

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**

**MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA  
RECHERCHE SCIENTIFIQUE**

**UNIVERSITE SAAD DAHLAB BLIDA 01**



**Faculté de Technologie  
Département automatique**

## **Mémoire de Projet de Fin d'Études**

Pour l'obtention du diplôme de Master

**Option : Automatique Appliquée**

---

### **Thème**

---

# **Implémentations De l'IA Dans Une Machine D'inspection Par Camera**

---

**Dirigé par :**

M. BENCHABANE B SOFIANE

M.DJELOULI BILEL

**Réalisé par :**

M. HORRI WALID

M. HAMZA ISHAK

BLIDA Juin 2023

## Remerciements

---

À la fin de ce parcours académique significatif, j'aimerais exprimer ma plus profonde gratitude à toutes les personnes qui ont contribué à la réalisation de ce Projet de Fin d'Études.

Tout d'abord, je tiens à remercier mon promoteur, Monsieur BENCHABANE B SOFIANE, pour sa précieuse guidance, sa patience et son soutien inestimables. Ses conseils pertinents et son dévouement inconditionnel ont largement contribué à la réalisation de ce travail.

Je voudrais également remercier mes encadreur dans l'entreprise BOMARE Company, Monsieur DJELOULI Bilel et BOUMEDIENE Walid. Leur contribution a été essentielle dans l'application pratique de ce projet et ses expériences a été une source d'inspiration inestimable pour nous.

Un grand merci à l'équipe pédagogique de département ATM et ELT, pour le savoir et la passion qu'ils ont montrés tout au long de ma formation. Chaque cours, chaque interaction a été un pas de plus vers la réalisation de ce projet.

À ma famille, mes parents et mes frères et sœurs, je vous dois une reconnaissance infinie. Votre amour, votre soutien et votre confiance ont été ma source d'inspiration et ma force tout au long de ce voyage. Merci pour votre foi inébranlable en moi.

Enfin, je tiens à remercier chaque personne qui a directement ou indirectement contribué à la réussite de ce projet, votre soutien n'a pas été en vain.

*A mes chers parents, Vous êtes la source de mon être et de mon évolution.*

*Votre amour inconditionnel m'a façonné et m'a guidé tout au long de ma vie. A mes frères et ma sœur, Nos liens indissolubles, forgés dans les joies et les peines partagées, sont précieux et irremplaçables. Vous êtes des compagnons de vie inestimables. Et à Walid, Dans le labyrinthe de la vie, certaines âmes laissent une empreinte indélébile, et vous, Walid, êtes l'une d'elles. Pour votre amitié, pour votre sincérité, pour chaque moment de rire et de réflexion partagée, pour être à mes côtés dans les hauts et les bas, je vous offre ma profonde gratitude. A MHT, Votre soutien indéfectible et votre foi en moi ont été un réconfort et un pilier dans ma vie. Je vous suis profondément reconnaissant. Et à mes amis, Vous qui m'avez accompagné dans ce voyage, qui avez partagé mes peines et mes joies, mes victoires et mes échecs. Vous m'avez donné le courage de poursuivre mes rêves et la force de surmonter les obstacles. Votre amitié est un cadeau précieux que je chérirai toujours.*

*Je dédie mon travail à chacun de vous, avec tout mon amour et ma gratitude.*

**HAMZA Ishak**

"Je tiens à exprimer ma gratitude envers Allah Tout-Puissant pour Sa guidance, Sa miséricorde et Sa bénédiction tout au long de la rédaction de mon mémoire. C'est grâce à Sa volonté et à Sa grâce que j'ai pu accomplir ce travail.

Mes plus sincères remerciements vont à plusieurs personnes :

Tout d'abord, à mes parents, dont les nombreux sacrifices et le soutien inconditionnel tout au long de mon cursus scolaire ont été d'une importance capitale. Leur confiance en moi ainsi que leur amour ont été une source de détermination qui m'a poussé à réussir.

Je n'oublie pas mes frères et sœurs pour leur présence constante et leurs encouragements, qui ont été un soutien précieux tout au long de mon parcours.

À Hamza Ishak, mon binôme, je tiens à exprimer ma reconnaissance pour notre collaboration fructueuse. Ton dévouement, ton travail acharné et ta camaraderie ont été essentiels pour la réussite de ce mémoire.

Enfin, à Mounignon, qui a toujours été à mes côtés, je tiens à te remercier du fond du cœur pour ton précieux soutien. Tes conseils et ton amitié ont été inestimables tout au long de ce projet.

Ce mémoire marque la fin d'une étape, mais il représente aussi le début d'une nouvelle aventure. À tous ceux qui ont joué un rôle, grand ou petit, dans cette réussite, je vous adresse ma profonde reconnaissance.

**HORRI Walid**

---

## الملخص:

يتناول هذا المشروع النهائي للسنة الدراسية استخدام الذكاء الصناعي (AI) لتحسين عملية فحص اللوحات الدارات المطبوعة (PCBA) في شركة Bomare. باستخدام شبكة عصبية عميقة تُعرف بالشبكة العصبية الالتفافية (CNN)، قمنا بتطوير نموذج AI قادر على التمييز بدقة عالية بين اللوحات الدارات المطبوعة المعيبة والغير معيبة. تم تدريب النموذج على مجموعة كبيرة من الصور، وأظهر النموذج أداء ممتاز من حيث الدقة، الاسترجاع، ودرجة AUC. كما قمنا بمناقشة بالتفصيل عملية دمج النموذج في عملية الإنتاج، مع التأكيد على أهمية التعاون بين الفرق المختلفة، تدريب العاملين، والرصد المستمر لأداء النموذج. تم التأكيد على إمكانية الذكاء الصناعي في تحسين الكفاءة والجودة وتقليل تكاليف الإنتاج، مما يجعل هذه التقنية حلاً ممكناً لفحص اللوحات الدارات المطبوعة في صناعة التصنيع.

**الكلمات المفتاحية:** الذكاء الصناعي (AI)، اللوحات الدارات المطبوعة (PCBA)، بالشبكة العصبية الالتفافية (CNN)،

---

## Résumé :

Ce projet de fin d'études examine l'utilisation de l'intelligence artificielle (IA) pour optimiser l'inspection des cartes de circuits imprimés (PCBA) chez Bomare Company. En utilisant un réseau de neurones convolutifs (CNN), nous avons développé un modèle d'IA capable de différencier avec précision les PCB défectueux des PCB non défectueux. Ce modèle, entraîné sur un large ensemble de données d'images, a démontré d'excellentes performances en termes de précision, de rappel et de score AUC. Nous avons également discuté en détail de l'intégration du modèle dans le processus de production, mettant en évidence l'importance de la collaboration entre différentes équipes, de la formation des opérateurs et de la surveillance continue de la performance du modèle. Le potentiel de l'IA pour améliorer l'efficacité, la qualité et réduire les coûts de production a été mis en évidence, faisant de cette technologie une solution viable pour l'inspection des PCB dans l'industrie manufacturière.

**Mots Clé :** l'intelligence artificielle (IA), PCBA, réseau de neurones convolutifs (CNN), AUC

---

## Abstract:

This final year project investigates the use of artificial intelligence (AI) to enhance the inspection process of printed circuit boards (PCBA) at Bomare Company. Utilizing a convolutional neural network (CNN), we developed an AI model capable of accurately distinguishing defective from non-defective PCBA. Trained on a large dataset of images, the model demonstrated excellent performance in terms of accuracy, recall, and AUC score. We also discussed in detail the integration of the model into the production process, highlighting the importance of collaboration among various teams, operator training, and continuous performance monitoring of the model. The potential of AI to improve efficiency, quality, and reduce production costs was underscored, making this technology a viable solution for PCBA inspection in the manufacturing industry.

