit gaussien
model.add(layers.Conv2D(64, (3,3), padding='SAME', activation='relu')) # Couche de convolution avec 64 filtres et une taille de noyau de 3x3
model.add(layers.Conv2D(64, (3,3), padding='SAME', activation='relu')) # Couche de convolution avec 64 filtres et une taille de noyau de 3x3
model.add(layers.MaxPool2D()) # Couche de pooling max
model.add(layers.Dropout(0.2)) # Couche de dropout pour régulariser et prévenir le surapprentissage
model.add(layers.SpatialDropout2D(0.2)) # Couche de dropout 2D pour régulariser et prévenir le surapprentissage en 2D
model.add(layers.BatchNormalization()) # Couche de normalisation des lots
model.add(layers.Conv2D(128, (3,3), padding='SAME', activation='relu')) # Couche de convolution avec 128 filtres et une taille de noyau de 3x3

# Dense layers
model.add(layers.Flatten()) # Couche de mise à plat pour convertir les activations en un vecteur unidimensionnel
model.add(layers.Dense(512, activation='relu', activity_regularizer=tf.keras.regularizers.l2(0.001))) # Couche dense avec 512 neurones et une fonction d'activation ReLU
model.add(layers.Dropout(0.3)) # Couche de dropout pour régulariser et prévenir le surapprentissage
model.add(layers.Dense(256, activation='relu', activity_regularizer=tf.keras.regularizers.l2(0.001))) # Couche dense avec 256 neurones et une fonction d'activation ReLU
model.add(layers.Dense(128, activation='relu', activity_regularizer=tf.keras.regularizers.l2(0.001))) # Couche dense avec 128 neurones et une fonction d'activation ReLU
model.add(layers.Dropout(0.2)) # Couche de dropout pour régulariser et prévenir le surapprentissage
model.add(layers.Dense(num_classes, activation='softmax', activity_regularizer=tf.keras.regularizers.l2(0.001))) # Couche dense de sortie avec une fonction d'activation softmax

```

Figure 27 Architecture du modèle 2 .

### Modèle 3 (AlexNet)

AlexNet est un modèle de réseau de neurones convolutionnels (CNN) introduit en 2012, qui a révolutionné la classification d'images en obtenant des résultats remarquables sur le défi ImageNet grâce à son architecture profonde et l'utilisation de techniques telles que la régularisation dropout

L'architecture du modèle est basée sur AlexNet, un célèbre modèle de réseau de neurones convolutifs (CNN) utilisé pour la vision par ordinateur. Voici une explication de chaque couche de l'architecture :

1. Couche de convolution 1 : Cette couche applique 96 filtres de convolution de taille 11x11 à l'image d'entrée. Elle utilise la fonction d'activation ReLU pour introduire la non-linéarité dans les activations. La couche effectue un sous-échantillonnage ( $\text{strides}=(4,4)$ ) pour réduire la dimension de l'image. Une normalisation par lot (Batch Normalization) est ensuite appliquée pour accélérer l'apprentissage.
2. Couche de pooling 1 : Cette couche effectue une opération de pooling maximale avec une fenêtre de taille 3x3 et un sous-échantillonnage ( $\text{strides}=(2,2)$ ). Elle réduit la taille spatiale de l'image tout en préservant les caractéristiques les plus importantes.

3. Couche de convolution 2 : Cette couche applique 256 filtres de convolution de taille 5x5 à l'activation de la couche précédente. Elle utilise également la fonction d'activation ReLU et la normalisation par lot.
4. Couche de pooling 2 : Comme la couche de pooling précédente, cette couche effectue une opération de pooling maximale avec une fenêtre de taille 3x3 et un sous-échantillonnage (strides=(2,2)).
5. Couche de convolution 3 : Cette couche applique 384 filtres de convolution de taille 3x3 à l'activation de la couche précédente, suivie de la fonction d'activation ReLU et de la normalisation par lot.
6. Couche de pooling 3 : Une fois de plus, une opération de pooling maximale est appliquée avec une fenêtre de taille 3x3 et un sous-échantillonnage (strides=(2,2)).
7. Couche de convolution 4 : Cette couche applique 384 filtres de convolution de taille 3x3 à l'activation de la couche précédente, avec la fonction d'activation ReLU et la normalisation par lot.
8. Couche de convolution 5 : Cette couche applique 256 filtres de convolution de taille 3x3 à l'activation de la couche précédente, suivie de la fonction d'activation ReLU et de la normalisation par lot.
9. Couche d'aplanissement : Cette couche aplatit le volume des activations précédentes en un vecteur unidimensionnel, préparant ainsi les données pour les couches entièrement connectées.
10. Couche dense 1 : Cette couche est une couche entièrement connectée avec 4096 neurones et utilise la fonction d'activation ReLU. La normalisation par lot et le dropout sont appliqués pour réduire le surapprentissage.
11. Couche dense 2 : De même, cette couche est entièrement connectée avec 4096 neurones et utilise la fonction d'activation ReLU.
12. Couche dense 3 : Il s'agit de la dernière couche entièrement connectée, avec 1000 neurones et la fonction d'activation ReLU.



13. Couche de sortie : Cette couche finale est une couche dense avec 4 neurones (correspondant aux 4 classes de défauts) et utilise la fonction d'activation softmax pour donner une probabilité pour chaque classe.

L'architecture du modèle comprend également des couches de normalisation par lot (Batch Normalization) pour accélérer l'apprentissage et des couches de dropout pour réduire le surapprentissage.

