



الجمهورية الجزائرية الديمقراطية الشعبية
People's Democratic Republic of Algeria
وزارة التعليم العالي والبحث العلمي
Ministry of Higher Education and Scientific Research
جامعة عبد الحميد بن باديس – مستغانم
Abdel Hamid Ibn Badis University – Mostaganem
كلية العلوم والتكنولوجيا
Faculty of Sciences and Technology
قسم الهندسة الكهربائية



Department of Electrical Engineering

N° d'ordre : M2...../GE/2026

MEMOIRE

Présenté pour obtenir le diplôme de

MASTER EN Automatique et Informatique Industrielle

Filière : Automatique

Spécialité : Automatique et Informatique Industrielle

Présenté par :

- BENKETIRA Abdelkader Mohamed
- BERDJI Mohamed Abdel Islam

Diagnostic visuel de pièces industrielles par Machine Learning

Soutenu le 29 / 06 / 2026 devant le jury composé de :

Président :	M. KOUADRIA	M.C.A	Université de Mostaganem
Examineur:	B. TARGUI	M.C.A	Université de Mostaganem
Encadrante :	K. BERRADJA	M.C.A	Université de Mostaganem

Année universitaire 2025 / 2026

Remerciements

Tout d'abord, nous remercions Dieu Tout-Puissant de nous avoir accordé la force, la santé et la volonté nécessaires pour mener à bien ce mémoire.

Nous exprimons notre profonde gratitude et nos sincères remerciements à notre encadrante, Dr. K. BERRADJA, pour son accompagnement, sa disponibilité ainsi que ses précieux conseils, qui nous ont été d'une grande aide tout au long de la réalisation de ce mémoire.

Nous exprimons tout notre respect et notre profonde gratitude aux membres du jury qui ont bien voulu consacrer leur temps et leur attention à l'évaluation de ce travail. Nous remercions tout particulièrement Dr. M. KOUADRIA pour avoir accepté de présider ce jury, ainsi que Dr. B. TARGUI pour avoir accepté d'examiner et d'évaluer ce mémoire.

Nous adressons également nos remerciements à l'ensemble des enseignants du département d'électronique pour la qualité de leur enseignement et pour les connaissances qu'ils nous ont transmises au cours de notre formation académique.

Enfin, nous n'oublions pas de remercier nos familles pour leur soutien et leurs encouragements tout au long de notre parcours d'études.

Dédicaces

Nous dédions ce travail

À nos chers parents, qui nous ont soutenus et encouragés tout au long de nos années d'études.

À notre enseignante Dr. Berradja Khadidja, en reconnaissance de ses précieux conseils et de son accompagnement durant la réalisation de ce travail. Nous lui exprimons toute notre gratitude et notre respect.

À nos familles et à nos proches, ainsi qu'à tous ceux qui nous ont apporté amour, soutien et énergie positive.

Et à tous nos amis qui ont été un véritable soutien et nous ont encouragés à persévérer et à réussir.

Avec nos sincères remerciements et notre profond respect.

Résumé

Ce projet de fin d'études porte sur la classification automatique des défauts de surface des plaques d'acier laminées à chaud à partir de la base de données NEU-CLS. Les défauts générés lors du procédé de laminage, tels que les fissures, les inclusions, les rayures ou les irrégularités de texture, peuvent altérer la qualité des produits et engendrer des pertes économiques importantes. Face aux limites de l'inspection visuelle manuelle, notamment son coût, sa subjectivité et sa difficulté à suivre les cadences industrielles élevées, ce travail vise à développer un système automatique de reconnaissance des défauts. L'approche proposée s'appuie sur des techniques de vision par ordinateur et d'apprentissage automatique. Les caractéristiques des images sont extraites à l'aide des descripteurs LBP, HOG et Gabor, puis utilisées par des algorithmes de classification supervisée tels que les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (ANN). Les performances des différentes combinaisons de descripteurs et de classifieurs sont ensuite évaluées afin d'identifier la solution la plus performante pour la classification automatique des défauts de surface.

Mots clés : Classification de défauts de surface, Vision par ordinateur, Apprentissage automatique, Descripteurs de caractéristiques (handcrafted features), Machines à vecteurs de support (SVM), Réseaux de neurones artificiels (ANN), Contrôle qualité industriel.

Abstract

This final-year project focuses on the automatic classification of surface defects in hot-rolled steel plates using the NEU-CLS dataset. Defects generated during the rolling process, such as cracks, inclusions, scratches, and texture irregularities, can significantly affect product quality and lead to substantial economic losses. Due to the limitations of manual visual inspection, including its cost, subjectivity, and inability to keep pace with modern high-speed production lines, this work aims to develop an automatic defect recognition system. The proposed approach is based on computer vision and machine learning techniques. Image features are extracted using LBP, HOG, and Gabor descriptors and then processed by supervised classification algorithms such as Support Vector Machines (SVM) and Artificial Neural Networks (ANN). The performance of different combinations of feature descriptors and classifiers is evaluated and compared in order to identify the most effective solution for the automatic classification of surface defects.

Keywords: Surface defect classification, Computer vision, Machine learning, Handcrafted feature descriptors, Support Vector Machines (SVM), Artificial Neural Networks (ANN), Industrial quality control.

يركز مشروع التخرج هذا على التصنيف الآلي لعيوب السطح في صفائح الفولاذ المدرفلة على الساخن باستخدام قاعدة بيانات مرجعية متخصصة في هذا المجال. إن العيوب الناتجة عن عملية الدرفلة، مثل الشقوق والشوائب والخدوش وعدم انتظام النسيج السطحي، قد تؤثر بشكل كبير على جودة المنتج وتؤدي إلى خسائر اقتصادية معتبرة. ونظراً للقيود المرتبطة بالفحص البصري اليدوي، من حيث التكلفة الذاتية وصعوبة مواكبة خطوط الإنتاج الحديثة ذات الوتيرة العالية، يهدف هذا العمل إلى تطوير نظام آلي للتعرف على العيوب. تعتمد المقاربة المقترحة على تقنيات الرؤية الحاسوبية وتعلم الآلة، حيث يتم استخراج خصائص الصور باستخدام واصفات الأنماط الثنائية المحلية، ومدرجات التدرجات الموجهة، ومرشحات غابور، ثم معالجتها بواسطة خوارزميات التصنيف الخاضع للإشراف مثل آلات المتجهات الداعمة والشبكات العصبية الاصطناعية. بعد ذلك، يتم تقييم ومقارنة أداء مختلف تركيبات واصفات الخصائص والمصنفات من أجل تحديد الحل الأكثر فعالية للتصنيف الآلي لعيوب السطح

الكلمات المفتاحية: تصنيف عيوب السطح، الرؤية الحاسوبية، تعلم الآلة، واصفات الخصائص اليدوية، آلات المتجهات الداعمة، الشبكات العصبية الاصطناعية، مراقبة الجودة الصناعية

SOMMAIRE :

INTRODUCTION GENERALE	-
Chapitre 01 : Laminage des produits plats en acier et enjeux de qualité	- 1 -
1.1 Introduction	- 2 -
1.2 L'acier et son importance industrielle.....	- 2 -
1.2.1 Généralités sur l'acier	- 2 -
1.2.2 Production mondiale et importance économique	- 2 -
1.3 Le procédé de laminage à chaud	- 3 -
1.3.1 Principe du l'aminage.....	- 3 -
1.3.2 Etape du procédé de laminage a chaud des produits plats	- 3 -
1.3.3 Paramètres influençant la qualité du produit laminé	- 5 -
1.4 Les défauts de surface sur produits plats laminés à chaud.....	- 5 -
1.4.1 Origine et classification des défauts	- 5 -
1.4.2 Risque pour la sécurité et la fiabilité.....	- 5 -
1.4.3 Les défauts de la base de données NEU.....	- 6 -
1.5 Contrôle qualité dans l'industrie sidérurgique.....	- 8 -
1.5.1 Méthodes traditionnelles d'inspection	- 8 -
1.5.2 Limites de l'inspection manuelle	- 8 -
1.5.3 Systèmes d'inspection automatique de surface (SIA).....	- 8 -
1.6 Apports de l'intelligence artificielle dans le l'automatisation du contrôle qualité	- 9 -

1.7 Conclusion.....	- 9 -
Chapitre 2 : Vision Artificielle pour l'Inspection Automatique des Surfaces.....	- 10 -
2.1 Introduction	- 11 -
2.2 Principe de la vision par ordinateur.....	- 11 -
2.3 Système d'inspection automatisée par vision	- 11 -
2.3.1 Acquisition de l'image	- 11 -
2.3.2 Prétraitement de l'image	- 13 -
2.3.3 Segmentation	- 14 -
2.3.4 Extraction des caractéristiques	- 14 -
2.3.5 Classification	- 19 -
2.4 Conclusion	- 19 -
Chapitre 3 Généralités sur le Machine Learning	- 20 -
3.1 Introduction	- 21 -
3.2 Définition	- 21 -
3.3 Principe de fonctionnement de l'apprentissage automatique	- 22 -
3.4 Les différents types d'apprentissage	- 22 -
3.5 Avantages et inconvénients de machine learning	- 22 -
3.6 Méthodes de Classification	- 23 -
3.6.1 Les séparateurs à vaste marge (SVM).....	- 23 -
3.6.2 Réseaux de Neurones Artificiels (ANN).....	- 25 -
3.6.3 Perceptron multicouche (MLP Multilayer Perceptron)	- 27 -

3.7 Conclusion.....	- 28 -
Chapitre 4 Classification des défauts de surface : implémentation et analyse des performances	
4.1 Introduction	- 30 -
4.2 Présentation de la base de données NEU-CLS.....	- 30 -
4.3 Description de la méthodologie utilisée	- 31 -
4.3.1 Prétraitement des données	- 32 -
4.3.2 Extraction des descripteurs HOG, LBP et Gabor	- 32 -
4.3.3 Classification supervisée des défauts à l'aide des SVM et ANN.....	- 33 -
4.4 Évaluation et interprétation des résultats	- 34 -
4.5 Conclusion.....	- 38 -
Conclusion générale et perspectives.....	- 39 -
Références.....	- 41 -

Liste des tableaux

Tableau 1.1 : Paramètres influençant la qualité du produit laminé à chaud.

Tableau 1.2 : Récapitulatif des défauts de surface du dataset NEU-CLS.

Tableau 2.1 : Avantages et inconvénients des trois descripteurs.

Tableau 3.1 : Différents types de fonctions d'activations

Tableau 4.1 : Matrice de confusion

Tableau 4.2 : Bilan des performances des classifieurs ANN et SVM sur la base de données NEU-CLS.

Liste des figures :

Figure 1.1: Schéma illustratif montrant les différentes étapes du processus du laminage.

Figure 1.2: Exemples de défauts de surface issus de la base de données NEU-CLS.

Figure 2.1: les différentes étapes constituant un système d'inspection automatisée par vision.

Figure 2.2: Exemple illustrant le calcul du descripteur de Gabor

Figure 3.1: Architecture générale de l'apprentissage automatique

Figure 3.2: Surface de séparation linéaire du classifieur SVM.

Figure 3.3: Architecture d'un réseau de neurones artificiel à deux couches cachées (ANN).

Figure 3.4: Schéma d'un Neurone artificiel

Figure 4.1: Exemples de défauts de surface issus de la base de données NEU-CLS.

Figure 4.2: Organigramme présentant les différentes étapes de la méthodologie utilisée.

Figure 4.3: Étapes de prétraitement : (a) image originale, (b) image filtrée à l'aide d'un filtre médian, (c) image filtrée avec amélioration du contraste.

Figure 4.4: Matrice de confusion du modèle LBP + Gabor + SVM sur l'ensemble de test (ACC = 98,33 %). Classes 0–5 : Cr, In, Pa, PS, RS, Sc.