**Key Words:** artificial intelligence (AI), PCBA, convolutional neural network (CNN), AUC

# **Table des matières**

Table des matières

*Remerciements*

*Dédicaces*

*Résumés*

*Table des Matières*

*Liste des Figures & Tableaux*

*Liste des Abréviations*

<i>Introduction General</i> .....	1
<i>Chapitre I : Présentation de la Société</i>	
<b>I.1. Introduction</b> .....	<b>3</b>
<b>I.2. Présentation de l'Entreprise Bomare Company</b> .....	<b>3</b>
I.2.1. Introduction .....	3
I.2.2. BOMARE structure .....	4
I.2.3. La vision de Bomare Company .....	8
<b>I.3. Contexte et Importance du Sujet</b> .....	<b>9</b>
<b>I.4. Problématique</b> .....	<b>9</b>
<b>I.5. Objectifs de l'Étude</b> .....	<b>9</b>
<b>I.6. Importance de l'Étude</b> .....	<b>10</b>
<b>I.7. Conclusion</b> .....	<b>10</b>
<i>Chapitre II : L'intelligence artificielle</i>	
<b>II.1. Introduction</b> .....	<b>12</b>
<b>II.2. Introduction à l'intelligence artificielle</b> .....	<b>Error! Bookmark not defined.</b>
II.2.1. Définition de l'IA.....	12
II.2.2. Historique et évolution de l'IA .....	13
II.2.3. Applications de l'IA.....	14
<b>II.3. Les principes de base de l'IA</b> .....	<b>14</b>
II.3.1. L'apprentissage supervisé .....	14
II.3.2. L'apprentissage non supervise.....	15
II.3.3. L'apprentissage par renforcement .....	16
<b>II.4. L'apprentissage profond : un sous-domaine clé de l'IA</b> .....	<b>17</b>
II.4.1. Réseaux de neurones convolutifs (CNN) .....	18
II.4.2. La Propagation Avant Le Principe Fondateur de l'Apprentissage Profond.....	19
II.4.3. La Rétropropagation une Méthode Clé dans l'Apprentissage Profond .....	20
<b>II.5. Les défis de l'apprentissage profonde</b> .....	<b>22</b>

II.5.1. Le Surapprentissage (Overfitting) .....	22
II.5.2. Le Sous-apprentissage (Underfitting).....	24
<b>II.6. Techniques d'optimisation de l'apprentissage profond .....</b>	<b>25</b>
II.6.1. La Normalisation par Lots (Batch Normalization) .....	25
II.6.2. Le Dropout en Apprentissage Profond .....	27
II.6.3. Les Fonctions d'Activation en Apprentissage Profond .....	28
<b>II.7. Les paramètres d'optimisation dans l'apprentissage profond .....</b>	<b>31</b>
II.7.1. Les Optimiseurs en Apprentissage Profond.....	31
II.7.2. Le Taux d'Apprentissage en Apprentissage Profond (Learning Rate).....	34
<b>II.8. L'IA et l'éthique.....</b>	<b>36</b>
II.8.1. Problématiques éthiques liées à l'IA.....	36
II.8.2. Solutions et recommandations .....	37
<b>II.9. Les tendances futures de l'IA .....</b>	<b>38</b>
II.9.1. IA et Big Data .....	38
II.9.2. IA et IoT .....	38
II.9.3. IA et la robotique.....	39
<b>II.10. Conclusion.....</b>	<b>40</b>
 <i>Chapitre III : IA dans le contrôle de qualité</i>	
<b>III.1. Introduction.....</b>	<b>41</b>
<b>III.2. Fabrication de PCBA et Processus de Bain de Soudure .....</b>	<b>41</b>
III.2.1. Fabrication de PCBA .....	41
III.2.2. La technique de soudure par vague.....	43
<b>III.3. Inspection des As : Méthodes Traditionnelles.....</b>	<b>44</b>
III.3.1. Inspection manuelle .....	44
III.3.2. Inspection Automatisée par Rayons X .....	45
III.3.3. Inspection Automatisée Optique (AOI) .....	45
<b>III.4. Notions de Base sur l'Image Numérique .....</b>	<b>46</b>
<b>III.5. Traitement d'images .....</b>	<b>47</b>
III.5.1. Techniques de Traitement d'Image .....	47
<b>III.6. Vision par Ordinateur.....</b>	<b>50</b>
<b>III.7. Application de l'IA dans le Contrôle Qualité .....</b>	<b>51</b>
III.7.1. Vue d'ensemble .....	51
III.7.2. Apprentissage Machine pour le Contrôle Qualité.....	51
III.7.3. Avantages de l'IA pour le Contrôle Qualité .....	51
III.7.4. Défis de l'IA pour le Contrôle Qualité .....	52

<b>III.8. Inspection des PCBA Basée sur l'IA.....</b>	<b>53</b>
III.8.1. Vue d'ensemble .....	53
III.8.2. Avantages de l'inspection des PCBA basée sur l'IA .....	53
III.8.3. Défis de l'inspection des PCBA basée sur l'IA .....	53
III.8.4. Exemples d'inspection des PCBA basée sur l'IA .....	53
<b>III.9. Conclusion .....</b>	<b>54</b>
 <i>Chapitre III : Solution proposée</i>	
<b>IV.1. Introduction.....</b>	<b>55</b>
<b>IV.2. Choix du Modèle d'Apprentissage Automatique .....</b>	<b>55</b>
IV.2.1. Pourquoi un réseau de neurones convolutif (CNN) ? .....	55
IV.2.2. Sélection d'une architecture CNN spécifique .....	56
<b>IV.3. Collecte et Préparation des Données.....</b>	<b>56</b>
IV.3.1. Collecte des Données .....	56
IV.3.2. Préparation des Données .....	57
<b>IV.4. Entraînement du Modèle.....</b>	<b>58</b>
<b>IV.5. Évaluation de la Performance du Modèle .....</b>	<b>59</b>
<b>IV.6. Intégration du Modèle dans les Processus de Production .....</b>	<b>66</b>
<b>IV.7. Intégration de model dans les processus de production.....</b>	<b>67</b>
IV.7.1. Évaluation de la faisabilité de l'intégration .....	67
IV.7.2. Mise en œuvre de l'intégration .....	68
IV.7.3. Surveillance de la performance et amélioration continue .....	69
IV.7.4. Impact de l'intégration du modèle sur la production .....	70
<b>IV.8. Conclusion .....</b>	<b>71</b>
<i>Conclusion Générale et Perspectives .....</i>	<i>71</i>
<i>Références Bibliographiques .....</i>	<i>72</i>
 <i>Annexes</i>	