```
# Using Alexnet architecture. Input is a 227x227x3 image and output is 4 classes
model = tf.keras.models.Sequential([ # 1st Convolutional Layer
    tf.keras.layers.Conv2D(filters=96, kernel_size=(11,11), strides=(4,4), activation='relu', input_shape=(227,227,3)),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.MaxPool2D(pool_size=(3,3), strides=(2,2)),# 2nd Convolutional Layer
    tf.keras.layers.Conv2D(filters=256, kernel_size=(5,5), strides=(1,1), activation='relu', padding="same"),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.MaxPool2D(pool_size=(3,3), strides=(2,2)),# 3rd Convolutional Layer
    tf.keras.layers.Conv2D(filters=384, kernel_size=(3,3), strides=(1,1), activation='relu', padding="same"),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.MaxPool2D(pool_size=(3,3), strides=(2,2)),# 4th Convolutional Layer
    tf.keras.layers.Conv2D(filters=384, kernel_size=(3,3), strides=(1,1), activation='relu', padding="same"),
    tf.keras.layers.BatchNormalization(),# 5th Convolutional Layer
    tf.keras.layers.Conv2D(filters=256, kernel_size=(3,3), strides=(1,1), activation='relu', padding="same"),
    tf.keras.layers.BatchNormalization(),
    # Passing it to a Fully Connected layer
    tf.keras.layers.Flatten(),
    # 1st Fully Connected Layer
    tf.keras.layers.Dense(4096, activation='relu'),
    tf.keras.layers.BatchNormalization(),
    tf.keras.layers.Dropout(0.5), # Ajoute un Dropout pour prévenir le surapprentissage
    # 2nd Fully Connected Layer
    tf.keras.layers.Dense(4096, activation='relu'),
    # 3rd Fully Connected Layer
    tf.keras.layers.Dense(1000, activation='relu'),
    # Couche de sortie
    tf.keras.layers.Dense(4, activation='softmax')
])
```

Figure 28 Architecture du modèle 3 .

#### Modèle 4 (VGG19)

Le modèle VGG19 a été proposé par Karen Simonyan et Andrew Zisserman de l'Université d'Oxford. Il tire son nom de la Visual Geometry Group (VGG) de cette université. Le "19" dans le nom fait référence au nombre total de couches dans le réseau, y compris les couches convolutives et les couches entièrement connectées.

L'architecture de notre modèle est basée sur le réseau VGG19, un réseau de neurones convolutifs populaire et performant pour la classification d'images. Voici un résumé de l'architecture :

1. Chargement du modèle VGG19 pré-entraîné avec ``include_top=False`` pour exclure les couches entièrement connectées.
2. Transfert d'apprentissage en figeant les poids des premières couches pour conserver les caractéristiques apprises.
3. Ajout de couches personnalisées, y compris des couches Dense avec des activations ReLU et des couches de dropout pour réduire le surapprentissage.
4. Création du modèle final en spécifiant les entrées et les sorties.
5. Compilation du modèle avec une fonction de perte, un optimiseur et des métriques appropriés.

Cette architecture permet d'exploiter les caractéristiques extraites par le modèle VGG19 pré-entraîné tout en adaptant le modèle aux besoins spécifiques de la classification des défauts de joints soudés.

En utilisant cette approche, nous pouvons obtenir de bons résultats de classification en exploitant les connaissances préalables du modèle VGG19 et en adaptant les dernières couches pour répondre à votre tâche spécifique.

```

from tensorflow.keras.applications import VGG19
resnet_model = Sequential()
# Load the pre-trained ResNet50 model
pretrained_model = tf.keras.applications.ResNet50(include_top=False,
input_shape=(180,180,3),
pooling='avg', classes=5,
weights='imagenet')
# Freeze the weights of the pre-trained model
for layer in pretrained_model.layers:
    layer.trainable = False
# Add the pre-trained ResNet50 model to the sequential model
resnet_model.add(pretrained_model)
resnet_model.add(Flatten())
resnet_model.add(Dense(512, activation='relu'))
resnet_model.add(Dense(5, activation='softmax'))
# Load the pre-trained VGG19 model
model = VGG19(weights='imagenet', include_top=False, input_shape=(256, 256, 3))
# Define your model
x = model.output # Récupère la sortie du modèle existant
x = Flatten()(x) # Applique une mise à plat à la sortie
x = Dense(64, activation="relu")(x) # Ajoute une couche dense avec 64 neurones et une fonction d'activation ReLU
x = Dropout(0.3)(x) # Ajoute une couche de dropout pour la régularisation avec un taux de 0.3
x = Dense(64, activation="relu")(x) # Ajoute une autre couche dense avec 64 neurones et une fonction d'activation ReLU
predictions = Dense(4, activation="softmax")(x) # Couche de sortie avec une fonction d'activation softmax pour 4 classes

# Create the final model
model_final = Model(model.input, predictions) # Crée un nouveau modèle en spécifiant l'entrée du modèle existant et les prédictions comme sortie

```

Figure 29 Architecture du modèle 4.

### Modèle 5(EfficientNet)

EfficientNet est une famille de modèles de réseau de neurones convolutionnels (CNN) introduite en 2019 qui propose une architecture efficace en termes de précision et d'efficacité en exploitant différentes échelles et niveaux de profondeur pour des performances optimales.

Le modèle EfficientNetB1 est pré-entraîné pour la classification d'images. Voici une explication étape par étape de l'architecture du code :

1. La ligne `effnet = EfficientNetB1(weights='imagenet', include\_top=False, input\_shape=(224, 224, 3))` charge le modèle EfficientNetB1 pré-entraîné sur le jeu de données ImageNet, en spécifiant l'absence de la couche supérieure (include\_top=False) et la forme d'entrée des images (input\_shape=(224, 224, 3)).
2. La ligne `model = effnet.output` récupère la sortie du modèle EfficientNetB1.
3. La ligne `model = GlobalAveragePooling2D()(model)` applique une opération de pooling global moyenne pour réduire la dimension spatiale de la sortie du modèle.

4. La ligne `model = Dropout(0.5)(model)` ajoute une couche de dropout pour régulariser le modèle en désactivant aléatoirement 50% des neurones pendant l'entraînement.

5. La ligne `model = Dense(4, activation='softmax')(model)` ajoute une couche dense avec 4 neurones et une fonction d'activation softmax pour effectuer la classification des 4 classes de sortie.

6. La ligne `model = Model(inputs=effnet.input, outputs=model)` crée le modèle final en spécifiant à la fois l'entrée (`effnet.input`) et les sorties (`model`).

Cette architecture utilise EfficientNetB1 comme extracteur de caractéristiques pré-entraîné, suivi de quelques couches supplémentaires spécifiques à la tâche de classification des 4 classes de sortie.