Abréviations

- IA : Intelligence Artificielle
- ML : Machine Learning
- CV : Computer Vision (Vision par Ordinateur)
- SIA : Système d'Inspection Automatique
- SIS : Surface Inspection System
- NEU-DET : Northeastern University Surface Defect Detection Database
- NEU-CLS : Northeastern University Surface Defect Classification Database
- CR : Crazing
- IN : Inclusion
- PA : Patches
- PS : Pitted Surface
- RS : Rolled-in Scale
- SC : Scratches
- LBP : Local Binary Pattern
- HOG : Histogram of Oriented Gradients
- GAB : Gabor Filter
- ROI : Region of Interest
- SVM : Support Vector Machine
- ANN : Artificial Neural Network
- MLP : Multi-Layer Perceptron
- RBF : Radial Basis Function
- FCN : Fully Convolutional Network
- CCD : Charge-Coupled Device
- CMOS : Complementary Metal-Oxide-Semiconductor
- CLAHE : Contrast Limited Adaptive Histogram Equalization
- ReLU : Rectified Linear Unit

INTRODUCTION GENERALE

L'industrie sidérurgique occupe une place centrale dans l'économie mondiale en fournissant des matériaux indispensables à de nombreux secteurs tels que la construction, l'automobile, et l'aéronautique. Dans ce contexte, la qualité des produits sidérurgiques constitue un enjeu majeur pour garantir la fiabilité, la sécurité et la compétitivité des entreprises. Parmi ces produits, les plaques d'acier laminées à chaud occupent une place importante dans de nombreux secteurs industriels. Cependant, le procédé de laminage peut entraîner l'apparition de divers défauts de surface, tels que des fissures, des inclusions, des rayures ou des irrégularités de texture. Ces imperfections peuvent dégrader les propriétés mécaniques ainsi que l'aspect visuel du produit final, engendrer des pertes économiques significatives et porter atteinte à l'image de marque du fabricant.

Dans la pratique industrielle, la détection de ces défauts repose sur une inspection visuelle réalisée par des opérateurs qualifiés. Cependant, cette approche présente plusieurs limites : elle est coûteuse en temps et en ressources humaines, sensible à la fatigue et à la subjectivité des inspecteurs, et difficilement compatible avec les cadences élevées des lignes de production modernes. Face à ces contraintes, l'automatisation du contrôle qualité à l'aide des techniques de vision par ordinateur et d'apprentissage automatique s'impose comme une solution efficace. Ces approches permettent d'analyser automatiquement les images des surfaces d'acier et d'identifier les défauts de manière fiable et reproductible.

Parmi les différentes approches existantes, les méthodes fondées sur l'extraction de caractéristiques manuelles (handcrafted features) associée à des algorithmes d'apprentissage supervisé constituent une alternative intéressante aux approches de deep learning. En effet, elles sont généralement plus interprétables, moins exigeantes en ressources de calcul et nécessitent souvent des volumes de données plus modestes, ce qui les rend particulièrement adaptées à certains contextes industriels. Dans ce cadre, des descripteurs tels que le Local Binary Pattern (LBP), l'Histogram of Oriented Gradients (HOG) et les filtres de Gabor permettent de représenter efficacement les caractéristiques texturales et directionnelles des images.

L'objectif de ce projet de fin d'études est de concevoir et d'évaluer un système de classification automatique des défauts de surface des plaques d'acier laminées à chaud à partir de la base de données NEU, largement utilisée comme référence dans ce domaine. L'approche proposée repose sur l'extraction de caractéristiques pertinentes à l'aide des descripteurs LBP, HOG et Gabor, suivie de la construction de vecteurs de représentation exploités par des algorithmes d'apprentissage supervisé, notamment les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (ANN). Les performances des différentes combinaisons de descripteurs et de classifieurs sont ensuite évaluées et comparées afin d'identifier les configurations les plus efficaces pour la reconnaissance automatique des défauts de surface.

Le présent mémoire est organisé en quatre chapitres. Le premier chapitre présente le procédé de laminage à chaud des produits plats en acier, les principaux défauts de surface susceptibles d'apparaître ainsi que leurs impacts sur la qualité des produits finis. Les limites des méthodes d'inspection classiques y sont également abordées.

Le deuxième chapitre est consacré à la vision artificielle appliquée à l'inspection automatique

des surfaces. Il présente les principes fondamentaux de la vision par ordinateur, les différentes étapes d'un système d'inspection ainsi que les méthodes d'extraction de caractéristiques utilisées dans ce travail, notamment le Local Binary Pattern (LBP), l'Histogram of Oriented Gradients (HOG) et les filtres de Gabor.

Le troisième chapitre introduit les concepts de base de l'apprentissage automatique et décrit les méthodes de classification retenues, en particulier les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels.

Le quatrième chapitre expose le protocole expérimental adopté, les métriques d'évaluation utilisées ainsi que les résultats obtenus. Une analyse comparative des différentes approches étudiées est menée afin d'identifier les méthodes les plus performantes pour la classification des défauts de surface.

Enfin, une conclusion générale synthétise les principaux résultats obtenus, souligne les limites du travail réalisé et présente des perspectives de recherche et d'amélioration.

Chapitre 1

Laminage des produits plats en acier et enjeux de qualité

1.1 Introduction

L'acier est l'un des matériaux les plus utilisés dans l'industrie mondiale. Sa fabrication implique une série de procédés complexes parmi lesquels le laminage occupe une place centrale. Le laminage à chaud des produits plats est un processus thermomécanique qui permet de transformer des brames d'acier en tôles ou en bobines de faible épaisseur, largement utilisées dans les secteurs de l'automobile, de la construction, de l'énergie et de l'aéronautique.

Cependant, ce processus industriel est sujet à l'apparition de défauts de surface qui peuvent compromettre la qualité du produit final et engendrer des pertes économiques considérables. La maîtrise et le contrôle de ces défauts constituent donc un enjeu stratégique majeur pour les industriels.

Ce chapitre présente les fondements du procédé de laminage à chaud des produits plats en acier, les types de défauts de surface susceptibles d'apparaître, les méthodes traditionnelles et modernes de contrôle qualité, ainsi que les limites des approches manuelles qui justifient le recours à l'automatisation par des méthodes d'intelligence artificielle.

1.2 L'acier et son importance industrielle

1.2.1 Généralités sur l'acier

L'acier est un alliage de fer et de carbone dont la teneur en carbone est comprise entre 0,02% et 2,1% en masse. Il se distingue de la fonte par sa teneur en carbone plus faible, ce qui lui confère une meilleure ductilité et une plus grande aptitude à la déformation. Selon la composition chimique et les traitements thermiques appliqués, l'acier peut présenter une grande variété de propriétés mécaniques, notamment en termes de résistance à la traction, de dureté, de ténacité et de résilience.

On distingue plusieurs grandes familles d'aciers utilisés dans l'industrie. Les aciers au carbone, qui constituent la majorité de la production mondiale, sont principalement destinés à des applications structurelles. Les aciers alliés, qui contiennent des éléments d'addition tels que le manganèse, le chrome, le nickel ou le molybdène, sont utilisés dans des applications nécessitant des propriétés mécaniques ou chimiques particulières. Les aciers inoxydables, riches en chrome, offrent quant à eux une excellente résistance à la corrosion.

1.2.2 Production mondiale et importance économique

L'industrie sidérurgique est l'une des industries les plus importantes au monde, avec une production annuelle d'acier brut dépassant 1 900 millions de tonnes en 2022 selon l'Institut mondial de l'acier (World Steel Association) [1].

Cette industrie représente un maillon essentiel dans la chaîne de valeur de nombreux secteurs économiques, de la construction automobile à la fabrication de machines industrielles, en passant par le bâtiment et les travaux publics.

La qualité des produits sidérurgiques est directement liée à la compétitivité des entreprises productrices. Tout défaut de surface ou de structure interne peut entraîner des rebuts coûteux,

des retards de livraison, des réclamations clients et dans les cas les plus graves, des accidents industriels. Il est donc impératif de garantir un contrôle qualité rigoureux tout au long du processus de fabrication.

1.3 Le procédé de laminage à chaud

1.3.1 Principe du laminage

Le laminage est un procédé de mise en forme par déformation plastique qui consiste à faire passer un produit métallique entre deux cylindres rotatifs appelés laminoirs. La distance entre les cylindres, appelée entrefer ou emprise, est inférieure à l'épaisseur initiale du produit, ce qui provoque une réduction de l'épaisseur et un allongement du métal dans le sens de laminage.

Lorsque le laminage est effectué à une température supérieure à la température de recristallisation du métal (généralement entre 1050°C et 1250°C pour l'acier), on parle de laminage à chaud [2]. Cette température élevée facilite la déformation plastique, réduit les contraintes mécaniques appliquées sur les cylindres et permet d'obtenir des réductions de section importantes en un seul passage.

1.3.2 Étapes du procédé de laminage à chaud des produits plats

Le laminage à chaud des produits plats suit une séquence d'opérations bien définie, depuis la préparation de la matière première jusqu'à l'obtention du produit fini. Les principales étapes (voir figure 1.1) sont les suivantes :

a) Préparation et réchauffage des brames

La matière première du laminage à chaud est la brame, un demi-produit sidérurgique de section rectangulaire obtenu par coulée continue. Les brames, dont l'épaisseur varie généralement entre 150 mm et 300 mm, sont stockées dans un parc avant d'être introduites dans un four de réchauffage. Ce four porte les brames à une température homogène comprise entre 1150°C et 1250°C, ce qui les rend suffisamment ductiles pour subir la déformation de laminage.

La qualité du réchauffage est primordiale : une température trop élevée peut provoquer une oxydation excessive de la surface de la brame et la formation d'une calamine épaisse, tandis qu'une température trop faible peut engendrer des défauts de laminage liés à une déformation inhomogène.

b) Laminage dégrossisseur (Roughing Mill)

À la sortie du four de réchauffage, la brame passe dans un laminoir dégrossisseur (roughing mill) constitué de plusieurs cages de laminage réversibles. L'objectif de cette étape est de réduire progressivement l'épaisseur de la brame de plusieurs centimètres à quelques centimètres (typiquement de 250 mm à 30-50 mm), tout en homogénéisant la structure cristallographique de l'acier par recristallisation dynamique.

Entre les passes de laminage dégrossisseur, des systèmes de détartrage à haute pression (entre 150 et 400 bars) projettent de l'eau sur la surface de la brame pour éliminer la calamine

primaire formée lors du réchauffage [3]. Cette opération est essentielle pour éviter que la calamine ne soit incrustée dans la surface du métal lors des passes suivantes.

c) Laminage finisseur (Finishing Mill)

Le transfert bar issu du laminoir dégrossisseur est ensuite laminé dans un train finisseur (finishing mill), composé généralement de 6 à 7 cages de laminage en tandem. L'épaisseur est réduite progressivement jusqu'à la valeur finale souhaitée, qui peut aller de moins d'un millimètre à plusieurs millimètres selon l'application visée.

Le contrôle précis de la température, de la vitesse de laminage et de la pression exercée par les cylindres est fondamental à cette étape pour garantir les propriétés mécaniques et la géométrie du produit final. Des systèmes automatiques de contrôle d'épaisseur (Automatic Gauge Control, AGC) et de planéité sont utilisés pour maintenir les tolérances dimensionnelles dans les limites acceptables [4].

d) Refroidissement contrôlé et enroulement

À la sortie du train finisseur, la tôle chaude circule sur une table de refroidissement à eau (Run-Out Table, ROT) où elle est refroidie de manière contrôlée jusqu'à une température d'enroulement souhaitée, généralement comprise entre 550°C et 750°C. Ce refroidissement contrôlé permet d'obtenir une microstructure et des propriétés mécaniques spécifiques en fonction des exigences du client.

La tôle est ensuite enroulée en bobines par des enrouleuses (down coilers). Les bobines ainsi formées sont ensuite transférées vers les ateliers de finition, de refendage ou d'expédition directe.




Figure 1.1 : Schéma illustratif montrant les différentes étapes du processus du laminage.

1.3.3 Paramètres influençant la qualité du produit laminé

La qualité du produit laminé à chaud dépend d'un grand nombre de paramètres interdépendants. On peut les regrouper en trois catégories principales dans le tableau 1.1 suivant:

Catégorie	Paramètres clés	Impact sur la qualité
Matière première	Composition chimique, qualité de la brame, propreté inclusionnaire	Propriétés mécaniques, défauts internes
Thermique	Température de réchauffage, température de finition, température d'enroulement	Microstructure, résistance mécanique
Mécanique	Réduction par passe, vitesse de laminage, pression des cylindres	Géométrie, planéité, état de surface
Refroidissement	Débit d'eau, uniformité du refroidissement	Microstructure finale, contraintes résiduelles

Tableau 1.1 Paramètres influençant la qualité du produit laminé à chaud.