# **Liste des Figures et Tableaux**

**Liste des Figures**

Figure I.1. BOMARE COMPANY LOGO .....3  
Figure I.2. Unité 1 salle SMT ..... 4  
Figure I.3. Unité 2 d'assemblage.....5  
Figure II.1. Architecture d'un CNN..... 18  
Figure II.2. Linear activation function ..... 29  
Figure II.3. Fonction sigmoïde..... 29  
Figure II.4. Tan activation function ..... 30  
Figure II.5. ReLU activation function ..... 30  
Figure II.6. Correction des biais..... 33  
Figure II.7. Tableau comparatif de optimiseurs communs ..... 34  
Figure III.1. Inspection manuelle de PCBA par un operateur ..... 44  
Figure III.2. Inspection Automatisée par Rayons X..... 45  
Figure III.3. Inspection Automatisée Optique (AOI) ..... 46  
Figure IV.1. Évaluation de la précision du modèle..... 62  
Figure IV.2. Évaluation de la fonction de perte..... 63

**Liste des Tableaux**

Tableau IV-1. Quelques essais..... 65

# **Liste des Abréviations**

**Adam** : Adaptive Moment Estimation

**AOI**: Automated inspection machine

**AUC**: Area Under the ROC Curve

**CNN** : Convolutional neural network

**DPI** : Département de développement de projet industriel

**ESD**: Electrostatic discharge

**HSV**: Hue, saturation, lightness

**IA** : Intelligence Artificielle

**PCBA** : Printed circuit board Assembled

**ReLU**: Rectified Linear Unit

**ResNet**: Residual networks

**RGB**: Red, green, blue

**SGD**: Stochastic Gradient Descent

**SMT** : Surface mount device

**SVM** : Support Vector Machine ou Machine à vecteurs de support

**THT**: PTH (Pin Through Hole)

## Introduction Générale

La vision par ordinateur est un domaine scientifique et une branche de l'intelligence artificielle qui permet aux ordinateurs d'acquérir une compréhension de haut niveau à partir d'images ou de vidéos numériques. Elle vise à automatiser des tâches que le système visuel humain peut accomplir, en analysant et interprétant des images ou des vidéos de la même manière que les humains[1].

Les algorithmes de vision par ordinateur sont basés sur la reconnaissance de formes et nécessitent d'être alimentés par de grandes quantités d'images étiquetées pour être entraînés. Les applications de vision par ordinateur utilisent des capteurs, de l'intelligence artificielle, de l'apprentissage automatique et de l'apprentissage profond pour reproduire le fonctionnement du système visuel humain[2].

Les sous-domaines de la vision par ordinateur incluent la reconstruction de scènes, la détection d'objets, la détection d'événements, le suivi vidéo, la reconnaissance d'objets, l'estimation de la pose 3D, l'apprentissage, l'indexation, l'estimation de mouvement, la supervision visuel, la modélisation de scènes 3D et la restauration d'images[3].

Notre objectif dans le PFE consiste à implémenter l'intelligence artificielle dans les machines d'inspection des composants traversent sur les cartes mères de l'usine BOMARE. L'IA offre des opportunités passionnantes pour améliorer l'efficacité et la précision de ces machines. En intégrant des algorithmes d'apprentissage automatique et des capacités de traitement avancées, nous visons à créer un système capable de détecter et de classifier automatiquement les défauts dans les produits inspectés. Nous sommes convaincus que cette technologie révolutionnaire pourrait réduire les erreurs humaines, augmenter la productivité et garantir des normes de qualité élevées dans l'industrie de l'inspection. Nous sommes impatients de relever ce défi et de contribuer aux avancées de l'IA dans le domaine de l'inspection industrielle.

L'implémentation de l'intelligence artificielle dans les machines d'inspection implique la mise en œuvre de plusieurs étapes essentielles. Tout d'abord, il est nécessaire de collecter un ensemble de données d'inspection, comprenant à la fois des exemples de produits exempts de défauts et des produits présentant divers types de défauts. Ensuite, ces données sont prétraitées pour les rendre

compatibles avec l'algorithme d'apprentissage automatique choisi. Une fois cela fait, le modèle d'apprentissage automatique est entraîné en utilisant ces données, afin de lui permettre d'identifier les caractéristiques et les motifs associés à chaque type de défaut. Après l'entraînement, le modèle est testé et validé avec de nouvelles données pour évaluer sa performance. Enfin, une fois que le modèle est prêt, il est intégré dans la machine d'inspection, lui permettant d'analyser et de détecter automatiquement les défauts lors de l'inspection des produits. Cette méthode d'application de l'IA dans les machines d'inspection permet d'automatiser le processus de détection des défauts, améliorant ainsi l'efficacité et la fiabilité de l'inspection industrielle.

On trouve dans notre mémoire chapitre I présentation de la société BOMAR fournie une présentation détaillée sur la, en mettant en évidence son domaine d'activité, ses produits et ses services. Chapitre II y a des recherches sur l'image l'importance de l'imagerie dans le processus d'inspection industrielle et des différents types d'images utilisées dans ce contexte et les techniques courantes de traitement d'image, introduire les concepts fondamentaux de l'intelligence artificielle et son application dans le domaine du traitement d'image, on explique comment l'IA peut améliorer la précision et l'efficacité du traitement d'image dans le contexte de l'inspection industrielle. On trouve sur chapitre III notre travail en détail les méthodes que nous avons utilisées pour intégrer l'IA dans le processus d'inspection, y compris les algorithmes d'apprentissage automatique spécifiques que nous avons choisis, comment nous avons préparé les données d'inspection, entraîné le modèle d'IA et l'avez intégré dans la machine d'inspection, en évidence les défis techniques auxquels nous avons été confrontés et les solutions que nous avons proposées.

# **Chapitre I**

## **Présentation de la Société**

## I.1. Introduction

Dans ce chapitre, nous allons présenter l'entreprise BOMARE Company, une société dynamique et innovante qui opère dans le secteur de la technologie et de l'électronique. Fondée en 2001, BOMARE Company a connu une croissance exponentielle au fil des années, devenant l'un des acteurs majeurs de l'industrie en Algérie et sur les marchés internationaux.

## I.2. Présentation de l'Entreprise BOMARE Company

### I.2.1. Introduction

BOMARE Company est une entreprise algérienne spécialisée dans l'industrie électronique. Elle a été créée en 2001 par son fondateur et actuel directeur général, M. Ali Boumediene, avec un capital de 1.023.000.000 DZD, la société est connue pour sa marque commerciale "Stream System" qui a été déposée en 2003. Bomare Company a pour mission de développer le secteur de l'industrie électronique en Algérie, de renforcer sa position en Europe et de l'étendre. Elle est le premier exportateur de produits électroniques en Europe et en Afrique, la société fabrique une large gamme de produits électroniques, notamment des téléviseurs, des écrans interactifs, des caméras, des tableaux blancs interactifs et des murs vidéo[4].



**Figure Error! No text of specified style in document..1. BOMARE COMPANY LOGO**

BOMARE COMPANY peut être résumée dans les chiffres qui suivent :

- **Chiffre d'affaires** : 42 Millions de Dollars réalisé en 2020
- **COLLABORATEURS** : 620
- **SITE DE PRODUCTION** : 1
- **SUPERFICIE DU SITE DE PRODUCTION** : 15.000 m<sup>2</sup>
- **STORES** : 10
- **UNITÉS DE DISTRIBUTION** : Plates-formes de distribution propres à Bomare Company au (Centre, Est, Ouest et Sud de l'Algérie)

- SERVICES APRÈS-VENTE : 21
- PRÉSENCE À L'INTERNATIONAL : Espagne/Portugal/Italie/ Afrique du Sud/ Gabon/Allemagne en cours de négociation
- SERVICES APRÈS-VENTE À L'INTERNATIONAL : (5 ans de garantie) Espagne/Portugal/Italie/ Afrique du Sud/ Gabon / Allemagne en cours de négociation

### I.2.2. BOMARE structure

La société Bomare possède quatre unités de production s'étendant sur 15 000 m<sup>2</sup>, situées à Birtouta, dans la province d'Alger, et emploie six cents personnes, dont 40 % sont des cadres supérieurs et des ingénieurs. L'entreprise est certifiée ISO 9001 depuis 2011 et CE depuis 2010.