```

effnet = EfficientNetB1(weights='imagenet', include_top=False, input_shape=(224, 224, 3)) # Charge le modèle EfficientNetB1 pré-entraîné avec des poids ImageNet

model = effnet.output # Récupère la sortie du modèle EfficientNetB1
model = GlobalAveragePooling2D()(model) # Applique une opération de pooling global pour réduire les dimensions spatiales
model = Dropout(0.5)(model) # Ajoute une couche de dropout pour la régularisation avec un taux de 0.5
model = Dense(4, activation='softmax')(model) # Couche de sortie avec une fonction d'activation softmax pour 4 classes
model = Model(inputs=effnet.input, outputs=model) # Crée un nouveau modèle en spécifiant les entrées du modèle EfficientNetB1 et les sorties de la couche de sortie

model.summary() # Affiche un résumé du modèle

input = tf.keras.Input(shape=(100,), dtype='int32', name='input') # Définit une entrée avec une forme de (batch_size, 100)
x = tf.keras.layers.Embedding(output_dim=512, input_dim=10000, input_length=100)(input) # Couche d'embedding pour convertir les entiers en vecteurs denses
x = tf.keras.layers.LSTM(32)(x) # Couche LSTM avec 32 unités
x = tf.keras.layers.Dense(64, activation='relu')(x) # Couche dense avec 64 neurones et fonction d'activation ReLU
x = tf.keras.layers.Dense(64, activation='relu')(x) # Autre couche dense avec 64 neurones et fonction d'activation ReLU
x = tf.keras.layers.Dense(64, activation='relu')(x) # Autre couche dense avec 64 neurones et fonction d'activation ReLU
output = tf.keras.layers.Dense(1, activation='sigmoid', name='output')(x) # Couche de sortie avec une fonction d'activation sigmoid pour une classification binaire
model = tf.keras.Model(inputs=[input], outputs=[output]) # Crée le modèle en spécifiant les entrées et les sorties
dot_img_file = '/tmp/model_1.png' # Fichier de sortie pour le diagramme du modèle
tf.keras.utils.plot_model(model, to_file=dot_img_file, show_shapes=True) # Génère et enregistre le diagramme du modèle

```

Figure 30 Architecture du modèle 5.

### 3.5. Résultats Obtenus et discussion :

Après avoir vu les architectures des différents modèles, nous allons maintenant discuter les résultats obtenus lors et après la phase d'entraînement, en analysant les graphes de précision et d'erreur de chaque modèle, comparer les architectures vu auparavant et voir la différence entre eux.

### 3.5.1. Résultats obtenus pour le 1er Modèle (CNN)





Figure 31 Figure : Courbes de Précision pour le 1er modèle



**Figure 32** Figure : Courbes d'Erreur pour le 1er modèle

Les deux figures ci-dessus montrent les courbes de précision et d'erreur obtenues pendant la phase d'entraînement du premier modèle. Au début, on remarque que la précision d'apprentissage augmente lentement, passant de 35.31% à 42.98%. Cela signifie que le réseau est en train d'apprendre les caractéristiques de l'image pour la première fois. Ensuite, on observe une légère augmentation de la précision jusqu'à la fin, qui atteint 64.18%. À ce stade, le réseau essaie d'ajouter de nouvelles caractéristiques qu'il n'a pas apprises lors des epochs précédents.

En même temps, l'évaluation de cet apprentissage se fait par le réseau lui-même en utilisant des images des quatre classes qu'il n'a pas vues pendant la phase d'apprentissage. Ces images sont utilisées en entrée du réseau, qui tente ensuite de les classer en fonction de leur catégorie. Cela donne la courbe de précision de validation. Cette validation est effectuée simultanément à la phase d'apprentissage et permet de suivre l'efficacité d'apprentissage du réseau. On constate que dans les premiers epochs, la précision de validation est minimale (32%) car le réseau n'était pas suffisamment entraîné. Ensuite, elle augmente jusqu'à dépasser

la précision d'apprentissage (68.32%), ce qui indique que le réseau est en bon état d'apprentissage. Finalement, on observe une diminution de la précision de validation jusqu'à 42,11%.

En ce qui concerne les courbes d'erreur d'apprentissage et de validation, il est important de noter que ces deux paramètres sont inversement liés à la précision d'apprentissage et de validation. Lorsque la précision d'apprentissage augmente, l'erreur diminue, et vice versa. Cela s'applique également à la précision et à l'erreur de validation.

En ce qui concerne la courbe d'erreur d'apprentissage, on observe une diminution de 186 % à 87 % pendant la phase d'apprentissage, ce qui indique que le réseau est en train d'apprendre. De même, pour l'erreur de validation, elle passe de 131 % à 78 %, ce qui suggère un apprentissage légèrement lent du réseau et une validation des résultats moyenne.