1.4 Les défauts de surface sur produits plats laminés à chaud

1.4.1 Origine et classification des défauts

Les défauts métalliques sont des imperfections ou irrégularités présentes dans un matériau métallique ou une pièce industrielle, apparaissant au cours des différentes étapes de fabrication ou de transformation. Ils peuvent être superficiels (visibles en surface) ou internes à la matière, et affectent directement les propriétés mécaniques ainsi que la qualité des produits finis. Dans l'industrie sidérurgique, les défauts de surface constituent l'une des principales causes de non-conformité des produits laminés à chaud.

Ces défauts peuvent se former à différentes étapes du processus de fabrication : lors de la coulée continue (défauts dits héréditaires), lors du réchauffage (oxydation, décarburation), ou encore lors du laminage proprement dit. On distingue généralement deux grandes catégories de défauts :

- Les défauts exogènes, issus de l'incorporation de corps étrangers à la surface du métal (calamine, inclusions non métalliques, oxydes).
- Les défauts endogènes, résultant de phénomènes mécaniques ou métallurgiques internes, tels que les fissures, les plissements ou les décollements de matière.

1.4.2 Risque pour la sécurité et la fiabilité

Les défauts métalliques constituent un facteur critique pour la sécurité des systèmes industriels. Une pièce présentant des anomalies non détectées peut entraîner des défaillances au

niveau des équipements, pouvant aller jusqu'à des arrêts de production ou des accidents industriels. Ainsi, la fiabilité globale du système dépend fortement de la qualité des opérations de détection et de contrôle des défauts.

1.4.3 Les défauts de la base de données NEU

La base de données NEU (Northeastern University) [5], qui constitue le support expérimental de ce travail, est une base d'images industrielles largement utilisée dans le domaine de la détection et de la classification automatiques des défauts de surface métalliques par vision artificielle et apprentissage automatique [6]. Elle se décline en deux versions :

NEU-DET (Northeastern University Surface Defect Detection Database), dédiée à la détection des défauts, et NEU-CLS (Northeastern University Surface Defect Classification Database), destinée à leur classification. Cette base contient des images de surfaces d'acier laminé à chaud présentant six types de défauts caractéristiques (voir figure 1.2)

Les différentes catégories de défauts considérées dans ce travail sont décrites ci-après.

a) Craquelures (Crazing)

Les craquelures sont des réseaux de fissures superficielles fines et interconnectées qui apparaissent sur la surface de l'acier. Elles résultent généralement de contraintes thermiques ou mécaniques répétées subies par la surface lors du laminage. Les craquelures se manifestent sous forme d'un maillage irrégulier qui peut affecter l'intégrité de la surface et la tenue à la corrosion du produit.




Figure. 1.2 : Exemples de défauts de surface issus de la base de données NEU-CLS.

b) Inclusions (Inclusion)

Les inclusions sont des particules non métalliques (oxydes, sulfures, silicates) emprisonnées dans la matrice métallique lors de la coulée ou du laminage. Elles apparaissent généralement sous forme de taches sombres ou claires de formes irrégulières sur la surface. Selon leur nature et leur taille, les inclusions peuvent affecter significativement les propriétés mécaniques du métal, notamment sa ductilité et sa résistance à la fatigue.

c) Taches (Patches)

Les taches sont des zones de coloration ou de texture différentes, généralement d'origine chimique, liées à des variations locales de composition de surface, d'oxydation inhomogène ou de contamination. Elles se présentent sous la forme de zones plus sombres ou plus claires sans relief apparent, et peuvent indiquer une hétérogénéité de la microstructure de surface.

d) Surfaces piquées (Pitted Surface)

Les surfaces piquées présentent de petites cavités ou alvéoles réparties sur la surface du métal. Ce type de défaut est souvent associé à l'incrustation de calamine secondaire lors du laminage, ou à des phénomènes d'oxydation localisée. Les piqûres peuvent constituer des amorce de corrosion et affecter l'aspect esthétique du produit final.

e) Écailles de laminage (Rolled-in Scale)

Les écailles de laminage résultent de l'incorporation mécanique d'oxydes de fer (calamine) dans la surface de l'acier lors du passage dans les cylindres de laminage. Ces oxydes, formés à haute température à la surface de la brique, n'ont pas été correctement éliminés par le détartrage et ont été laminés dans la surface, créant des défauts lamellaires caractéristiques et difficiles à éliminer lors des opérations de finition ultérieures.

f) Rayures (Scratches)

Les rayures sont des stries linéaires ou courbes apparaissant sur la surface du métal, résultant d'un contact mécanique entre la surface de l'acier et des éléments durs (guides, cylindres endommagés, corps étrangers sur les tables de transfert). Les rayures peuvent être superficielles ou profondes selon l'énergie du contact, et peuvent constituer des amorce de rupture ou de corrosion. Un récapitulatif des défauts de surface du dataset NEU-CLS est représenté dans le tableau 1.2.

Défaut	Origine principale	Impact sur le produit
Craquelures	Contraintes thermiques/mécaniques	Fragilisation, corrosion
Inclusions	Coulée continue, laminage	Rupture, fatigue
Taches	Oxydation inhomogène	Aspect, microstructure
Surfaces piquées	Calamine incrustée, oxydation	Corrosion, aspect

Écaillés de laminage	Détartrage insuffisant	Adhérence, corrosion
Rayures	Contact mécanique	Rupture, corrosion

Tableau 1.2 Récapitulatif des défauts de surface du dataset NEU-CLS.

1.5 Contrôle qualité dans l'industrie sidérurgique

Les défauts métalliques constituent un facteur critique pour la sécurité des systèmes industriels. Une pièce présentant des anomalies non détectées peut entraîner des défaillances dans les équipements, pouvant aller jusqu'à des arrêts de production ou des accidents industriels. Ainsi, la fiabilité globale du système est fortement dépendante de la qualité de détection et de contrôle des défauts.

1.5.1 Méthodes traditionnelles d'inspection

Historiquement, le contrôle de la qualité de surface des produits sidérurgiques reposait essentiellement sur l'inspection visuelle humaine. Des opérateurs qualifiés examinaient visuellement les produits à différentes étapes de la chaîne de production, soit directement sur la ligne (inspection en ligne), soit sur des échantillons prélevés (inspection hors ligne). Cette approche, bien que simple à mettre en œuvre, présente de nombreuses limitations dans le contexte industriel actuel.

1.5.2 Limites de l'inspection manuelle

L'inspection visuelle manuelle souffre de plusieurs handicaps fondamentaux qui la rendent inadaptée aux exigences de la production sidérurgique moderne :

- La subjectivité : l'appréciation de la qualité de surface dépend de l'expérience et de l'état de fatigue de l'opérateur, ce qui peut introduire une variabilité importante dans les décisions d'acceptation ou de rejet.
- La lenteur : la vitesse des lignes de laminage modernes, pouvant atteindre plusieurs dizaines de mètres par seconde, rend impossible une inspection exhaustive par voie humaine.
- Les conditions de travail difficiles : la proximité de l'acier chaud, la luminosité variable et le bruit ambiant dégradent les conditions d'inspection et augmentent le risque d'erreur.
- Le coût humain : le maintien d'équipes d'inspection sur plusieurs postes représente un coût opérationnel élevé.
- L'absence de traçabilité : l'inspection manuelle ne produit généralement pas de données structurées permettant l'analyse statistique des défauts et l'amélioration continue des processus.

1.5.3 Systèmes d'inspection automatique de surface (SIA)

Face aux limitations de l'inspection manuelle, l'industrie sidérurgique a progressivement adopté des Systèmes d'Inspection Automatique (SIA) de surface basés sur la vision par ordinateur [7]. Ces systèmes, également appelés Surface Inspection System (SIS) dans la littérature anglo-

saxonne, utilisent des caméras haute résolution et des algorithmes de traitement d'image pour détecter et classifier les défauts de surface en temps réel.

Un système d'inspection automatique de surface typique est composé des éléments suivants un système d'éclairage adapté (lumière structurée, LED, laser), une ou plusieurs caméras linéaires ou matricielles haute résolution, un système d'acquisition et de traitement d'image en temps réel, et un module de classification et de prise de décision.

Ces systèmes permettent une inspection exhaustive et continue de la surface à des vitesses compatibles avec les lignes industrielles, produisent des données exploitables pour l'amélioration des procédés, et réduisent significativement le taux de faux rejets et de faux acceptés par rapport à l'inspection humaine.

1.6 Apports de l'intelligence artificielle dans l'automatisation du contrôle qualité

L'essor de l'intelligence artificielle et du machine learning au cours des deux dernières décennies a ouvert de nouvelles perspectives pour l'automatisation du contrôle qualité en sidérurgie [8]. Contrairement aux systèmes d'inspection basés sur des règles expertes fixes, les approches d'apprentissage automatique permettent aux algorithmes d'apprendre les caractéristiques discriminantes des différents types de défauts directement à partir des données, sans nécessiter de programmation explicite de règles de décision.

Deux grandes familles d'approches coexistent dans la littérature. D'une part, les méthodes basées sur des caractéristiques manuelles (handcrafted features), qui consistent à extraire des descripteurs mathématiques à partir des images de défauts (texture, gradient, fréquences spatiales, etc.), lesquels sont ensuite exploités par des classifieurs de machine learning tels que les SVM ou les Random Forest. D'autre part, les approches d'apprentissage profond (deep learning), notamment les réseaux de neurones convolutionnels (CNN), qui apprennent automatiquement des représentations pertinentes directement à partir des images brutes [10].

1.7 Conclusion

Ce chapitre a présenté le contexte industriel dans lequel s'inscrit ce travail. Nous avons décrit le procédé de laminage à chaud des produits plats en acier, en détaillant les différentes étapes, depuis le réchauffage de la brame jusqu'à l'enroulement de la tôle. Nous avons également présenté les six types de défauts de surface recensés dans la base de données NEU : les craquelures, les inclusions, les taches, les surfaces piquées, les écailles de laminage et les rayures, en précisant leur origine ainsi que leur impact sur la qualité du produit.

L'analyse des méthodes traditionnelles d'inspection a mis en évidence leurs limites dans le contexte de la production industrielle moderne, ce qui justifie le recours à des systèmes d'inspection automatique basés sur l'intelligence artificielle. L'approche adoptée dans ce travail, fondée sur l'extraction de caractéristiques manuelles (handcrafted features) et l'apprentissage automatique, s'inscrit dans cette démarche d'automatisation du contrôle qualité.

Le chapitre suivant présentera les concepts fondamentaux de l'apprentissage automatique (Machine Learning) ainsi que les principaux classifieurs utilisés dans ce travail pour la classification des défauts de surface

Chapitre 2

Vision Artificielle pour l'Inspection Automatique des Surfaces

2.1 Introduction

Dans le domaine du diagnostic automatisé des défauts métalliques, la vision par ordinateur constitue une technologie clé permettant d'analyser les images de manière rapide, fiable et sans intervention humaine. Grâce aux techniques de traitement d'image et d'intelligence artificielle, il est possible de détecter, d'identifier et de classifier différents types de défauts présents sur les surfaces métalliques.

2.2 Principe de la vision par ordinateur

La vision par ordinateur (Computer Vision) est une discipline de l'intelligence artificielle qui vise à doter les machines de la capacité d'interpréter et de comprendre le contenu visuel des images numériques [11]. Dans le contexte industriel, elle constitue la base technologique des systèmes d'inspection non destructifs, permettant d'automatiser la détection, la localisation et la classification des défauts de surface.