#### a. U1 unité insertion des composants SMT

Le département U1 est le département de production et test des cartes mères. Pour ce faire il y'a deux lignes de production, qui utilisent la technologie *SMT (Surface Mounted Technology)* la différence entre les deux étant l'âge des machines et leur rendement. La première ligne est constituée de machines plus anciennes (Débuté en 2012) et de machine 60 nozzels et la deuxième ligne une machine de 120 nozzels, mais les deux ont le même procédé de fonctionnement.



Figure Error! No text of specified style in document..2. Unité 1 salle SMT

**b. U2 unité d'assemblage**

Cette unité se compose de trois lignes dont seulement deux qui sont encore opérationnelles, cette dernière s'occupe de l'assemblage des composants de téléviseurs en partant d'un produit complètement désassemblé (dalles, cartes mères, connecteurs, caches etc. ...), vers un produit fini et prêt à la vente. Des opérateurs s'occupent de l'assemblage selon un cahier de charges mis en place par le département DPI (Développement de Projets Industriels), les tâches étant équitablement divisées entre les opérateurs selon la durée et l'effort de chacune.

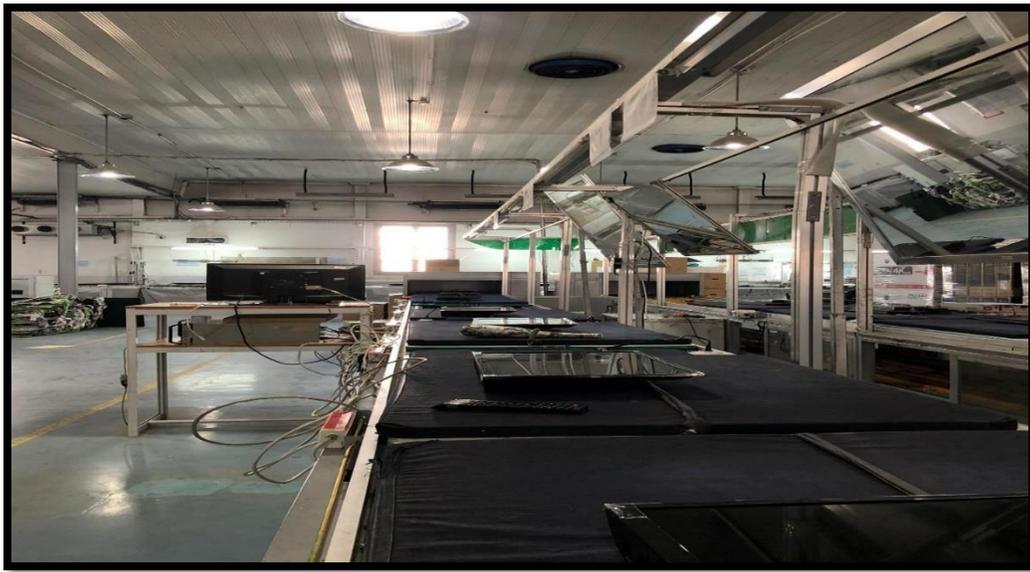


Figure Error! No text of specified style in document..3. Unité 2 d'assemblage.

**c. Les unités de support****• Département de développement de projets industriels****➤ Sous-traitance**

Dans le cadre de leurs activités, ils se chargent non seulement de la production des produits de BOMARE COMPANYY, mais également de trouver de nouveaux clients pour l'entreprise. Leur rôle consiste à identifier des entreprises qui ont besoin de PCBA (cartes de circuits imprimés) ou qui nécessitent la réparation de certaines machines. De plus, ils possèdent l'expertise nécessaire pour effectuer du reverse engineering sur des articles spécifiques, tels que des cartes PCBA. Cette compétence leur permet d'analyser et de comprendre la structure et le fonctionnement de ces produits afin de les reproduire ou de les améliorer. Ainsi, en plus de la production, ils jouent un rôle clé dans le développement de nouveaux marchés et dans la

satisfaction des besoins spécifiques des clients en dehors de la gamme de produits standard de BOMARE COMPANY.

➤ **Intégration locale**

Dans le cadre de leurs efforts pour optimiser les opérations de BOMARE COMPANY, ils s'engagent également à trouver des entreprises locales ou des startups spécialisées dans la production de matières premières. Cette démarche vise à réduire les coûts liés à l'importation, qui peuvent souvent être très élevés. En établissant des partenariats avec des fournisseurs locaux, BOMARE COMPANY peut non seulement économiser sur les frais de transport et de douane, mais aussi contribuer au développement de la production locale. La recherche de fournisseurs locaux présente plusieurs avantages. Tout d'abord, cela réduit la dépendance de l'entreprise vis-à-vis des importations, ce qui peut être bénéfique en cas de fluctuations des taux de change ou de perturbations dans les chaînes d'approvisionnement mondiales. De plus, cela favorise le développement économique de la région en soutenant les entreprises locales et en créant de nouvelles opportunités d'emploi. En identifiant des startups prometteuses, ils peuvent également encourager l'innovation et la croissance de l'écosystème local. En collaborant avec ces entreprises émergentes, BOMARE COMPANY peut bénéficier de nouvelles idées, de technologies avancées et de partenariats stratégiques qui stimulent l'efficacité et la compétitivité de ses propres activités. En résumé, leur rôle ne se limite pas à la production de produits de BOMARE COMPANY, mais englobe également la recherche active de fournisseurs locaux, la promotion du développement de la production locale et la participation à l'écosystème économique régional. Cette approche globale permet à BOMARE COMPANY de renforcer sa position sur le marché, d'optimiser ses coûts et de contribuer de manière significative au développement économique durable de la région.

➤ **ESD (Electrostatic Discharge)**

Les ingénieurs de BOMARE COMPANY jouent un rôle crucial dans la garantie du respect des normes en matière de décharges électrostatiques (ESD). Les décharges électrostatiques sont des événements électriques soudains qui peuvent se produire lorsqu'il y a une différence de charge entre deux objets. Elles peuvent se produire de manière imperceptible et peuvent être extrêmement nocives pour les composants électriques sensibles, car elles peuvent entraîner des dommages permanents et réduire considérablement leur durée de vie. Afin de

minimiser les risques liés aux décharges électrostatiques, les ingénieurs de BOMARE COMPANY mettent en place des mesures préventives rigoureuses. Ils s'assurent que toutes les installations de production et les zones de travail sont conçues et aménagées conformément aux normes ESD internationales. Cela comprend l'utilisation de revêtements de sol et de tapis spéciaux, le port de vêtements et d'équipements de protection adaptés, tels que des bracelets antistatiques et des chaussures spéciales, ainsi que la mise en place de systèmes de mise à la terre appropriés. De plus, les ingénieurs veillent à ce que tous les employés de BOMARE COMPANY soient régulièrement formés sur les bonnes pratiques en matière de prévention des décharges électrostatiques. Cela inclut des formations sur la manipulation sûre des composants électroniques, l'utilisation correcte des outils et des équipements de protection, ainsi que la sensibilisation aux facteurs environnementaux qui peuvent contribuer aux décharges électrostatiques, tels que l'humidité et la température. En adoptant une approche proactive en matière de gestion des décharges électrostatiques, les ingénieurs de BOMARE COMPANY garantissent la qualité et la fiabilité des produits électroniques fabriqués. Ils contribuent ainsi à prolonger la durée de vie des composants électriques, à réduire les défaillances prématurées et à renforcer la satisfaction des clients. En mettant en œuvre des normes strictes en matière de prévention des décharges électrostatiques, BOMARE COMPANY démontre son engagement envers la qualité et la performance de ses produits, tout en assurant la sécurité et la durabilité des composants électroniques.