```

495/496 [=====>.] - ETA: 0s - loss: 1.2861 - accuracy: 0.3617
Epoch 3: loss did not improve from 0.97441
496/496 [=====>.] - 34s 69ms/step - loss: 1.2861 - accuracy: 0.3616 - val_loss: 1.2968 - val_accuracy: 0.3347
Epoch 4/10
495/496 [=====>.] - ETA: 0s - loss: 1.4582 - accuracy: 0.3580
Epoch 4: loss did not improve from 0.97441
496/496 [=====>.] - 35s 70ms/step - loss: 1.4581 - accuracy: 0.3578 - val_loss: 1.2797 - val_accuracy: 0.3670
Epoch 5/10
495/496 [=====>.] - ETA: 0s - loss: 1.3682 - accuracy: 0.3589
Epoch 5: loss did not improve from 0.97441
496/496 [=====>.] - 34s 69ms/step - loss: 1.3679 - accuracy: 0.3591 - val_loss: 1.2556 - val_accuracy: 0.3842
Epoch 6/10
495/496 [=====>.] - ETA: 0s - loss: 1.2900 - accuracy: 0.3658
Epoch 6: loss did not improve from 0.97441
496/496 [=====>.] - 32s 65ms/step - loss: 1.2900 - accuracy: 0.3656 - val_loss: 1.2744 - val_accuracy: 0.3617
Epoch 7/10
495/496 [=====>.] - ETA: 0s - loss: 1.2199 - accuracy: 0.4298
Epoch 7: loss did not improve from 0.97441
496/496 [=====>.] - 34s 69ms/step - loss: 1.2196 - accuracy: 0.4298 - val_loss: 1.1165 - val_accuracy: 0.4929
Epoch 8/10
495/496 [=====>.] - ETA: 0s - loss: 1.0933 - accuracy: 0.5174
Epoch 8: loss did not improve from 0.97441
496/496 [=====>.] - 32s 65ms/step - loss: 1.0933 - accuracy: 0.5173 - val_loss: 1.0564 - val_accuracy: 0.5409
Epoch 9/10
495/496 [=====>.] - ETA: 0s - loss: 0.9713 - accuracy: 0.5891
Epoch 9: loss improved from 0.97441 to 0.97089, saving model to data_welded.h5
496/496 [=====>.] - 46s 92ms/step - loss: 0.9709 - accuracy: 0.5893 - val_loss: 0.8334 - val_accuracy: 0.6630
Epoch 10/10
495/496 [=====>.] - ETA: 0s - loss: 0.8710 - accuracy: 0.6419
Epoch 10: loss improved from 0.97089 to 0.87101, saving model to data_welded.h5
496/496 [=====>.] - 48s 95ms/step - loss: 0.8710 - accuracy: 0.6418 - val_loss: 0.7815 - val_accuracy: 0.6832

```

**Figure : les valeurs des Précisions et d'Erreur avec le nombre epochs du 1er modèle.**

### 3.5.2. Résultats obtenus pour le 2ème Modèle(LeNet)



**Figure 33 Courbes de Précision et d'Erreur pour le 2ème modèle**

Dans le modèle mentionné, on peut remarquer que la précision de validation augmente rapidement, passant de 36,32% à 76,55%. En revanche, la précision d'apprentissage a une progression plus lente, passant de 30,73% à 57,31%. De même, la courbe d'erreur d'apprentissage montre une diminution légère mais constante, passant de 138% à 100% pendant la phase d'apprentissage. Quant à l'erreur de validation, on observe une baisse de 129% à 82,41%.

Ces observations indiquent que le réseau est en phase d'apprentissage et qu'il apprend à mieux classer les images au fil du temps. La précision de validation supérieure à la précision d'apprentissage suggère que le modèle généralise bien aux données qu'il n'a pas vues pendant l'entraînement.

En conclusion, ce modèle est performant en classification car la précision de validation est supérieure à la précision d'apprentissage. Les valeurs d'erreur indiquent également un bon apprentissage, ce qui signifie que le réseau a pu extraire les caractéristiques pertinentes des données et les utiliser efficacement pour la classification.

```
Found 15862 images belonging to 4 classes.
Found 1049 images belonging to 4 classes.
```