Le fonctionnement d'un système d'inspection automatisée repose sur une succession d'étapes, depuis l'acquisition des images jusqu'à la prise de décision. La vision par ordinateur repose généralement sur trois étapes fondamentales :

- **Acquisition de l'information visuelle** : un capteur d'image (caméra CCD, CMOS ou infrarouge) convertit la scène physique en un signal numérique. L'image obtenue est représentée sous forme d'une matrice de pixels codés en niveaux de gris ou en composantes couleur RVB [12].
- **Traitement numérique des images** : des algorithmes de traitement d'image transforment les données brutes en représentations exploitables à travers des opérations telles que le filtrage, la segmentation ou l'extraction de caractéristiques géométriques, texturales ou statistiques.
- **Interprétation et prise de décision** : un modèle d'analyse, fondé sur des méthodes classiques ou sur l'apprentissage automatique, exploite les caractéristiques extraites afin de déterminer l'état de la surface, de localiser les défauts éventuels et de les classifier [13].

2.3 Système d'inspection automatisée par vision

La figure 2.1 illustre les différentes étapes constituant un système d'inspection automatisée par vision, depuis l'acquisition des images jusqu'à la prise de décision [14].




Figure 2.1 : les différentes étapes constituant un système d'inspection automatisée par vision.

2.3.1 Acquisition de l'image

L'acquisition d'image est la première étape critique du système. Elle repose sur trois composants essentiels :

❖ La caméra

Deux types sont utilisés selon l'application :

- **Caméra linéaire** : capture ligne par ligne au fil du déplacement du produit sur la ligne. C'est la plus courante en sidérurgie car elle permet une inspection continue à très haute vitesse (jusqu'à plusieurs dizaines de mètres par seconde).
- **Caméra matricielle** : capture une zone rectangulaire d'un coup. Utilisée pour des inspections sur pièces arrêtées ou à faible vitesse.

❖ L'éclairage

C'est souvent le facteur le plus déterminant pour la qualité de détection. Plusieurs techniques existent :

- **Éclairage rasant** : la lumière arrive à faible angle, ce qui accentue les reliefs et révèle les défauts de surface (rayures, bosses).
- **Éclairage en champ sombre** : seule la lumière diffusée par les défauts est captée — idéal pour les inclusions et les piqûres.
- **Éclairage structuré (laser ou LED)** : projette un motif connu sur la surface pour détecter les variations de forme ou d'épaisseur.

❖ La synchronisation

Le déclenchement de la caméra doit être parfaitement synchronisé avec la vitesse de défilement du produit, grâce à un codeur optique (encoder) placé sur la ligne. Sans cela, l'image est étirée ou compressée, ce qui fausse toute l'analyse ultérieure. Les paramètres critiques à régler sont :

- La résolution spatiale (en mm/pixel) selon la taille minimale du défaut à détecter
- La vitesse d'obturation (shutter speed) pour éviter le flou de bougé à haute vitesse
- Le rapport signal/bruit, minimisé par un bon éclairage et une caméra adaptée (capteur CCD ou CMOS industriel)

En sidérurgie, pour les produits laminés à chaud comme ceux de votre chapitre, la chaleur résiduelle de la surface peut perturber la caméra (rayonnement infrarouge). Des filtres optiques passe-bas ou des caméras spécialisées sont alors nécessaires.

2.3.2 Prétraitement de l'image

Le prétraitement des images dans un système d'inspection industrielle vise à améliorer la qualité des images acquises afin de faciliter les étapes ultérieures d'analyse. Il comprend principalement trois opérations [16].

❖ Filtrage du bruit

Les images peuvent être affectées par différents types de bruit liés aux capteurs ou aux conditions d'acquisition. Afin de limiter ces effets, des techniques de filtrage telles que le filtre médian ou le filtre gaussien sont couramment utilisées pour atténuer le bruit tout en préservant les structures importantes de l'image.

❖ Amélioration du contraste

Les variations d'éclairage constituent un problème fréquent en environnement industriel. Des méthodes de normalisation et d'égalisation de l'histogramme permettent d'uniformiser les niveaux d'intensité et d'améliorer la visibilité des défauts de surface. L'égalisation d'histogramme adaptative (CLAHE) est couramment utilisée en inspection de surface métallique, afin de mieux mettre en évidence les détails locaux.

❖ Normalisation

Enfin, le prétraitement peut inclure des opérations de redimensionnement et de normalisation des valeurs des pixels, afin d'assurer une homogénéité des données et leur compatibilité avec les algorithmes d'apprentissage automatique.

2.3.3 Segmentation

La segmentation des images dans un système d'inspection industrielle vise à identifier et à isoler les régions d'intérêt susceptibles de contenir des défauts de surface. Cette étape permet de distinguer les zones pertinentes de l'objet inspecté du fond ou des régions non informatives.

Elle repose généralement sur des techniques simples et efficaces telles que le seuillage (global ou adaptatif), qui consiste à classifier les pixels en fonction de leur intensité, ou encore les méthodes basées sur les contours, permettant de détecter les discontinuités dans l'image. Dans certains cas, des approches plus avancées comme la segmentation par régions ou les méthodes basées sur le clustering peuvent également être utilisées.

La Segmentation par deep learning (approches modernes) est réalisée par les réseaux entièrement convolutionnels (FCN) et les architectures de type U-Net produisent directement un masque de segmentation pixel par pixel, sans règles manuelles. Ils surpassent les méthodes classiques sur des défauts complexes ou ambigus, au prix d'un besoin important de données annotées.

2.3.4 Extraction des caractéristiques

L'extraction des caractéristiques constitue une étape clé dans un système d'inspection industrielle par vision. Elle consiste à transformer les images prétraitées et segmentées en un ensemble de descripteurs numériques représentatifs des propriétés visuelles de la surface.

Ces descripteurs permettent de décrire efficacement les défauts en mettant en évidence leurs caractéristiques discriminantes, telles que la texture, la forme ou les variations locales d'intensité. Parmi les méthodes couramment utilisées figurent les descripteurs de texture et de gradient, notamment le Local Binary Pattern (LBP), l'Histogram of Oriented Gradients (HOG) ainsi que les filtres de Gabor.

❖ Descripteur LBP (Local Binary Pattern)

Le descripteur LBP (Local Binary Pattern) repose sur l'analyse des relations locales entre un pixel et ses voisins immédiats afin de caractériser la texture d'une image [18][19]. Le processus se déroule généralement comme suit :

1. **Calcul du code LBP** : pour chaque pixel central, les intensités des pixels voisins sont comparées à celle du pixel central. Si l'intensité d'un voisin est supérieure ou égale à celle du pixel central, on attribue la valeur 1 ; sinon, la valeur 0.
2. **Construction du motif binaire** : les bits obtenus sont ordonnés selon un parcours prédéfini (généralement dans le sens horaire) pour former un nombre binaire.

3. **Conversion en valeur décimale** : le nombre binaire est converti en une valeur décimale appelée **code LBP**.
4. **Reconstruction de l'image LBP** : chaque pixel de l'image initiale est remplacé par son code LBP, ce qui génère une nouvelle image appelée image LBP.
5. **Calcul de l'histogramme** : l'histogramme est construit à partir des valeurs présentes dans l'image LBP. Chaque classe de l'histogramme correspond à un code LBP possible, et la fréquence d'apparition de chaque code est comptabilisée

Pour un LBP classique utilisant un voisinage de 8 pixels ($P=8$), les codes LBP varient de 0 à 255, ce qui conduit à un histogramme de 256 bins. La figure 2.1 présente un exemple illustrant le processus de calcul du descripteur LBP.




Figure 2.1: Étapes de calcul du code LBP sur un voisinage 3×3.

Les valeurs de l'histogramme sont regroupées dans un vecteur numérique appelé vecteur de caractéristiques (feature vector). Ce vecteur résume la texture globale de l'image et sert d'entrée aux algorithmes de classification, tels que les SVM ou les ANN.

Le descripteur LBP permet de capturer efficacement les microstructures locales de la texture, telles que la granularité, la rugosité ou les motifs répétitifs. Il présente également l'avantage d'être peu sensible aux variations uniformes d'éclairage et d'être rapide à calculer, ce qui le rend particulièrement adapté aux applications d'inspection industrielle en temps réel. Dans le cas des surfaces d'acier laminé à chaud, il contribue à distinguer les zones saines des régions présentant des défauts, caractérisées par des perturbations de texture.

❖ Descripteur HOG (Histogram of Oriented Gradients)

Le descripteur HOG (Histogram of Oriented Gradients) est une méthode d'extraction de caractéristiques qui décrit la distribution des orientations de gradient dans une image [20]. Il permet de représenter efficacement les contours et les formes locales, ce qui le rend particulièrement adapté à la détection et à la classification des défauts de surface.

Le principe de calcul du descripteur HOG est illustré en Figure 2.2 pour un exemple d'une cellule de 3x3 comme suit :

1- Dans un premier temps, l'image est divisée en petites cellules. Dans chaque cellule, on calcule le gradient (direction et magnitude) de chaque pixel.

2- Puis, on construit un histogramme des orientations, pondéré par les magnitudes (et le résultat dans chaque bin est une somme de ces magnitudes pondérées). L'histogramme HOG utilise généralement des gradients non signés, ce qui limite les orientations à l'intervalle $[0^\circ, 180^\circ]$. Cet intervalle est subdivisé en neuf classes de 20° , permettant de représenter efficacement la distribution des orientations locales dans l'image.

3- Les histogrammes des cellules voisines sont groupés en blocs et normalisés. La norme L_2 du vecteur brut du bloc est obtenue en calculant la racine carrée de la somme des carrés de ses composantes. Le vecteur est ensuite normalisé en divisant chacune de ses composantes par cette norme, afin d'améliorer la robustesse du descripteur face aux variations d'illumination.

4- Enfin, les blocs sont concaténés afin de former le vecteur de caractéristiques final.

Le descripteur HOG permet de capturer la distribution locale des contours et des formes. Il est particulièrement sensible aux bords orientés, ce qui le rend efficace pour les rayures (contours linéaires directionnels) et les écailles de laminage (contours lamellaires). En revanche, il est moins adapté aux défauts diffus comme les taches sans bord net.

❖ Filtres de Gabor

Le calcul du descripteur de Gabor [21] s'effectue en quatre étapes principales décrites ci-dessous. Ce descripteur permet d'analyser les textures d'une image en combinant des informations de fréquence et d'orientation comme illustré par la Figure 2.3. Le processus se déroule généralement comme suit :

1- Dans un premier temps, un filtre de Gabor [22] est construit par la combinaison d'une fonction sinusoïdale et d'une enveloppe gaussienne. La composante sinusoïdale permet de détecter une fréquence spatiale et une orientation données, tandis que la fonction gaussienne limite l'analyse à une région locale de l'image. Le filtre obtenu est particulièrement adapté à la détection de motifs texturaux orientés.

Calcul du descripteur HOG — 4 étapes




Figure 2.2: Étapes de calcul du code HOG sur un voisinage 3×3 .

2- La deuxième étape, consiste à appliquer le filtre à l'image par convolution. Le filtre est déplacé sur l'ensemble de l'image et, pour chaque position, une réponse est calculée à partir des intensités des pixels du voisinage. Lorsque la texture locale présente une fréquence et une orientation similaires à celles du filtre, la réponse obtenue est élevée. À l'inverse, si la texture ne correspond pas aux caractéristiques du filtre, la réponse est faible ou proche de zéro.

3- Afin de capturer des textures de différentes tailles et orientations, une banque de filtres de Gabor est utilisée. Plusieurs filtres sont générés en faisant varier les paramètres de fréquence et d'orientation. L'application de ces 12 filtres produit 12 images de réponse. Pour chaque image de réponse, deux mesures statistiques sont calculées : la moyenne (μ) et l'écart-type (σ).

4- Enfin, les valeurs (μ) et (σ) obtenues pour chaque filtre sont concaténées afin de former le vecteur de caractéristiques final.