➤ **Coopération scientifique**

Responsable de la coopération avec les universités telle que la nôtre et de la co-organisation de certains événements comme IBTIKAR UP ou d'autres compétitions STARTUP avec d'autres universités ce qui permettra de faciliter l'intégration des étudiants fraîchement diplômés au monde de travail.

• **Département de contrôle de qualité**

Ce département faisant partie de l'unité d'assemblage, s'assure de la qualité des matières premières ainsi que la bonne application de tous les procédés d'assemblage afin que la qualité du produit finit soit irréprochable, il se compose de trois parties.

**a. IQC (Input Quality Control)**

Avant l'acquisition et l'achat de la matière première, des échantillons sont envoyés par les fournisseurs de cette dernière afin d'être testé par des ingénieurs de contrôle de qualité.

**b. LQC (Line Quality Control)**

Durant l'assemblage, des opérateurs procèdent à faire des tests pour assurer que la tâche d'assemblage sur le long de la ligne s'est bien déroulé, en vérifiant comme exemple si la dalle a été placée correctement ou si les hauts parleurs sont bien connectés.

**c. OQC (Output Quality Control)**

Après l'assemblage, quelques unités du produit fini sont choisies aléatoirement du lot pour être testées selon les normes imposés partant de l'emballage les accessoires, jusqu'au téléviseur en vérifiant l'affichage, le son etc., En cas de défaut un intervalle de produits sera signalé et révisé avant d'être remise.

**• Département service de développement et multimédia**

Ce département s'occupe de faire des études sur les cartes mères avant la production pour les optimiser et les améliorer, s'occupe aussi de la mise en place des cahiers de charges pour pouvoir optimiser les lignes d'assemblage.

**• Département de maintenance industrielle**

Ce département s'occupe de la maintenance de toute la machinerie de l'usine afin de remédier aux pannes qui peuvent être très coûteuses, il s'assure de la bonne alimentation et aussi le bon fonctionnement de toutes les machines de la chaîne de SMT ainsi que la ligne d'assemblage.

**I.2.3. La vision de Bomare Company**

Dans une interview accordée à un magazine, le fondateur et directeur général de Bomare Company, M. Ali Boumediene, a exposé sa vision de l'avenir de la filière électronique en Algérie. Il estime que l'Algérie est capable de créer une véritable industrie dans le domaine électronique, surtout que le savoir-faire existe déjà dans le pays. La mission de Bomare Company est de développer le secteur de l'industrie électronique en Algérie, de renforcer sa position en Europe et de l'étendre à d'autres pays européens et africains. La société a été primée

comme "modèle de succès sur le marché" en 2019. M. Boumediene a également évoqué les principales contraintes qui freinent le développement de son entreprise et suggère une démarche pertinente pour améliorer de façon substantielle l'intégration des produits électroniques fabriqués localement. En somme, la vision de Bomare Company pour l'avenir de l'industrie électronique en Algérie est de développer le secteur, renforcer sa position en Europe et l'étendre à d'autres pays européens et africains. M. Ali Boumediene estime que l'Algérie est capable de créer une véritable industrie dans le domaine électronique[5].

### **I.3. Contexte et Importance du Sujet**

Dans un monde où l'électronique joue un rôle de plus en plus prédominant, le contrôle de la qualité des composants électroniques est devenu une priorité. Parmi ces composants, les cartes de circuits imprimés (PCBA) sont l'épine dorsale de la plupart des appareils électroniques modernes. Cependant, leur processus de fabrication est complexe et susceptible de générer des défauts. Par conséquent, l'inspection des PCBA est une étape essentielle pour garantir leur fiabilité et leur performance.

Cependant, les méthodes d'inspection traditionnelles, comme l'inspection manuelle, sont souvent sujettes à des erreurs et sont peu efficaces. L'application de l'intelligence artificielle (IA) dans le processus d'inspection pourrait permettre d'améliorer considérablement la précision et l'efficacité de l'inspection des PCBA.

### **I.4. Problématique**

La question fondamentale qui se pose est la suivante : Comment pouvons-nous utiliser l'IA pour améliorer l'inspection des PCBA sortant du bain de soudure afin de les classer comme conformes ou non conformes ?

### **I.5. Objectifs de l'Étude**

L'objectif principal de cette étude est de concevoir et mettre en œuvre un système basé sur l'IA pour l'inspection des PCBA chez Bomare Company. Les objectifs spécifiques comprennent :

1. Développer un modèle d'IA capable de détecter et classer les défauts sur les PCBA.
2. Intégrer ce modèle à une machine d'inspection assistée par caméra.
3. Évaluer les performances du système par rapport aux méthodes d'inspection traditionnelles.

## **I.6. Importance de l'Étude**

Cette étude a plusieurs implications importantes. Premièrement, elle pourrait contribuer à améliorer la qualité des PCBA produits par Bomare Company, ce qui aurait un impact direct sur la qualité de ses produits finis. Deuxièmement, en augmentant l'efficacité du processus d'inspection, elle pourrait aider l'entreprise à réduire ses coûts et à augmenter sa productivité. Enfin, cette étude pourrait également fournir des connaissances précieuses pour d'autres entreprises du secteur de l'électronique intéressées par l'utilisation de l'IA pour l'inspection des PCBA.

## **I.7. Conclusion**

En conclusion, le premier chapitre a mis en évidence l'importance de la détection des défauts dans les PCBA dans le contexte industriel actuel. L'introduction de l'IA, et plus particulièrement des techniques d'apprentissage profond, a ouvert de nouvelles perspectives pour l'amélioration des systèmes de contrôle de qualité.

Cela a créé une opportunité pour l'industrie d'améliorer l'efficacité de la production et la qualité des produits, tout en minimisant les erreurs humaines et les inefficacités de production.

Dans les chapitres suivants, nous allons passer en revue la littérature existante, proposer notre propre approche de la détection des défauts en utilisant l'apprentissage profond, et finalement, évaluer et discuter de la performance de notre modèle dans un environnement de production réel. Nous allons explorer les détails techniques de notre solution, et comment elle peut être intégrée dans les processus de production existants pour améliorer la détection des défauts et la qualité globale du produit.