```
Epoch 1/10
247/247 [=====] - 5548s 22s/step - loss: 1.3871 - accuracy: 0.3073 - val_loss: 1.2932 - val_accuracy: 0.3632 - lr: 0.0100
Epoch 2/10
247/247 [=====] - 68s 274ms/step - loss: 1.3650 - accuracy: 0.3220 - val_loss: 1.4512 - val_accuracy: 0.2860 - lr: 0.0100
Epoch 3/10
247/247 [=====] - 67s 270ms/step - loss: 1.3403 - accuracy: 0.3480 - val_loss: 1.1722 - val_accuracy: 0.4967 - lr: 0.0100
Epoch 4/10
247/247 [=====] - 67s 271ms/step - loss: 1.2851 - accuracy: 0.4018 - val_loss: 1.3413 - val_accuracy: 0.3985 - lr: 0.0100
Epoch 5/10
247/247 [=====] - 67s 272ms/step - loss: 1.2577 - accuracy: 0.4207 - val_loss: 1.2841 - val_accuracy: 0.4023 - lr: 0.0100
Epoch 6/10
247/247 [=====] - 67s 270ms/step - loss: 1.1929 - accuracy: 0.4655 - val_loss: 0.9496 - val_accuracy: 0.6683 - lr: 0.0100
Epoch 7/10
247/247 [=====] - 67s 271ms/step - loss: 1.1585 - accuracy: 0.4749 - val_loss: 0.8459 - val_accuracy: 0.7741 - lr: 0.0100
Epoch 8/10
247/247 [=====] - 66s 266ms/step - loss: 1.1202 - accuracy: 0.4923 - val_loss: 0.9018 - val_accuracy: 0.7083 - lr: 0.0100
Epoch 9/10
247/247 [=====] - 66s 268ms/step - loss: 1.0683 - accuracy: 0.5277 - val_loss: 0.7430 - val_accuracy: 0.7655 - lr: 0.0100
Epoch 10/10
247/247 [=====] - 67s 272ms/step - loss: 1.0024 - accuracy: 0.5731 - val_loss: 0.8241 - val_accuracy: 0.7655 - lr: 0.0100
```

**Figure 34** les valeurs des Précisions et d'Erreur avec le nombre d'époque du 2ème modèle.

### 3.5.3. Résultats obtenus pour le 3ème Modèle (AlexNet)





Figure 35 Courbe d'Erreur pour le 3ème modèle



**Figure 36 Courbe de précision pour le 3ème modèle**

Pour le troisième modèle, les graphiques montrent que la précision d'apprentissage est d'environ 57,79%, avec une précision de validation de 65%. On observe une croissance relativement lente de la précision d'apprentissage. De même, la courbe d'erreur d'apprentissage montre une légère diminution de 149% à 100% pendant la phase d'apprentissage, ce qui indique que le réseau est en train d'apprendre.

En ce qui concerne l'erreur de validation, on constate une chute de 127,22% à 87,7%. Cela suggère que ce réseau est capable de bien classer les données, car la précision de validation est supérieure à la précision d'apprentissage. Cependant, les valeurs de précision pour les deux cas sont faibles par rapport aux autres modèles.

Il est important de noter que la précision d'apprentissage et de validation relativement faible peut être due à plusieurs facteurs, tels que la complexité du problème de classification, la taille du jeu de données d'entraînement et la capacité du modèle à capturer les


caractéristiques discriminantes. Il peut être bénéfique d'explorer des approches telles que l'augmentation des données, l'optimisation des hyperparamètres ou l'utilisation d'architectures de modèles plus avancées pour améliorer les performances de classification.

```

Epoch 4/10
495/495 [=====] - ETA: 0s - loss: 1.1507 - accuracy: 0.5035
Epoch 4: val_accuracy did not improve from 0.55812
495/495 [=====] - 245s 496ms/step - loss: 1.1507 - accuracy: 0.5035 - val_loss: 1.1322 - val_accuracy: 0.4859 - lr: 1.0000e-05
Epoch 5/10
495/495 [=====] - ETA: 0s - loss: 1.1181 - accuracy: 0.5159
Epoch 5: val_accuracy did not improve from 0.55812
495/495 [=====] - 246s 498ms/step - loss: 1.1181 - accuracy: 0.5159 - val_loss: 1.0411 - val_accuracy: 0.5547 - lr: 1.0000e-05
Epoch 6/10
495/495 [=====] - ETA: 0s - loss: 1.0991 - accuracy: 0.5283
Epoch 6: val_accuracy improved from 0.55812 to 0.58822, saving model to fruit_model.h5
495/495 [=====] - 256s 518ms/step - loss: 1.0991 - accuracy: 0.5283 - val_loss: 0.9814 - val_accuracy: 0.5882 - lr: 1.0000e-05
Epoch 7/10
495/495 [=====] - ETA: 0s - loss: 1.0609 - accuracy: 0.5464
Epoch 7: val_accuracy improved from 0.58822 to 0.59337, saving model to fruit_model.h5
495/495 [=====] - 251s 506ms/step - loss: 1.0609 - accuracy: 0.5464 - val_loss: 0.9660 - val_accuracy: 0.5934 - lr: 1.0000e-05
Epoch 8/10
495/495 [=====] - ETA: 0s - loss: 1.0537 - accuracy: 0.5483
Epoch 8: val_accuracy did not improve from 0.59337
495/495 [=====] - 236s 478ms/step - loss: 1.0537 - accuracy: 0.5483 - val_loss: 1.0250 - val_accuracy: 0.5575 - lr: 1.0000e-05
Epoch 9/10
495/495 [=====] - ETA: 0s - loss: 1.0160 - accuracy: 0.5660
Epoch 9: val_accuracy improved from 0.59337 to 0.61147, saving model to fruit_model.h5
495/495 [=====] - 250s 506ms/step - loss: 1.0160 - accuracy: 0.5660 - val_loss: 0.9381 - val_accuracy: 0.6115 - lr: 1.0000e-05
Epoch 10/10
495/495 [=====] - ETA: 0s - loss: 1.0017 - accuracy: 0.5779
Epoch 10: val_accuracy improved from 0.61147 to 0.64996, saving model to fruit_model.h5
495/495 [=====] - 245s 495ms/step - loss: 1.0017 - accuracy: 0.5779 - val_loss: 0.8770 - val_accuracy: 0.6500 - lr: 1.0000e-05
    
```


**Figure 37** les valeurs des Précisions et d'Erreur avec le nombre d'époque du 3ème modèle.

### 3.5.4. Résultats obtenus pour le 4ème Modèle (VGG19)



**Figure 38** Courbe de Précision pour le 4ème modèle

```
plt.show()
```



**Figure 39 Courbe d'Erreur pour le 4ème modèle**

Pour le quatrième modèle, les graphiques montrent une augmentation rapide de la précision de validation, passant de 58,70% à 91,84%. De même, la précision d'apprentissage augmente rapidement, passant de 52,54% à 90,30%. La courbe d'erreur d'apprentissage montre une décroissance assez rapide, passant de 108% à 29,07% pendant la phase d'apprentissage. Au niveau de l'erreur de validation, on constate une chute de 93,68% à 24%.

Ces variations intenses au niveau de la précision et de l'erreur d'apprentissage au cours des premières époques indiquent que le réseau était en phase d'apprentissage et n'était pas capable de bien classer les images. Cependant, au fur et à mesure que le modèle apprend, la précision de validation dépasse la précision d'apprentissage, ce qui suggère que le réseau est capable de bien classer les données.

On peut donc dire que ce réseau est assez bon en classification, car la précision de validation est supérieure à la précision d'apprentissage. De plus, les valeurs d'erreur sont minimales, ce qui indique que le modèle extrait efficacement les caractéristiques pertinentes et atteint une

précision satisfaisante en sortie. Cela suggère que le modèle a réussi à capturer les motifs discriminants dans les données et à les utiliser pour la classification.