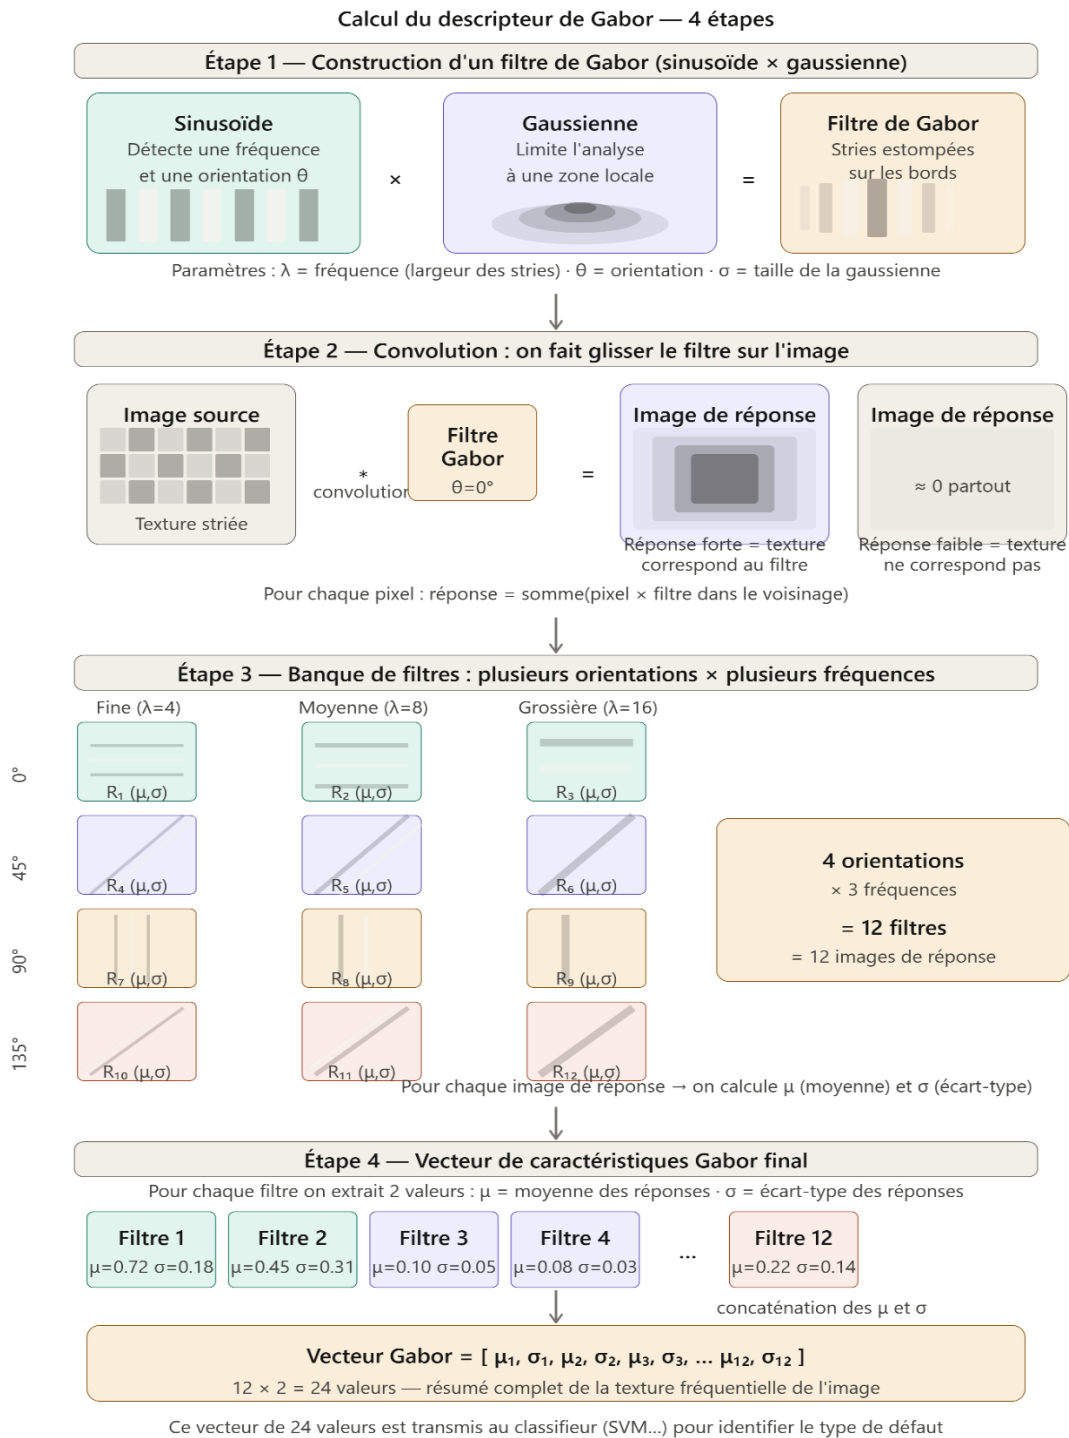


Figure 2.3: Étapes de calcul du descripteur de Gabor.

Les filtres de Gabor permettent de capturer la texture fréquentielle et orientée similaire à ce que fait le système visuel humain. Une surface piquée produit des réponses fortes à haute fréquence isotrope. Une rayure produit une réponse forte à l'orientation perpendiculaire à la rayure. On utilise généralement 4 à 8 orientations et 3 à 5 échelles, soit une vingtaine de filtres au total. Le tableau 2.1 ci-dessous résume les avantages et les inconvénients des trois descripteurs utilisés.

Méthode	Type d'information extraite	Principe	Avantages	Inconvénients
HOG	Formes et contours	Analyse des gradients et orientations des bords	Bon pour détecter les formes et structures	Sensible aux variations d'éclairage
LBP	Texture locale	Comparaison des pixels voisins avec le pixel central	Simple, rapide et efficace pour la texture	Sensible au bruit
Gabor	Texture fine et fréquences	Utilisation de filtres orientés à différentes fréquences	Très précis pour analyser les détails et textures complexes	Coût de calcul élevé

Tableau 2.1 Avantages et inconvénients des trois descripteurs.

Ainsi, les caractéristiques extraites des descripteurs précités servent de base aux algorithmes de classification pour distinguer les différentes catégories de défauts de surface.

2.3.5 Classification

Après l'extraction des caractéristiques, les vecteurs de caractéristiques sont présentés aux algorithmes de classification afin de les classer. Cette partie sera détaillée au chapitre suivant.

2.4 Conclusion

La vision artificielle appliquée à l'inspection des surfaces repose sur une chaîne de traitement structurée comprenant l'acquisition des images, leur prétraitement ainsi que l'extraction de caractéristiques pertinentes. Parmi les descripteurs les plus utilisés figurent le LBP, le HOG et les filtres de Gabor, qui permettent de représenter efficacement les propriétés texturales et directionnelles des images. Ces descripteurs peuvent être utilisés individuellement ou combinés afin d'améliorer les performances de reconnaissance. Les caractéristiques extraites servent ensuite d'entrée à différents algorithmes de classification, qu'il s'agisse de méthodes d'apprentissage automatique classiques, telles que les SVM ou les réseaux de neurones artificiels (ANN) pour assurer une classification fiables des défauts de surface dans le cadre du contrôle qualité industriel.

Chapitre 3

Laminage des produits plats en acier et enjeux de la qualité

3.1 Introduction

L'évolution rapide des technologies numériques et de la puissance de calcul a favorisé l'émergence de domaines avancés de l'intelligence artificielle (IA), au sein desquels le Machine Learning (ML) occupe une place centrale. Le ML permet aux machines d'apprendre automatiquement à partir des données et de prendre des décisions sans qu'elles aient été explicitement programmées pour chaque tâche.

Aujourd'hui, apprentissage automatique (ML) est largement utilisé dans des secteurs variés tels que la santé, la finance, la reconnaissance faciale, ou encore la conduite autonome. Son potentiel en fait un outil puissant pour traiter des volumes massifs de données, extraire des modèles pertinents et automatiser des processus complexes.

Ce chapitre a pour objectif de présenter les fondements du ML, en proposant un aperçu historique, une classification des différentes approches, un panorama des méthodes les plus courrent

Dans le domaine industriel, le Machine Learning est utilisé pour le diagnostic visuel automatique des pièces à partir d'images. Il permet de détecter les défauts, d'améliorer le contrôle qualité, de réduire les erreurs humaines et d'optimiser les processus de production

3.2 Définition

Le ML est un sous-ensemble de l'intelligence artificielle qui permet aux ordinateurs d'apprendre à partir de données, sans être explicitement programmés pour accomplir une tâche spécifique. En d'autres termes, au lieu de suivre des instructions strictes préalablement définies, les systèmes de ML utilisent des algorithmes pour identifier des modèles et des relations dans des ensembles de données et font ensuite des prédictions ou prennent des décisions basées sur ces données. Ces machines améliorent, notamment la montée en compétences (voir la Figure 3.1).




Figure 3.1: Architecture générale de l'apprentissage automatique [25].

Contrairement aux systèmes traditionnels qui effectuent des tâches selon un programme codé à la main, le ML permet aux machines de s'améliorer progressivement en fonction de l'expérience, ce qui les rend plus adaptables et autonomes [26].

3.3 Principe de fonctionnement de l'apprentissage automatique

Le principe général repose sur les étapes principales suivantes:

1. **Les données** : Le ML repose sur des données massives (big data) qui servent à entraîner les modèles. Ces données peuvent provenir de diverses sources telles que des images, du texte, des vidéos ou des capteurs. Plus les données sont variées et complètes, plus le modèle d'apprentissage sera performant.
2. **Les algorithmes** : Les algorithmes sont des suites d'instructions qui permettent aux machines de « comprendre » les données. Par exemple, un algorithme de régression linéaire peut être utilisé pour prédire une valeur continue, comme la température, en fonction de variables d'entrée.
3. **Les modèles** : Après avoir appris à partir des données, l'algorithme crée un modèle qui peut ensuite être utilisé pour faire des prédictions ou classer des données nouvelles. Par exemple, un modèle formé pour détecter des emails de spam pourra identifier de nouveaux messages comme étant légitimes ou indésirables.
4. **L'évaluation et l'amélioration** : Une fois le modèle formé, il est évalué sur sa capacité à généraliser. Cela signifie qu'il doit être capable de faire des prédictions sur de nouvelles données qu'il n'a jamais vues auparavant. L'évaluation permet de déterminer si le modèle est efficace ou s'il nécessite des ajustements.

3.4 Les différents types d'apprentissage

L'apprentissage automatique se divise principalement en trois grands types.

- **L'apprentissage supervisé** consiste à entraîner un modèle à partir de données étiquetées, c'est-à-dire des exemples dont la sortie est connue, afin qu'il apprenne à prédire correctement de nouvelles données (ex : classification ou régression).
- **L'apprentissage non supervisé**, quant à lui, travaille sur des données non étiquetées et cherche à découvrir automatiquement des structures cachées, comme des groupes ou des similarités entre les données (ex : clustering).
- **L'apprentissage par renforcement** repose sur un agent qui apprend par essais-erreurs en interagissant avec un environnement et en recevant des récompenses ou pénalités selon ses actions, dans le but d'optimiser une stratégie de décision.

Ces trois approches permettent de résoudre des problèmes très différents selon la nature des données et l'objectif recherché.

3.5 Avantages et inconvénients de machine learning

Le ML présente plusieurs avantages importants. Il permet de traiter de très grandes quantités de données rapidement, d'améliorer automatiquement les performances avec l'expérience et de résoudre des problèmes complexes comme la reconnaissance d'images, la détection de fraude ou la prédiction. De plus, il peut automatiser des tâches répétitives et fournir des résultats souvent plus précis que les méthodes classiques lorsqu'il est bien entraîné.

Cependant, il possède aussi des inconvénients. Il nécessite généralement beaucoup de données de qualité, ainsi qu'une forte puissance de calcul, ce qui peut être coûteux. De plus, certains

modèles fonctionnent comme des « boîtes noires », ce qui rend leurs décisions difficiles à interpréter. Enfin, ils peuvent être sensibles aux biais présents dans les données, ce qui peut entraîner des résultats injustes ou incorrects si les données ne sont pas bien équilibrées.

3.6 Méthodes de Classification

Les méthodes de classification sont des techniques d'apprentissage automatique (Machine Learning) qui permettent d'attribuer automatiquement une classe à une donnée en fonction de ses caractéristiques. Elles reposent sur un apprentissage à partir d'exemples étiquetés afin de construire un modèle capable de généraliser sur de nouvelles données. Dans notre projet, nous utilisons ces méthodes pour la classification des défauts de surface dans les images industrielles : chaque image est représentée par un vecteur de caractéristiques (par exemple HOG, LBP ou Gabor), puis un classifieur apprend à distinguer les différentes catégories de défauts (ou absence de défaut) afin d'automatiser le processus de détection et améliorer la fiabilité du contrôle qualité.