## **Chapitre II**

# **L'intelligence artificielle**

## II.1. Introduction

Ce chapitre de mémoire se concentre sur l'intelligence artificielle (IA) et plus particulièrement sur l'apprentissage profond, un sous-domaine clé de l'IA. L'introduction présente les principaux points abordés dans ce chapitre. Tout d'abord, elle met en évidence la définition de l'IA, son évolution historique et ses applications variées. Ensuite, elle souligne les principes fondamentaux de l'IA, en se concentrant sur les différentes méthodes d'apprentissage telles que l'apprentissage supervisé, non supervisé et par renforcement. L'apprentissage profond est ensuite introduit, avec une explication de ses définitions, de ses principes fondamentaux (propagation avant et rétropropagation) et des défis auxquels il est confronté (surapprentissage et sous-apprentissage). Les techniques d'optimisation de l'apprentissage profond sont également abordées, notamment la normalisation par lots, le Dropout et les fonctions d'activation. Les paramètres d'optimisation, tels que les optimiseurs et le taux d'apprentissage, sont ensuite discutés. L'importance de l'éthique dans l'IA est soulignée, avec une exploration des problématiques éthiques spécifiques et des solutions recommandées. Enfin, les tendances futures de l'IA sont examinées, mettant en évidence les liens avec le Big Data, l'Internet des objets et la robotique. L'objectif de ce chapitre est de fournir une compréhension approfondie de l'IA et de l'apprentissage profond, ainsi que des implications éthiques et des perspectives futures de ce domaine en constante évolution.

## II.2. Généralités sur l'intelligence artificielle

### II.2.1. Définition de l'IA

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à créer des systèmes capables de réaliser des tâches qui nécessitent normalement l'intelligence humaine. Cela inclut des activités telles que la résolution de problèmes, la reconnaissance de formes, l'apprentissage et l'adaptation, la perception sensorielle, l'interaction sociale et la manipulation physique du monde[6].

Il existe deux catégories principales d'IA :

#### a. L'IA faible (ou spécifique)

Il s'agit de systèmes d'IA conçus pour accomplir une tâche spécifique, comme la recommandation de produits sur un site de commerce électronique, ou la reconnaissance de la

parole par un assistant vocal. Les systèmes d'IA faibles ne possèdent pas de compréhension ou de conscience de soi[7].

**b. L'IA forte (ou générale) :**

Ce type d'IA, qui n'existe pas encore, représenterait des systèmes qui possèdent une forme de conscience de soi et la capacité d'aborder n'importe quelle tâche intellectuelle qu'un humain pourrait accomplir[8].

## **II.2.2. Historique et évolution de l'IA**

L'histoire de l'intelligence artificielle (IA) a commencé avec des mythes, des histoires et des rumeurs de créatures artificielles dotées d'intelligence ou de conscience. Le concept d'IA en tant que discipline académique a été fondé lors de la conférence de Dartmouth en 1956, où le terme "intelligence artificielle" a été utilisé pour la première fois [9].

Dans les années 1950 et 1960, l'IA a connu un certain optimisme, avec de nombreuses prédictions selon lesquelles les machines pourraient bientôt imiter l'intelligence humaine. Toutefois, ces attentes élevées n'ont pas été satisfaites, ce qui a conduit à une période connue sous le nom de "l'hiver de l'IA" dans les années 1970 et 1980, où le financement et l'intérêt pour l'IA ont diminué[6].

L'IA a connu une résurgence dans les années 1990, grâce à une combinaison d'améliorations dans la puissance de calcul, l'apparition de nouvelles méthodes basées sur des statistiques (notamment l'apprentissage automatique), et des succès tels que le programme d'échecs Deep Blue d'IBM qui a battu le champion du monde Garry Kasparov en 1997.

Depuis le début des années 2010, l'IA a connu une croissance exponentielle grâce aux progrès de l'apprentissage profond, une technique d'apprentissage automatique qui utilise des réseaux de neurones à plusieurs couches. Des entreprises comme Google, Facebook et Microsoft ont investi massivement dans la recherche et le développement de l'IA, et les applications de l'IA sont devenues omniprésentes dans notre vie quotidienne[10].

### II.2.3. Applications de l'IA

L'intelligence artificielle (IA) a une multitude d'applications dans divers domaines :

- **Reconnaissance vocale**

L'IA est largement utilisée dans les technologies de reconnaissance vocale. Les assistants vocaux, tels que Siri d'Apple, Alexa d'Amazon et Google Assistant, utilisent l'IA pour comprendre et répondre aux commandes vocales des utilisateurs[11].

- **Véhicules autonomes**

Les voitures sans conducteur, comme celles développées par Waymo (une filiale d'Alphabet, la société mère de Google), utilisent l'IA pour percevoir leur environnement et prendre des décisions de conduite[12].

- **Recommandations personnalisées**

Les systèmes de recommandation, comme ceux utilisés par Amazon et Netflix, utilisent l'IA pour analyser les habitudes et les préférences des utilisateurs afin de fournir des recommandations personnalisées[13].

- **Médecine**

L'IA a également trouvé des applications en médecine, par exemple dans l'analyse d'images médicales pour détecter les maladies, ou dans la personnalisation des plans de traitement en fonction des données spécifiques d'un patient[14].

- **Systemes de traduction automatique**

Les programmes de traduction, tels que Google Translate, utilisent l'IA pour traduire du texte d'une langue à une autre[15].

## II.3. Les principes de base de l'IA

### II.3.1. L'apprentissage supervisé

L'apprentissage supervisé est une méthode d'apprentissage automatique où un modèle est formé sur un ensemble de données d'entraînement composé d'entrées et de sorties correspondantes. L'idée est de créer un modèle qui, après un entraînement suffisant, est capable

de prédire la sortie d'une nouvelle entrée en se basant sur les relations apprises lors de l'entraînement.

Il existe deux types principaux de tâches d'apprentissage supervisé :

- **La classification**

Il s'agit d'une tâche qui consiste à prédire une catégorie ou une étiquette de classe pour une entrée donnée. Par exemple, un système de détection de spam est un problème de classification où le but est de classer les e-mails comme "spam" ou "non-spam"[16].

- **La régression**

Il s'agit d'une tâche qui consiste à prédire une valeur continue pour une entrée donnée. Par exemple, la prédiction du prix d'une maison en fonction de caractéristiques comme la taille et l'emplacement est un problème de régression[17].

L'apprentissage supervisé repose sur des algorithmes tels que la régression linéaire, la régression logistique, les arbres de décision, les forêts aléatoires, les machines à vecteurs de support (SVM) et les réseaux neuronaux[18].

### **II.3.2. L'apprentissage non supervisé**

L'apprentissage non supervisé est une méthode d'apprentissage automatique où le modèle apprend à identifier des structures dans l'ensemble de données sans avoir besoin d'étiquettes de sortie spécifiques pour l'entraînement. Les modèles d'apprentissage non supervisé cherchent à découvrir les relations intrinsèques et la structure sous-jacente des données.

Il existe deux types principaux de tâches d'apprentissage non supervisé :

- **Le clustering**

C'est une technique utilisée pour regrouper des éléments similaires dans un ensemble de données. Par exemple, le K-means est un algorithme de clustering populaire utilisé pour diviser un ensemble de données en groupes (ou "clusters") d'éléments similaires[19].

- **La réduction de dimensionnalité**

Cette technique est utilisée pour réduire le nombre de variables en entrée, ou "dimensions", dans un ensemble de données tout en préservant les informations importantes. Un exemple

célèbre est l'analyse en composantes principales (ACP), qui est souvent utilisée pour la visualisation de données à haute dimension[20].

Les techniques d'apprentissage non supervisé sont couramment utilisées pour l'analyse exploratoire des données, la détection d'anomalies, l'apprentissage de représentations et la préparation des données pour les techniques d'apprentissage supervisé[18].