```

)

Epoch 1/10
495/495 [=====] - 514s 1s/step - loss: 1.0899 - accuracy: 0.5254 - val_loss: 0.9368 - val_accuracy: 0.5870
Epoch 2/10
495/495 [=====] - 467s 942ms/step - loss: 0.9746 - accuracy: 0.5715 - val_loss: 0.8346 - val_accuracy: 0.6390
Epoch 3/10
495/495 [=====] - 457s 923ms/step - loss: 0.8593 - accuracy: 0.6358 - val_loss: 0.7106 - val_accuracy: 0.7151
Epoch 4/10
495/495 [=====] - 493s 996ms/step - loss: 0.7098 - accuracy: 0.7213 - val_loss: 0.5978 - val_accuracy: 0.7803
Epoch 5/10
495/495 [=====] - 458s 924ms/step - loss: 0.5597 - accuracy: 0.7961 - val_loss: 0.4878 - val_accuracy: 0.8405
Epoch 6/10
495/495 [=====] - 500s 1s/step - loss: 0.4544 - accuracy: 0.8356 - val_loss: 0.3881 - val_accuracy: 0.8623
Epoch 7/10
495/495 [=====] - 495s 999ms/step - loss: 0.3949 - accuracy: 0.8614 - val_loss: 0.3264 - val_accuracy: 0.8855
Epoch 8/10
495/495 [=====] - 495s 1s/step - loss: 0.3547 - accuracy: 0.8809 - val_loss: 0.2525 - val_accuracy: 0.9097
Epoch 9/10
495/495 [=====] - 496s 1s/step - loss: 0.3103 - accuracy: 0.8941 - val_loss: 0.2348 - val_accuracy: 0.9215
Epoch 10/10
495/495 [=====] - 495s 999ms/step - loss: 0.2907 - accuracy: 0.9030 - val_loss: 0.2400 - val_accuracy: 0.9184
    
```

**Figure 40** les valeurs des Précisions et d'Erreur avec le nombre d'époque du 4ème modèle.

### 3.5.5. Résultats obtenus pour le 5ème Modèle (Efficient Net)



**Figure 41** Courbes de Précision et d'Erreur pour le 5ème modèle.

Dans ce modèle, il est remarquable que les précisions d'apprentissage et de validation sont les meilleures parmi les autres modèles mentionnés, avec des valeurs respectives de 99,63%

et 96,40%. Ces valeurs indiquent que ce modèle est excellent en termes d'apprentissage et de classification. De plus, les valeurs d'erreur sont minimales, avec seulement 0,1% pour l'apprentissage et 1,23% pour la validation.

Les faibles variations observées indiquent que le modèle a convergé vers des performances très élevées et stables. Bien que la précision d'apprentissage soit légèrement supérieure à la précision de validation, cela ne remet pas en cause l'efficacité générale du modèle. En effet, il s'agit d'un modèle très performant, voire le meilleur parmi les modèles précédents mentionnés.

En résumé, ce modèle présente des résultats exceptionnels en termes d'apprentissage et de classification, avec des précisions élevées et des erreurs minimales. Il a réussi à extraire efficacement les caractéristiques pertinentes des données et à les utiliser pour classer avec précision les images.

```

Epoch 1/10
397/397 [=====] - ETA: 0s - loss: 0.0165 - accuracy: 0.9954
Epoch 1: val_accuracy did not improve from 0.97003
397/397 [=====] - 302s 759ms/step - loss: 0.0165 - accuracy: 0.9954 - val_loss: 0.2089 - val_accuracy: 0.9486
Epoch 2/10
397/397 [=====] - ETA: 0s - loss: 0.0206 - accuracy: 0.9950
Epoch 2: val_accuracy did not improve from 0.97003
397/397 [=====] - 265s 666ms/step - loss: 0.0206 - accuracy: 0.9950 - val_loss: 0.3201 - val_accuracy: 0.9407
Epoch 3/10
397/397 [=====] - ETA: 0s - loss: 0.0149 - accuracy: 0.9953
Epoch 3: val_accuracy did not improve from 0.97003
397/397 [=====] - 269s 678ms/step - loss: 0.0149 - accuracy: 0.9953 - val_loss: 0.1803 - val_accuracy: 0.9562
Epoch 4/10
397/397 [=====] - ETA: 0s - loss: 0.0161 - accuracy: 0.9954
Epoch 4: val_accuracy did not improve from 0.97003
397/397 [=====] - 303s 764ms/step - loss: 0.0161 - accuracy: 0.9954 - val_loss: 0.2950 - val_accuracy: 0.9341
Epoch 5/10
397/397 [=====] - ETA: 0s - loss: 0.0127 - accuracy: 0.9965
Epoch 5: val_accuracy did not improve from 0.97003
397/397 [=====] - 264s 665ms/step - loss: 0.0127 - accuracy: 0.9965 - val_loss: 0.3578 - val_accuracy: 0.9334
Epoch 6/10
397/397 [=====] - ETA: 0s - loss: 0.0125 - accuracy: 0.9967
Epoch 6: val_accuracy did not improve from 0.97003
397/397 [=====] - 263s 661ms/step - loss: 0.0125 - accuracy: 0.9967 - val_loss: 0.1736 - val_accuracy: 0.9536
Epoch 7/10
397/397 [=====] - ETA: 0s - loss: 0.0122 - accuracy: 0.9967
Epoch 7: val_accuracy did not improve from 0.97003
397/397 [=====] - 263s 662ms/step - loss: 0.0122 - accuracy: 0.9967 - val_loss: 0.2257 - val_accuracy: 0.9524