Dans cette section, nous présentons les principes fondamentaux des deux méthodes de classification utilisées dans ce travail : les séparateurs à vaste marge (Support Vector Machine, SVM) et les réseaux de neurones artificiels (ANN, Artificial Neural Network).

3.6.1 Les séparateurs à vaste marge (SVM)

Le classifieur à séparateurs à vaste marge, ou Support Vector Machine (SVM), introduit par Vapnik en 1995 [27], repose sur la théorie de l'apprentissage statistique. L'algorithme SVM s'appuie sur le concept d'hyperplans de séparation et cherche à identifier celui qui maximise la marge entre les deux classes à distinguer. Cette approche vise à obtenir un modèle robuste, capable de généraliser efficacement sur des données non vues. Dans le cas d'un problème linéairement séparable, le SVM linéaire peut être formulé de la manière suivante :

Considérons un ensemble d'entraînement:

$$S = \{(x_1, y_1), \dots, (x_i, y_i)\} \subset R^n \times \{-1, 1\} \quad 3.1$$

Où x_i représente les vecteurs en entrée et y_i est le label de classe du vecteur x_i .

L'algorithme du SVM vise à trouver, pour les données fournies, un hyperplan qui maximise la marge pour l'ensemble d'apprentissage (voir figure 3.2). Cet hyperplan est paramétré par:

$$S = \{x \mid \langle w, x \rangle + b = 0\} \quad (3.2)$$

où w est un vecteur de poids et b un biais. La fonction de décision associée est donnée par:

$$y = f(x) = \text{sign}(\langle w, x \rangle + b) \quad (3.3)$$

Cette fonction de décision est invariante par changement d'échelle, d'où l'hyperplan canonique est défini par:

$$\{\langle w, x \rangle + b \geq 1 \text{ si } y_i = 1 \text{ et } \langle w, x \rangle + b \leq -1 \text{ si } y_i = -1\} \quad (3.4)$$

En utilisant une formulation lagrangienne, la fonction discriminante de l'hyperplan optimal devient :

$$f(x) = \text{sign}(\sum_{i=1}^N \alpha_i y_i \langle x, x_i \rangle + b) \quad (3.5)$$

où x est le vecteur à classifier, x_i sont les vecteurs d'apprentissage et $\alpha_i > 0$ sont les multiplicateurs de Lagrange.




Figure 3.2 Surface de séparation linéaire du classifieur SVM.

Une des forces des SVM réside dans leur capacité à utiliser des noyaux pour projeter les données dans un espace de plus grande dimension, permettant ainsi de traiter des problèmes non linéaires. Parmi les noyaux [27] couramment utilisés, on trouve :

- Le noyau linéaire : $K(x, x_i) = \langle x, x_i \rangle$
- Le noyau polynomial : $K(x, x_i) = (\langle x, x_i \rangle + c)^n$
- Le noyau gaussien (ou RBF) : $K(x, x_i) = \exp(-\frac{\|x - x_i\|^2}{2\sigma^2})$
- Le noyau sigmoïde : $K(x, x_i) = \tanh(\alpha \langle x, x_i \rangle + c)$

❖ Extension des SVM aux problèmes multiclassés

Les machines à vecteurs de support (SVM) ont été initialement développées pour résoudre des problèmes de classification binaire. Cependant, de nombreuses applications réelles, telles que la classification des défauts de surface des plaques d'acier, nécessitent la distinction entre plusieurs classes. Pour étendre les SVM aux problèmes multiclassés, différentes stratégies de décomposition ont été proposées.

La stratégie la plus couramment utilisée est l'approche « un contre tous » (One-Versus-All, OVA), dans laquelle un classifieur SVM est entraîné pour chaque classe. Chaque classifieur apprend à distinguer une classe donnée de l'ensemble des autres classes. Lors de la phase de prédiction, l'échantillon est affecté à la classe associée au score de décision le plus élevé.

Une autre approche largement utilisée est la stratégie « un contre un » (One-Versus-One, OVO). Dans ce cas, un classifieur est construit pour chaque paire de classes. Pour un problème comportant (N) classes, le nombre total de classifieurs est donné par :

$$\frac{N(N-1)}{2} \quad (3.1)$$

La décision finale est obtenue par un mécanisme de vote majoritaire entre les différents classifieurs. Cette stratégie permet de traiter efficacement les problèmes multiclasses tout en conservant les performances élevées des SVM pour la séparation des différentes catégories de défauts.

3.6.2 Réseaux de Neurones Artificiels (ANN)

Les réseaux de neurones artificiels (Artificial Neural Networks, ANN) sont des modèles computationnels inspirés du fonctionnement du cerveau humain [28]. Ils visent à reproduire, de manière simplifiée, certains mécanismes cognitifs tels que l'apprentissage, la mémorisation, la reconnaissance de formes et la prise de décision. Le cerveau humain est constitué de milliards de neurones interconnectés par des synapses, formant un réseau complexe capable de traiter et de transmettre des informations. De manière analogue, un réseau de neurones artificiels est composé d'unités de calcul, appelées neurones artificiels, organisées en couches et reliées entre elles par des connexions pondérées (voir figure 3.3). Ces réseaux sont capables d'apprendre à partir des données en ajustant progressivement les poids des connexions au cours d'un processus itératif basé sur la répétition et la correction des erreurs, leur permettant ainsi d'améliorer leurs performances au fil de l'apprentissage.




Figure 3.3 Architecture d'un réseau de neurones artificiel à deux couches cachées (ANN).

● Principe de fonctionnement

Dans sa version la plus simple, un neurone formel (voir figure 3.4) calcule la somme pondérée des entrées reçues et ajoute un biais, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone, comme montré dans l'équation suivante [29] :




Figure 3.4: Schéma d'un Neurone artificiel [29].

$$y_i = \phi(\sum_{i=1}^n (w_{ij} * x_i) + b_j)$$

Où :

- x_i : les entrées.
- w_{ij} : les poids synaptiques.
- b_j : le biais (seuil).
- $\sum_{i=1}^n (w_{ij} * x_i) + b_j$: la somme pondérée.
- ϕ : la fonction d'activation (sigmoïde, tanh, ReLU...).
- y_i : la sortie du neurone.

Le poids : Le poids est le coefficient qui control le signal d'entrée (la force de connexion), en d'autres termes le poids décide l'influence de l'entrée sur la sortie.

Le biais : Le biais dans un réseau neuronal est un paramètre supplémentaire qui se connecte aux neurones de la couche précédente via un poids, souvent appelé seuil. C'est similaire à l'ajout d'une constante dans une équation linéaire pour ajuster la sortie en fonction de la somme pondérée des entrées du neurone. En ajustant le biais, le modèle peut mieux s'adapter aux données.

La fonction d'activation : Est une fonction mathématique responsable du type de l'information émise par le neurone, elle intervient après le calcul de la somme pondérée et l'ajout du biais, elle possède un influe profond sur les performances du réseau. D'où il est préférable de bien choisir le type de cette fonction dans chaque couche du réseau, notons que les neurones d'entrées ne possèdent pas de fonction d'activation, ils utilisent la fonction identité (voir le tableau 3.1).

Nom de la fonction	Relation d'entrée/sortie	Icône
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
linéaire	$a = n$	
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
sigmoïde	$a = \frac{1}{1+\exp^{-n}}$	
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
compétitive	$a = 1$ si n maximum $a = 0$ autrement	

Tableau 3.1 : Différents types de fonctions d'activations [29].

3.6.3 Perceptron multicouche (MLP Multilayer Perceptron)

C'est un type de réseau de neurones artificiels composé d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie. Les neurones sont organisés en couches successives et reliés par des connexions pondérées. L'apprentissage d'un MLP se fait généralement par l'algorithme de la rétropropagation « back-propagation » [30] qui est l'exemple d'apprentissage supervisé le plus utilisé pour les MLP. Il utilise une méthode d'optimisation universelle consiste à trouver les coefficients du réseau (poids et biais) minimisant une fonction d'erreur globale (fonction coût). La technique de rétro-propagation du gradient est une méthode qui permet de calculer le gradient de l'erreur pour chaque neurone du réseau, de la dernière couche vers la première, le principe de la rétropropagation peut être résumée par l'algorithme suivant :

Répéter :

1. **Propagation avant (forward propagation)** : les données d'entrée traversent successivement les couches du réseau jusqu'à la couche de sortie, produisant ainsi une prédiction.
2. **Calcul de l'erreur** : la sortie obtenue est comparée à la valeur cible à l'aide d'une fonction de coût (par exemple l'erreur quadratique moyenne).

3. **Rétropropagation de l'erreur** : l'erreur est propagée de la couche de sortie vers les couches cachées afin de calculer les gradients, c'est-à-dire l'influence de chaque poids sur l'erreur globale.
4. **Mise à jour des paramètres** : les poids et les biais sont ajustés dans la direction opposée au gradient (descente de gradient) afin de minimiser la fonction de coût.

Jusqu'à ce qu'une condition d'arrêt soit satisfaite, par exemple :

une erreur quadratique moyenne (EQM) inférieure à un seuil fixé, ou un nombre maximal d'itérations atteint.

L'efficacité de l'algorithme de la rétro-propagation dépend, en effet, d'un grand nombre de paramètres que l'utilisateur doit fixer : le pas du gradient, les paramètres des fonctions d'activation, l'architecture du réseau (nombre de couches, nombre de neurones par couche), l'initialisation des poids.

3.7 Conclusion

Dans ce chapitre, nous avons présenté les fondements du Machine Learning, un domaine central de l'intelligence artificielle. Nous avons défini ses principes généraux, ses principales étapes de fonctionnement, ainsi que les différents types d'apprentissage : supervisé, non supervisé et par renforcement.

Ensuite, nous nous sommes intéressés à deux méthodes de classification largement utilisées les Machines à Vecteurs de Support (SVM) et les Réseaux de Neurones Artificiels (ANN). Les SVM reposent sur la recherche d'un hyperplan optimal maximisant la marge entre les différentes classes, ce qui leur confère une bonne capacité de généralisation, notamment dans les problèmes de classification à haute dimension. De leur côté, les ANN s'inspirent du fonctionnement du cerveau humain et permettent de modéliser des relations non linéaires complexes grâce à l'apprentissage des poids via la rétropropagation de l'erreur.

Chapitre 4

Classification des défauts de surface : implémentation et analyse des performances

4.1 Introduction

Ce chapitre présente la mise en œuvre pratique de l'approche proposée pour la classification automatique des défauts de surface des plaques d'acier laminées à chaud. Après une présentation de la base de données NEU, les différentes étapes du système développé sont décrites, notamment le prétraitement des images, l'extraction des caractéristiques à l'aide des descripteurs LBP, HOG et des filtres de Gabor, ainsi que l'apprentissage des classifieurs SVM et ANN. Enfin, les performances des différentes combinaisons de descripteurs et de classifieurs sont évaluées et comparées à l'aide de métriques appropriées afin d'identifier les configurations les plus efficaces pour la reconnaissance des défauts de surface.

4.2 Présentation de la base de données NEU-CLS

La base de données NEU-CLS, qui est disponible sur Kaggle, est l'un des jeux de données de référence les plus utilisés pour l'évaluation des méthodes de détection et de classification des défauts de surface des plaques d'acier laminées à chaud. Elle a été développée par l'Université du Nord-Est (*Northeastern University*, Chine) afin de fournir un ensemble d'images standardisé pour la comparaison des performances des différentes approches proposées dans la littérature. Elle contient un total de 1 800 images en niveaux de gris, réparties équitablement en six catégories de défauts, avec 300 images par classe. Les défauts considérés sont les suivants :

- Crazing (Cr) : fissures superficielles ;
- Inclusion (In) : inclusions de matériaux étrangers ;
- Patches (Pa) : zones présentant des irrégularités locales ;
- Pitted Surface (PS) : surfaces piquées ou poreuses ;
- Rolled-in Scale (RS) : calamine incrustée ;
- Scratches (Sc) : rayures superficielles.