### **II.3.3. L'apprentissage par renforcement**

L'apprentissage par renforcement est une branche de l'intelligence artificielle qui se concentre sur la façon dont un agent peut apprendre à accomplir une tâche en interagissant avec son environnement. Contrairement à l'apprentissage supervisé et non supervisé, l'apprentissage par renforcement n'est pas basé sur un ensemble de données d'entraînement préétabli. Au lieu de cela, un agent apprend par essai et erreur, recevant des récompenses ou des pénalités (renforcements) pour ses actions.

Un système d'apprentissage par renforcement est généralement composé de quatre éléments principaux :

**a. L'agent**

L'entité qui apprend à partir de ses expériences et effectue des actions dans l'environnement.

**b. L'environnement**

Le monde dans lequel l'agent effectue ses actions.

**c. Les actions**

Ce sont les différentes étapes que l'agent peut entreprendre.

**d. Les récompenses**

Ce sont les signaux de feedback que l'agent reçoit à la suite de ses actions. L'objectif de l'agent est d'apprendre à maximiser la somme des récompenses qu'il reçoit au fil du temps[21].

L'apprentissage par renforcement a été utilisé pour résoudre un large éventail de problèmes, allant de la gestion de ressources dans les réseaux informatiques à la maîtrise de jeux complexes comme le Go et les jeux vidéo. Un exemple célèbre est AlphaGo de DeepMind, qui a

---

été le premier programme informatique à battre un champion du monde humain au jeu de Go[22].

## II.4. L'apprentissage profond : un sous-domaine clé de l'IA

L'apprentissage profond, aussi connu sous le nom de réseaux de neurones profonds, est une sous-catégorie de l'apprentissage automatique qui se concentre sur les algorithmes inspirés par la structure et la fonction du cerveau, appelés réseaux de neurones artificiels.

Les réseaux de neurones profonds sont caractérisés par le nombre de couches cachées entre la couche d'entrée (où les données sont introduites dans le réseau) et la couche de sortie (où le réseau donne le résultat de son apprentissage). Ces couches cachées, ou "profondes", donnent à l'apprentissage profond sa capacité à apprendre à partir de données non structurées et non étiquetées, comme les images, le son et le texte[18].

L'apprentissage profond a plusieurs caractéristiques importantes :

### a. Extraction automatique de caractéristiques

Contrairement à la plupart des autres méthodes d'apprentissage automatique, l'apprentissage profond peut apprendre automatiquement les caractéristiques à partir des données, ce qui est souvent réalisé à travers de nombreuses couches de réseaux de neurones. Cela élimine la nécessité d'une extraction manuelle de caractéristiques, qui est souvent laborieuse et sujette aux erreurs[23].

### b. Apprentissage de représentations hiérarchiques

L'apprentissage profond est capable d'apprendre des représentations de données à plusieurs niveaux de hiérarchie, où chaque niveau représente les données à un niveau d'abstraction différent. Cela permet au modèle de capturer des structures complexes dans les données[24].

### c. Capacité à gérer de grandes quantités de données

Les réseaux de neurones profonds ont la capacité de traiter et d'apprendre à partir de grandes quantités de données, ce qui les rend particulièrement utiles pour travailler avec des ensembles de données de grande taille, comme les images et les vidéos[25].

### II.4.1. Réseaux de neurones convolutifs (CNN)

#### a. Introduction aux CNN

Les réseaux de neurones convolutifs (CNN) sont un type de réseau de neurones artificiels qui sont spécialement conçus pour traiter les données structurées en grille, comme une image, qui est essentiellement une grille de pixels[26]. Les CNN sont particulièrement efficaces pour analyser les images en raison de leur architecture unique qui imite la façon dont le cortex visuel humain traite l'information visuelle.

#### b. Architecture d'un CNN

L'architecture d'un CNN est composée de plusieurs couches, y compris des couches de convolution, de pooling et de pleinement connectées. Les couches de convolution appliquent un ensemble de filtres à l'image, permettant au réseau de "voir" différentes caractéristiques de l'image à différents niveaux de complexité. Les couches de pooling réduisent la dimensionnalité des caractéristiques, ce qui aide à rendre le réseau plus efficace et à prévenir le surapprentissage. Enfin, les couches pleinement connectées interprètent ces caractéristiques pour faire une prédiction ou prendre une décision[27].

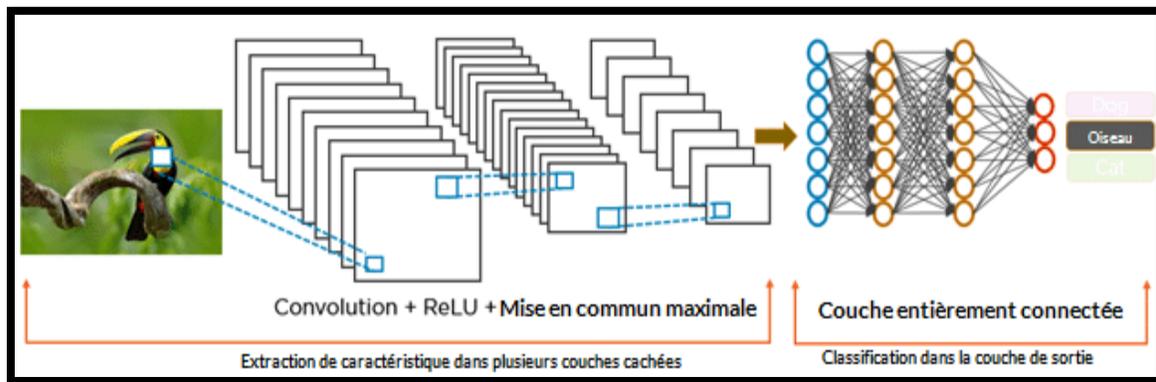


Figure Error! No text of specified style in document..4. Architecture d'un CNN

#### c. CNN dans l'inspection des PCBA

Dans le contexte de l'inspection des PCBA, un CNN peut être entraîné pour détecter différents types de défauts en analysant les images des PCBA. Par exemple, le CNN pourrait apprendre à reconnaître des caractéristiques visuelles spécifiques qui indiquent un joint de soudure défectueux, comme une forme ou une couleur anormale. Une fois entraîné, le CNN peut alors analyser de nouvelles images de PCBA et détecter ces défauts avec une grande précision[28].

---

## II.4.2. La Propagation Avant Le Principe Fondateur de l'Apprentissage Profond

### a. Introduction

La propagation avant, ou forward propagation, est une composante fondamentale des réseaux de neurones artificiels, spécifiquement dans le domaine de l'apprentissage profond [18]. C'est le processus par lequel l'information est transmise à travers le réseau de neurones, de l'entrée jusqu'à la sortie.

### b. Comprendre la Propagation Avant

Dans un réseau de neurones, la propagation avant commence par l'alimentation du réseau avec des entrées. Ces entrées sont traitées par chaque neurone de la couche d'entrée, qui applique un poids et un biais spécifique à l'entrée, puis passe le résultat à travers une fonction d'activation [29]. Le résultat est ensuite transmis à la couche suivante, et ainsi de suite jusqu'à la couche de sortie.

L'objectif de la propagation avant est de calculer une prédiction à partir des entrées. Cette prédiction est ensuite comparée à la véritable valeur dans le cadre de l'apprentissage supervisé, ce qui permet de calculer l'erreur ou la fonction de coût[30].