Epoch 8/10
397/397 [=====] - ETA: 0s - loss: 0.0072 - accuracy: 0.9978
Epoch 8: val_accuracy did not improve from 0.97003
397/397 [=====] - 260s 654ms/step - loss: 0.0072 - accuracy: 0.9978 - val_loss: 0.1865 - val_accuracy: 0.9609
Epoch 9/10
397/397 [=====] - ETA: 0s - loss: 0.0077 - accuracy: 0.9975
Epoch 9: val_accuracy did not improve from 0.97003
397/397 [=====] - 260s 654ms/step - loss: 0.0077 - accuracy: 0.9975 - val_loss: 0.3701 - val_accuracy: 0.9445
Epoch 10/10
397/397 [=====] - ETA: 0s - loss: 0.0100 - accuracy: 0.9963
Epoch 10: val_accuracy did not improve from 0.97003
397/397 [=====] - 259s 652ms/step - loss: 0.0100 - accuracy: 0.9963 - val_loss: 0.1231 - val_accuracy: 0.9640

```

**Figure 42 les valeurs des Précisions et d'Erreur avec le nombre d'époque du 5ème modèle.**

### 3.6. Comparaison des résultats

Dans la Table 1, les cinq modèles présentent des performances différentes en termes de précision d'apprentissage et d'erreurs. Le premier modèle se distingue par sa précision d'apprentissage assez bonne, avec un taux assez élevé par rapport aux modèles 2 et 5.

Les modèles 2 et 3 affichent une bonne précision d'apprentissage, avec des taux d'erreur similaires à celui du premier modèle. Cependant, les performances entre ces deux modèles peuvent différer en fonction de critères spécifiques tels que la précision de validation et les taux d'erreur d'apprentissage et de validation

Les modèles 4 et 5 se démarquent en tant que meilleurs classificateurs. Ils présentent la meilleure précision d'apprentissage et de validation, ainsi que des erreurs d'apprentissage et de validation minimales. Le modèle 5 en particulier affiche une précision d'apprentissage de 99,63% et un minimum d'erreurs d'apprentissage et de validation. Il présente également une bonne précision de validation de 96,40%.

En conclusion, les modèles 4 et 5 se distinguent comme les meilleurs classificateurs en termes de précision d'apprentissage, de précision de validation et d'erreurs. Le modèle 5 se démarque en tant que modèle le plus performant avec une précision d'apprentissage exceptionnellement élevée et un minimum d'erreurs d'apprentissage et de validation.

Modèles	Modèle 1	Modèle 2	Modèle 3	Modèle 4	Modèle 5
<b>Précision d'Apprentissage finale</b>	64%	57.31%	57.79%	90.30%	99.63%
<b>Précision de Validation finale</b>	68%	76.55%	65%	91.84%	96.40%
<b>Précision d'Apprentissage Moyenne</b>	35.9%	42.07%	51.59%	79.61	99.65%
<b>Précision de Validation Moyenne</b>	38.4%	40.23%	55.47%	84.05%	93.34%
<b>Erreur d'apprentissage</b>	87%	100%	100%	29.07%	0.1%



<b>Erreur de Validation</b>	78%	82.41%	87.70%	24%	1.2%
-----------------------------	-----	--------	--------	-----	------

**Tableau 1 Comparaison des précisions et erreurs d'apprentissage entre les modèles.**

Dans la Table 2, après avoir testé et évalué les cinq modèles avec les données de test, nous remarquons que les modèles 2 et 4 sont les meilleurs car ils dépassent les 50 % dans toutes les mesures de précision, de rappel et de score F comparativement aux autres modèles.

En comparant le modèle 2 et le modèle 4, nous concluons que le modèle 4, VGG19, est le meilleur en termes de précision, de rappel et de score F lors des phases de test, de validation et d'entraînement.

<b>Modèles</b>	<b>Modèle1</b>	<b>Modèle2</b>	<b>Modèle3</b>	<b>Modèle4</b>	<b>Modèle5</b>
<b>Précision de test</b>	10%	69%	12.8%	90%	29%
<b>Recall</b>	24.8%	64%	25%	91%	34%
<b>F-score</b>	14%	65%	17%	91%	27%

**Tableau 2 comparaison métriques d'évaluation de data set**

### 3.7. Conclusion :

Dans ce chapitre nous avons présenté une approche de classification des images radiographiques basée sur les réseaux de neurones convolutionnels, pour cela on a utilisé cinq modèles avec différentes architectures, et on a montré les différents résultats obtenus en termes de précision et d'erreur. La comparaison des résultats trouvés a montré que le choix de : l'architecture, nombre et taille des filtres, nombre des couches MaxPool et FC, nombre des epochs, et la profondeur de réseaux, sont des facteurs importants pour l'obtention de meilleurs résultats.

## **Conclusion générale**

Dans ce travail, nous avons mis l'accent sur l'utilisation de l'intelligence artificielle, plus précisément des réseaux de neurones convolutionnels, dans la classification des images radiographiques pour la détection des défauts de joints soudés. Notre objectif principal était d'automatiser ce processus de détection afin d'accélérer les mesures nécessaires et d'améliorer la précision de la classification.

Les réseaux de neurones convolutionnels ont été choisis en raison de leur capacité à extraire efficacement des caractéristiques complexes à partir des images. Ils sont capables de détecter des détails minuscules et des caractéristiques que l'œil humain pourrait ne pas percevoir. Cette approche permet une classification plus rapide et précise par rapport aux méthodes traditionnelles de classification d'images.