La base de données est divisée en deux ensembles : un ensemble d'apprentissage (*train set*) contenant 1440 images, utilisé pour l'entraînement des modèles, et un ensemble de test (*test set*) contenant 360 images, destiné à évaluer leurs performances sur de nouvelles données. Bien que toutes les images de la base NEU-CLS aient une résolution identique de 200×200 pixels, les défauts qu'elles contiennent présentent des variations importantes en termes de taille apparente, de forme, d'orientation, de texture et de contraste, ce qui rend leur classification automatique particulièrement complexe. La Figure 4.1 montre des exemples représentatifs des six classes de défauts de la base NEU-CLS.




Figure.4.1 Exemples de défauts de surface issus de la base de données NEU-CLS.

4.3 Description de la méthodologie utilisée

La méthodologie adoptée tout au long de ce travail est résumée dans l'organigramme illustré dans la Figure 4.2.




Figure 4.2: Organigramme présentant les différentes étapes de la méthodologie utilisée.

4.3.1 Prétraitement des données

Les images ont été soumises à une étape de suppression du bruit à l'aide d'un filtre médian, ce qui permet de réduire les perturbations tout en préservant les contours importants. Par ailleurs, une amélioration du contraste a été appliquée afin d'uniformiser les niveaux d'intensité, en raison des variations d'éclairage présentes dans les images de la base de données. La Figure 4.3 illustre un exemple des effets obtenus après ces opérations de prétraitement.




Figure 4.3: Étapes de prétraitement : (a) image originale, (b) image filtrée à l'aide d'un filtre médian, (c) image filtrée avec amélioration du contraste.

4.3.2 Extraction des descripteurs HOG, LBP et Gabor

Dans cette partie, les images prétraitées sont représentées sous forme de vecteurs de caractéristiques à l'aide des descripteurs HOG, LBP et Gabor déjà présentés dans le chapitre 2. L'objectif est d'extraire des informations complémentaires décrivant la forme, la texture et les propriétés fréquentielles des images de défauts.

Le descripteur HOG est utilisé pour capturer les informations de forme et de contours, tandis que le LBP permet de représenter la texture locale des surfaces analysées. Le descripteur de

Gabor, quant à lui, est employé pour extraire des caractéristiques fréquentielles et directionnelles à différentes échelles et orientations.

Les caractéristiques extraites par chaque méthode sont transformées en vecteurs et sont utilisées individuellement (HOG, LBP, Gabor) et combinées (HOG+LBP, HOG+Gabor, LBP+Gabor) afin de former un vecteur global plus discriminant. Ces vecteurs constituent l'entrée du classifieur pour la phase d'apprentissage et de reconnaissance des défauts.

4.3.3 Classification supervisée des défauts à l'aide des SVM et ANN

Cette section présente l'application de deux techniques de classification supervisée, à savoir le réseau de neurones artificiels (ANN) et la machine à vecteurs de support (SVM) présentées en chapitre 3, afin de classifier les défauts à partir des descripteurs extraits lors de la phase précédente. Toutes les simulations ont été réalisées sous l'environnement Python.

A. Préparation des données

Le jeu d'apprentissage est soumis à une validation croisée stratifiée à 5 plis (Stratified K-Fold, $K = 5$) pour les deux classifieurs SVM et ANN. La stratification garantit que la proportion des six classes de défauts est respectée dans chaque pli. À chaque itération, 4 plis (80 % des données du jeu d'apprentissage) sont utilisés pour l'apprentissage et 1 pli (20 % restants) pour la validation. Ce processus est répété 5 fois de façon à ce que chaque échantillon du jeu d'apprentissage soit utilisé une fois comme donnée de validation. La normalisation StandardScaler est recalculée à chaque pli, uniquement à partir des données d'apprentissage du pli concerné, afin d'éviter toute fuite d'information (data leakage) vers les données de validation. Cette validation croisée est utilisée afin d'obtenir une estimation plus fiable et robuste des performances de chaque configuration de classifieur testée. Elle permet de réduire la dépendance à un découpage particulier des données, de mieux exploiter l'ensemble du jeu d'apprentissage et de limiter les risques de surapprentissage. Le choix de $K = 5$ représente un bon compromis entre la précision de l'estimation et le coût de calcul, tout en assurant une variance raisonnable des résultats, ce qui permet d'obtenir une estimation stable et une meilleure capacité de généralisation du modèle. Les résultats de cette étape (CV-accuracy, CV-F1-score) sont rapportés sous forme de moyenne $\pm$ écart-type sur les 5 plis, et servent de critère de sélection de la meilleure configuration d'hyperparamètres pour chaque classifieur (voir section C).

Une fois la configuration optimale identifiée, le modèle correspondant est réentraîné sur l'intégralité du jeu d'apprentissage (80 %) et évalué une seule fois sur le jeu de test (20 %), jamais vu auparavant, afin d'obtenir une estimation finale et indépendante de sa capacité de généralisation (accuracy, F1-score).

B. Classification par SVM et ANN

Les classifieurs SVM et ANN, présentés au chapitre 3, sont utilisés pour la classification des défauts à partir des vecteurs de caractéristiques extraits des images prétraitées. Les vecteurs de caractéristiques obtenus à partir des descripteurs HOG, LBP et Gabor, ainsi que de leurs combinaisons (HOG+LBP, HOG+Gabor, LBP+Gabor et HOG+LBP+Gabor), sont successivement utilisés comme données d'entrée des deux classifieurs.

Le processus de classification se déroule en deux étapes :

- **Étape d'apprentissage** : au cours de cette phase, le classifieur apprend à partir des exemples étiquetés en ajustant ses paramètres internes afin de modéliser la relation entre les vecteurs de caractéristiques et les classes correspondantes.
- **Étape de prédiction** : une fois l'apprentissage terminé, le classifieur utilise les paramètres appris précédemment pour prédire la classe des exemples non vus durant la phase d'apprentissage.

Pour chaque descripteur et chaque combinaison de descripteurs, plusieurs configurations d'hyperparamètres ont été testées manuellement pour les deux classifieurs, en évaluant à chaque fois le CV-accuracy (moyenne et écart-type sur les 5 plis) obtenu sur le jeu d'apprentissage. La configuration retenue est celle maximisant le CV-accuracy tout en présentant un écart-type faible, gage d'une meilleure stabilité du modèle vis-à-vis du découpage des données.

B.1 Apprentissage du classifieur ANN

Le réseau de neurones utilisé est un perceptron multicouche (MLP). Le nombre de couches cachées ainsi que le nombre de neurones les composant ont été variés lors de la phase d'optimisation présentée en section C. La fonction d'activation utilisée est ReLU pour les couches cachées et Softmax pour la couche de sortie, adaptée à la classification multiclass à six catégories. L'optimiseur utilisé est Adam avec un taux d'apprentissage initial de valeur 0.01, la fonction de perte est l'entropie croisée catégorielle (categorical cross-entropy), et l'entraînement est effectué sur 500 époques. Un mécanisme d'arrêt anticipé (early stopping) a été utilisé pour limiter le surapprentissage.

B.2 Apprentissage du classifieur SVM

Dans ce travail, la classification des défauts de surface constitue un problème multiclasss comprenant six catégories de défauts. L'extension multiclass des SVM permet ainsi de distinguer automatiquement les différentes classes à partir des caractéristiques extraites des images. L'algorithme SVM utilisé est implémenté à l'aide de la classe SVC de la bibliothèque scikit-learn. Cette implémentation repose sur la stratégie « un contre un » (One-Versus-One, OVO), qui consiste à construire un classifieur binaire pour chaque paire de classes (voir section 3.6.1). Ainsi, pour les six classes de défauts de la base de données NEU-CLS, quinze classifieurs binaires sont entraînés. Lors de la phase de prédiction, chaque classifieur attribue un vote à l'une des deux classes qu'il distingue. La classe finale est ensuite déterminée par un mécanisme de vote majoritaire parmi l'ensemble des classifieurs.

Le type de noyau (kernel) ainsi que les paramètres de régularisation C et gamma ont été variés lors de la phase d'optimisation présentée en section C.

C. Optimisation des hyperparamètres

Les hyperparamètres du SVM et de l'ANN ont été ajustés manuellement pour chaque descripteur (HOG, LBP, Gabor) et leurs combinaisons. Plusieurs configurations ont été testées en faisant varier le type de noyau (rbf, linéaire), le paramètre de régularisation C (1, 10, 100) et le paramètre gamma (0.01, 0.001 et 0.0001) pour le classifieur SVM, et le nombre de couches cachées (1 ou 2), le nombre de neurones par couche (1024, 512, 256, etc...) ainsi que la fonction d'activation (sigmoïde, Relu) des couches cachées pour le classifieur ANN. Pour chaque configuration, une validation croisée à 5 plis a été réalisée afin d'évaluer la performance moyenne et la stabilité du modèle. La configuration retenue pour chaque descripteur est celle ayant obtenu les meilleurs résultats en validation croisée, ces performances étant ensuite confirmées par l'évaluation finale sur le jeu de test.

4.4 Évaluation et interprétation des résultats

Cette section présente les résultats expérimentaux obtenus avec les deux classifieurs (SVM et ANN), appliqués à la base de données NEU-CLS. L'objectif de cette section est d'évaluer l'influence des différents descripteurs et de leurs combinaisons sur les performances des classifieurs. Les résultats obtenus avec chaque vecteur de caractéristiques sont comparés afin d'identifier la représentation la plus discriminante pour la classification des défauts. Une analyse comparative des performances des classifieurs SVM et ANN est également menée afin de déterminer l'approche la plus adaptée à la base de données étudiée.

A. Évaluation des performances

L'évaluation des performances d'un modèle repose sur l'analyse de la matrice de confusion (voir Tableau 4.1), qui permet de comparer les prédictions du modèle aux valeurs réelles en distinguant les classifications correctes et incorrectes. À partir de cette matrice, plusieurs métriques sont calculées afin de quantifier les performances du modèle, notamment l'exactitude (accuracy), la précision, le rappel (ou sensibilité) et le F1-score. Ces mesures permettent d'obtenir une évaluation plus complète et plus fiable que l'exacte précision globale, en particulier dans le cas de jeux de données déséquilibrés ou de problèmes de classification complexes.

Classe prédite \ Classe réelle	Positif	Négatif
	Positif	Négatif
Positif	Vrai Positif (VP)	Faux Négatif (FN)
Négatif	Faux Positif (FP)	Vrai Négatif (VN)

Tableau 4.1 : Matrice de confusion

Les performances sont ensuite évaluées à l'aide de plusieurs métriques classiques :

- **Exactitude (Accuracy)** : proportion globale de prédictions correctes.

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.1)$$

- **Précision (Precision)** : proportion de vrais positifs parmi les positifs prédits.

$$Precision = \frac{VP}{VP + FP} \quad (4.2)$$

- **Rappel (Recall ou Sensibilité)** : proportion de vrais positifs parmi les cas réellement positifs.

$$Rappel = \frac{VP}{VP + FN} \quad (4.3)$$

- **F1-score** : moyenne harmonique entre précision et rappel.

$$F1 = 2 \times \frac{Precision \times Rappel}{Precision + Rappel} \quad (4.4)$$

L'évaluation des performances des deux classifieurs, dans notre cas, repose sur l'accuracy et le F1-score. Afin d'obtenir une estimation plus robuste et fiable des performances, ces métriques sont également calculées dans le cadre de la validation croisée à cinq fold (5-fold cross-validation), donnant lieu aux indicateurs CV-Accuracy et CV-F1-score. Les valeurs d'accuracy et de F1-score sont ensuite calculées sur l'ensemble de test afin d'évaluer la capacité de généralisation des modèles sur des données non vues durant la phase d'apprentissage. Enfin, pour le modèle présentant les meilleures performances, une matrice de confusion est établie afin d'analyser plus finement la qualité de la classification et d'identifier les éventuelles confusions entre les différentes classes de défauts.

B. Résultats obtenus et discussion

L'ensemble des résultats obtenus est résumé dans le Tableau 4.2. La matrice de confusion associée au meilleur résultat est également présentée afin d'illustrer concrètement la répartition des prédictions en phase de test (voir Figure 4.4).

Les résultats obtenus dans le tableau 4.2, montrent que LBP est le descripteur le plus performant parmi les méthodes individuelles, avec une accuracy de 95,28 % et une CV-accuracy de 96,25 % en association avec le classifieur SVM. Le descripteur Gabor suit avec une accuracy de 93,89 %, tandis que HOG obtient les performances les plus faibles avec une accuracy de 90,83 % et une CV-accuracy de 93,06 %. Cela montre que la texture et les informations fréquentielles sont plus discriminantes que les contours seuls pour la base NEU-CLS.

Concernant les combinaisons de descripteurs, la fusion LBP + Gabor donne les meilleurs résultats globaux, avec une accuracy de 98,33 % et une CV-accuracy de 98,61 %, montrant une nette amélioration. Ceci s'explique par la complémentarité entre la micro-texture locale (LBP) et les informations fréquentielles multi-échelles (Gabor). En revanche, les combinaisons incluant HOG n'améliorent pas significativement les performances. Enfin, le classifieur SVM obtient globalement de meilleures performances que l'ANN, avec des gains allant jusqu'à environ 1 à 2 % selon les descripteurs.

La Figure 4.4 présente la matrice de confusion du modèle LBP+Gabor+SVM sur l'ensemble de test. Quatre des six classes de défauts, crazing (Cr), patches (Pa), pitted surface (PS) et rolled-in scale (RS), sont reconnues avec une précision parfaite de 100 % (60/60). Les seules confusions observées concernent les classes inclusion (In) et scratches (Sc) : trois échantillons de la classe inclusion sont classés à tort comme scratches, et quatre échantillons de scratches sont classés comme inclusion. Cette confusion bidirectionnelle est cohérente avec la similitude visuelle entre ces deux classes, qui présentent toutes deux des motifs allongés et fins à la surface de l'acier, comme illustré à la Figure 4.1. Malgré ces erreurs, la précision globale reste élevée à 98,33 %.

D'autre part, les meilleures performances du SVM s'expliquent probablement par la taille modeste du jeu de données, qui favorise un modèle comme le SVM, capable de bien généraliser avec peu d'exemples grâce à son principe de marge maximale. Les réseaux de neurones, plus nombreux en paramètres, sont en comparaison, plus sensibles au surapprentissage et nécessitent davantage de données ainsi qu'un réglage plus fin de leur architecture pour être pleinement performants.

Tableau 4.2 : Bilan des performances des classifieurs ANN et SVM sur la base de données NEU-CLS.

Descripteur	Classifieur	CV-ACC (%)	CV-F1 (%)	ACC (%)	F1 (%)
HOG	ANN	92.15 ± 1.00	92.14 ± 0.98	90.00	89.97
	SVM	93.06 ± 0.44	93.02 ± 0.44	90.83	90.79
LBP	ANN	95.69 ± 0.89	95.69 ± 0.90	95.28	95.28
	SVM	96.25 ± 1.27	96.23 ± 1.28	95.28	95.27
Gabor	ANN	94.58 ± 1.45	94.58 ± 1.47	92.78	92.65
	SVM	96.46 ± 1.21	96.45 ± 1.23	93.89	93.74
HOG+LBP	ANN	92.57 ± 0.64	92.56 ± 0.64	91.11	91.03
	SVM	94.03 ± 1.31	94.00 ± 1.35	92.50	92.39
HOG+Gabor	ANN	91.94 ± 1.23	91.86 ± 1.24	91.94	91.71
	SVM	94.03 ± 0.40	93.99 ± 0.41	92.50	92.50
LBP+Gabor	ANN	98.06 ± 0.71	98.06 ± 0.72	97.78	97.77

Descripteur	Classifieur	CV-ACC (%)	CV-F1 (%)	ACC (%)	F1 (%)
	SVM	98.61 ± 0.31	98.61 ± 0.31	98.33	98.33
HOG+LBP+Gabor	ANN	93.61 ± 0.56	93.63 ± 0.56	93.89	93.85
	SVM	95.42 ± 0.97	95.39 ± 1.01	95.56	95.52




Figure 4.4 : Matrice de confusion du modèle LBP + Gabor + SVM sur l'ensemble de test (ACC = 98,33 %). Classes 0–5 : Cr, In, Pa, PS, RS, Sc.

4.5 Conclusion

Dans ce chapitre, nous avons présenté les résultats expérimentaux obtenus pour la classification des défauts de la base de données NEU-CLS à l'aide des classifieurs SVM et ANN. Les performances ont été évaluées en utilisant plusieurs descripteurs de caractéristiques, à savoir HOG, LBP et Gabor, ainsi que leurs différentes combinaisons.

Les résultats obtenus montrent que les descripteurs de texture, en particulier LBP et Gabor, sont les plus discriminants pour cette tâche de classification. La fusion de ces deux descripteurs a permis d'atteindre les meilleures performances, avec une accuracy de 98,33 % et une CV-accuracy de 98,61 %, confirmant ainsi leur complémentarité.

Par ailleurs, les résultats indiquent que le classifieur SVM surpasse globalement le réseau de neurones artificiels ANN sur la majorité des configurations testées. Enfin, l'utilisation de la validation croisée a permis d'assurer une évaluation plus robuste et fiable des performances des modèles.

Conclusion générale et perspectives

Ce travail de mémoire s'est intéressé à la classification automatique des défauts de surface de l'acier, à partir de la base de données NEU-CLS. L'objectif principal consistait à évaluer l'efficacité de descripteurs de caractéristiques conçus manuellement, associés à différentes techniques de classification supervisée, afin de déterminer la combinaison la plus performante pour la reconnaissance des différents types de défauts.

La méthodologie proposée s'est articulée autour de plusieurs étapes : le prétraitement des images par réduction du bruit et amélioration du contraste, l'extraction des caractéristiques à l'aide des descripteurs HOG, LBP et Gabor, ainsi que l'évaluation de différentes combinaisons de ces descripteurs. Les vecteurs de caractéristiques obtenus ont ensuite été utilisés pour entraîner et évaluer deux classifieurs, à savoir la machine à vecteurs de support (SVM) et le réseau de neurones artificiels (ANN).

Les résultats expérimentaux obtenus montrent que les descripteurs de texture, notamment LBP et Gabor, offrent les meilleures capacités de discrimination pour la classification des défauts de surface. La combinaison LBP + Gabor s'est révélée la plus performante, avec une exactitude de 98,33 % sur l'ensemble de test et une CV-Accuracy de 98,61 % avec le classifieur SVM. Les résultats ont également montré que le SVM surpasse globalement l'ANN sur la majorité des configurations testées, ce qui peut s'expliquer par la taille modérée de la base de données et par l'efficacité du SVM à exploiter des vecteurs de caractéristiques de dimension modérée.

Plusieurs perspectives peuvent être envisagées afin d'améliorer et d'étendre ce travail :

- étudier d'autres techniques d'extraction de caractéristiques, telles que les descripteurs basés sur les ondelettes ou les caractéristiques profondes ;
- explorer des stratégies de fusion plus avancées des descripteurs afin d'exploiter davantage leur complémentarité ;
- optimiser les hyperparamètres des classifieurs à l'aide de méthodes de recherche automatisées ;
- évaluer l'approche proposée sur d'autres bases de données de défauts industriels afin de vérifier sa robustesse et sa capacité de généralisation ;
- comparer les méthodes traditionnelles aux approches d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN), capables d'apprendre automatiquement des représentations discriminantes à partir des images brutes ;

Ces perspectives ouvrent la voie à des travaux futurs visant à concevoir des systèmes de détection et de classification des défauts toujours plus performants, robustes et adaptés aux contraintes industrielles.

Références

- [1] World Steel Association. World Steel in Figures 2023. Brussels: World Steel Association; 2023. Disponible sur : <https://worldsteel.org>
- [2] Roberts W.L. Hot Rolling of Steel. New York: Marcel Dekker; 1983. 800 p. (Manufacturing Engineering and Materials Processing; vol. 10).
- [3] Benasciutti D., Branco R. Scale removal in hot rolling mills: a review of high-pressure water descaling systems. Journal of Materials Processing Technology. 2012;212(4):789–802.
- [4] Pittner J., Simaan M.A. Tandem Cold Metal Rolling Mill Control: Using Practical Advanced Methods. London: Springer; 2011. 239 p.
- [5] Song, K., Yan, Y. (2013). A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects. Applied Surface Science, 285, 858–864. <https://doi.org/10.1016/j.apsusc.2013.08.002>.
- [6] He K., Zhang X., Ren S., Sun J. Surface Defect Dataset for Steel Strip: NEU Surface Defect Database. IEEE Transactions on Instrumentation and Measurement. 2020;69(7):4893–4905.
- [7] Neogi N., Mohanta D.K., Dutta P.K. Review of vision-based steel surface inspection systems. EURASIP Journal on Image and Video Processing. 2014;2014(1):50.
- [8] Schmidhuber J. Deep learning in neural networks: An overview. Neural Networks. 2015;61:85–117.
- [9] Luo Q., Fang X., Liu L., Yang C., Sun Y. Automated visual defect detection for flat steel surface: a survey. IEEE Transactions on Instrumentation and Measurement. 2020;69(3):626–644.
- [10] LeCun Y., Bengio Y., Hinton G. Deep learning. Nature. 2015;521(7553):436–444.
- [11] Szeliski, R. (2022). Computer Vision: Algorithms and Applications (2nd ed.). Springer. ISBN 978-3-030-34372-9.
- [12] Gonzalez, R. C., & Woods, R. E. (2018). Digital Image Processing (4th ed.). Pearson. ISBN 978-0-13-335672-4.
- [13] Steger, C., Ulrich, M., & Wiedemann, C. (2018). Machine Vision Algorithms and Applications (2nd ed.). Wiley-VCH.
- [14] Malamas, E. N., et al. (2003). A survey on industrial vision systems, applications and tools. Image and Vision Computing, 21(2), 171–188.
- [15] Zhang, X., et al. (2021). Deep learning-based surface defect inspection: A comprehensive review. Engineering Applications of Artificial Intelligence, 104, 104322.

- [16] Jain, A. K. (1989). *Fundamentals of Digital Image Processing*. Prentice Hall.
- [17] Serra, J. (1982). *Image Analysis and Mathematical Morphology*. Academic Press.
- [18] Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE TPAMI*, 24(7), 971–987.
- [19] Pietikainen, M., Hadid, A., Zhao, G., & Ahonen, T. (2011). *Computer Vision Using Local Binary Patterns*. Springer.
- [20] Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *CVPR 2005*, 1, 886–893.
- [21] Daugman, J. G. (1985). Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. *Journal of the Optical Society of America A*, 2(7), 1160–1169.
- [22] Manjunath, B. S., & Ma, W. Y. (1996). Texture features for browsing and retrieval of image data. *IEEE TPAMI*, 18(8), 837–842.
- [23] Jain, A. K., & Farrokhnia, F. (1991). Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24(12), 1167–1186.
- [24] Humeau-Heurtier, A. (2019). Texture feature extraction methods: A survey. *IEEE Access*, 7, 8975–9000.
- [25] C. M. Bishop, *Pattern Recognition and Machine Learning*. Springer, 2006.
- [26] Wikipédia : « Apprentissage automatique », Mémoire (article en ligne), Fondation Wikimedia, Département d'Intelligence Artificielle, 2025, consulté sur https://fr.wikipedia.org/wiki/Apprentissage_automatique. [Accès le 9 septembre 2025]. Publication de la dernière modification : 9 juin 2025.
- [27] Vladimir Vapnik. *The Nature of Statistical Learning Theory*. New York : Springer-Verlag, 1995.
- [28] T. M. Mitchell, *Machine Learning*. New York, NY, USA: McGraw-Hill, 1997, p. 27.
- [29] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Pearson, 2009.
- [30] L. Martin : « Analyse de la propagation avant dans les réseaux de neurones artificiels pour la reconnaissance de formes » Thèse de Doctorat, Université de Lyon, Faculté des Sciences, Département d'Informatique, 2021.