Dans notre travail, nous avons présenté les différentes couches utilisées dans les réseaux de neurones convolutionnels, telles que les couches de convolution, de pooling et entièrement connectées. Nous avons également abordé les hyperparamètres tels que les poids et les biais, ainsi que d'autres paramètres tels que le padding et le stride. Des techniques de régularisation, telles que le dropout et l'augmentation des données, ont été utilisées pour éviter le surapprentissage et améliorer les performances du modèle.

Nous avons également souligné les défis auxquels nous avons été confrontés, tels que la recherche d'une base de données appropriée pour notre travail et les contraintes de temps d'exécution lors de l'implémentation en raison de l'utilisation d'un GPU.

En conclusion, l'utilisation du deep learning, en particulier des réseaux de neurones convolutionnels, dans l'analyse des images radiographiques de joints soudés présente de nombreux avantages, tels qu'une meilleure précision, une analyse plus rapide et la capacité à détecter des défauts subtils. Cependant, il est important de souligner que l'expertise humaine reste essentielle pour garantir des résultats précis et fiables. Nous suggérons également que ce travail puisse être étendu dans différentes directions futures, ouvrant ainsi la voie à de nouvelles idées et développements dans le domaine de l'inspection non destructive.

**Références bibliographiques**

- [1] Russian Ministry of Education and Science in accordance to the Government Decree 218 from April 9, 2010 (project number 074-11-2018-013 from May 31, 2018 (03.G25.31.0284).
- [2] J. H. Rogerson, "Defects in welds – Their prevention and their significance", Applied science publishers, 1983.
- [3] "Classification des défauts dans les soudures par fusion des métaux, avec commentaires explicatifs". Norme de "International Standard Organization", 6520-1982, 1982.
- [4] "Classification des défauts dans les soudures par fusion des métaux, avec commentaires explicatifs". Norme de "International Standard Organization", 6520-1982, 1982.
- [5] W.J. Mc Gonnagle, "Essais non destructifs", Edition Eyrolles, 1967.
- [6] Bastien L. "Machine Learning : Définition, fonctionnement, utilisations". <https://www.lebigdata.fr/machine-learning-et-big-data>, 2020 , Consulté le 22/05/2023.
- [7] Lu Hongtao; Zhang Qinchuan Applications of Deep Convolutional Neural Network in Computer Vision Department of Computer Science and Engineering, Shanghai Jiao Tong University,utilization " <https://www.cnki.net/kcms/doi/10.16337/j.1004-9037.2016.01.001.html> ",consulté le 22/05/2023.
- [8] "Classification des défauts dans les soudures par fusion des métaux, avec commentaires explicatifs". Norme de "International Standard Organization", 6520-1982, 1982.
- [9] R.C. Gonzalez, R.E. Woods, "Digital Image Processing". Addison-Wesley Publishing Company, 1993.
- [10] The MIT Press, « [Reinforcement Learning, Second Edition](#) », sur The MIT Press), p. 47, Section 3.1 : « The agent-environment interface »,consulté le 6 février 2023.
- [11] <https://datascientest.com/apprentissage-non-supervis>, consulté le 07/06/2023.
- [12] Les GPU de Nvidia s'imposent dans les réseaux de neurones [David Feugey](#), 19 juin 2013, 16:35 | Mis à jour le 2 mars 2021, 11:50 .
- [13] Michael A. Nielsen, "Neural Networks and Deep Learning", Determination Press, 2015.

- [14] <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition> ,consulté 29/05/2023.
- [15] <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>, Consulté le 30/05/2023.
- [16] Margot P article sur le Perceptron : qu'est-ce que c'est et à quoi ça sert ?7 avril 2021 .
- [17] Kountchev, R. K., Rubin, S. H., Todorov, V. T., and Kountcheva, R. A., "Automatic detection of welding defects," Int. J. Reasoning-based Intelligent Systems 3(1) (2011).
- [18] Comprendre la science tou-te-s ensemble, Sciences du Numérique , par Ikram Chraibi Kaadoud , 10.11.2018 .
- [19] <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> , consulté 01/06/2023.
- [20] Intelligence artificielle vulgarisée , Aurélien VANNIEUWENHUYZE , septembre 2019.
- [21] Apprentissage automatique pour la détection d'anomalies dans les données ouvertes , application à la cartographie Thèse Rémi Delassus , 2018 .
- [22] LeCun, Y., et al. Handwritten digit recognition with a back-propagation network. in Advances in neural information processing systems. 1990.
- [23] Gonzalez, R. and Woods, R., "Digital image processing," Prentice Hall, New Jersey (2002).
- [24] BOSTON—March 30, 2022—O'Reilly, the premier source for insight-driven learning on technology and business, today announced the results of its annual AI Adoption in the Enterprise survey.
- [25] Uploaded a work by Google from <https://colab.research.google.com> Google Colab top-left logo with UploadWizard.
- [26] <https://levelup.gitconnected.com/5-important-changes-coming-with-tensorflow-2-0-e6bb172c5fdf> , Consulté le 05/06/2023.
- [27] <https://keras.io/#keras-the-python-deep-learning-library> Consulter le 05/06/2023.
- [28] Benito Totino, Fanny Spagnolo, Stefania Perri, "RIAWELC: A Novel Dataset of Radiographic Images for Automatic Weld Defects Classification", in the Proceedings of the Interdisciplinary Conference on Mechanics, Computers and Electrics (ICMECE 2022), 6-7 October 2022, Barcelona, Spain.