### c. Importance de la Propagation Avant

La propagation avant est essentielle pour le fonctionnement des réseaux de neurones. Elle permet la transmission de l'information à travers le réseau, de l'entrée jusqu'à la sortie. Pour une fonction d'activation donnée  $f$ , un poids  $w$ , une entrée  $x$  et un biais  $b$ , la sortie d'un neurone individuel lors de la propagation avant peut être calculée comme suit :

$$y = f(w * x + b)$$

Sans cette étape, il serait impossible pour le réseau de faire des prédictions à partir des entrées. De plus, la propagation avant joue un rôle crucial dans l'entraînement du réseau de neurones, puisque c'est lors de cette étape que la prédiction est générée, laquelle est ensuite utilisée pour ajuster les poids du réseau par rétropropagation[31].

**d. Applications de la Propagation Avant**

La propagation avant est utilisée dans toutes les applications qui impliquent des réseaux de neurones, y compris l'apprentissage profond, la reconnaissance d'images, la reconnaissance vocale, et le traitement du langage naturel. Par exemple, dans un réseau de neurones utilisé pour la classification d'images, la propagation avant pourrait être utilisée pour générer une prédiction pour une image donnée. Pour une image avec des pixels représentés par un vecteur d'entrée  $x$ , et un réseau avec des poids  $W$  et des biais  $b$ , la prédiction  $\hat{y}$  est donnée par :

$$\hat{y} = f(W * x + b)$$

Où  $f$  est la fonction d'activation[32].

**e. Conclusion**

La propagation avant est le pilier du fonctionnement des réseaux de neurones et de l'apprentissage profond. Elle permet non seulement le traitement des informations par le réseau, mais aussi l'apprentissage à partir de ces informations.

**II.4.3. La Rétropropagation une Méthode Clé dans l'Apprentissage Profond****a. Introduction**

La rétropropagation, aussi connue sous le nom de backpropagation, est une méthode largement utilisée dans le domaine de l'apprentissage automatique, spécifiquement pour l'apprentissage profond (Deep Learning) [18]. Cette technique permet d'ajuster les poids et les biais d'un réseau de neurones afin de minimiser l'erreur de prédiction. Dans cet article, nous allons explorer le fonctionnement de la rétropropagation, son importance et les applications actuelles dans divers domaines.

**b. Comprendre la Rétropropagation**

La rétropropagation est fondamentalement une procédure pour mettre à jour les poids d'un réseau de neurones en calculant le gradient de la fonction de coût [33]. Pour comprendre la rétropropagation, il faut d'abord comprendre le concept de gradient. Le gradient est une mesure de la manière dont la sortie d'une fonction change lorsqu'on modifie ses entrées. Dans le contexte

---

de l'apprentissage profond, la fonction est la fonction de coût, et les entrées sont les poids et les biais du réseau de neurones.

La rétropropagation est réalisée en deux étapes : la propagation avant et la propagation arrière. Pendant la propagation avant, les entrées sont transmises à travers le réseau pour produire une prédiction. L'erreur de cette prédiction est ensuite calculée. Pendant la propagation arrière, cette erreur est utilisée pour ajuster les poids et les biais dans le réseau[34].

### c. Importance de la Rétropropagation

L'importance de la rétropropagation réside dans son efficacité pour entraîner des réseaux de neurones profonds. Avant son introduction, l'ajustement des poids dans un réseau de neurones était un processus lent et inefficace. Cependant, la rétropropagation permet de calculer rapidement les gradients et d'effectuer les mises à jour nécessaires[31].

### d. Applications de la Rétropropagation

La rétropropagation est utilisée dans une grande variété de domaines, y compris la reconnaissance vocale, la vision par ordinateur, et le traitement automatique du langage naturel. Par exemple, dans la reconnaissance d'image, les réseaux de neurones entraînés par rétropropagation sont utilisés pour identifier et classer les objets dans une image[32].

### e. Rétropropagation mathématiquement

La rétropropagation utilise le concept du calcul du gradient pour ajuster les poids et les biais dans le réseau neuronal. C'est un exemple d'optimisation gradient, où le but est de minimiser une fonction de coût  $J(w, b)$  par rapport aux poids ( $w$ ) et aux biais ( $b$ ) du réseau.

#### • Calcul de l'erreur

Lors de la première étape de la rétropropagation, l'erreur de prédiction du réseau est calculée. L'erreur est la différence entre la sortie prédite du réseau ( $\hat{y}$ ) et la sortie réelle ( $y$ ). Pour une fonction de coût d'erreur quadratique moyenne (MSE), l'erreur  $E$  peut être calculée comme suit :

$$E = 1/2 * (\hat{y} - y)^2$$

- **Rétropropagation de l'erreur**

Dans cette étape, le gradient de l'erreur est calculé pour chaque neurone, à partir de la couche de sortie et en remontant jusqu'à la couche d'entrée. Le gradient de l'erreur par rapport au poids  $w_{ij}$  (où  $i$  est le neurone en amont et  $j$  est le neurone en aval) est calculé en utilisant la règle de la chaîne du calcul différentiel :

$$\partial E / \partial w_{ij} = \partial E / \partial y_j * \partial y_j / \partial net_j * \partial net_j / \partial w_{ij}$$

Où  $y_j$  est la sortie du neurone  $j$ , et  $net_j$  est la sortie du neurone  $j$  avant l'application de la fonction d'activation.

- **Mise à jour des poids et des biais**

Enfin, une fois que les gradients sont calculés, les poids et les biais sont mis à jour. Pour un taux d'apprentissage  $\eta$ , la mise à jour du poids est effectuée comme suit :

$$w_{ij}(\text{nouveau}) = w_{ij}(\text{ancien}) - \eta * \partial E / \partial w_{ij}$$

**f. Conclusion**

La rétropropagation est un outil indispensable dans le domaine de l'apprentissage automatique. Sa capacité à effectuer rapidement et efficacement l'apprentissage sur des réseaux de neurones profonds a rendu possible le développement de nombreuses applications en intelligence artificielle.

## II.5. Les défis de l'apprentissage profonde

### II.5.1. Le Surapprentissage (Overfitting)

**a. Introduction**

Le surapprentissage, ou overfitting, est un problème commun en apprentissage automatique et en apprentissage profond. Il se produit lorsqu'un modèle apprend trop bien les données d'entraînement, à tel point qu'il devient moins performant sur les nouvelles données ou les données de test. Cet article explore la nature du surapprentissage, ses causes, ainsi que les algorithmes et techniques pour y faire face[18].

**b. Comprendre le Surapprentissage**

Le surapprentissage se produit lorsque le modèle s'ajuste trop précisément aux données d'entraînement, capturant même leur bruit inhérent. En conséquence, le modèle performe bien sur les données d'entraînement, mais mal sur les données de test ou de validation, ce qui se traduit par une mauvaise généralisation[35].

Pour comprendre visuellement le surapprentissage, on peut regarder les courbes d'erreur d'entraînement et de validation. Si le modèle surapprend, la courbe d'erreur d'entraînement continuera de descendre avec le temps, tandis que l'erreur de validation commencera à augmenter, illustrant un écart entre les deux[29].

**c. Causes du Surapprentissage**

Plusieurs facteurs peuvent contribuer au surapprentissage. Il se produit le plus souvent lorsque le modèle est trop complexe par rapport à la quantité et à la variété des données d'entraînement. D'autres causes possibles comprennent la présence de bruit ou d'outliers dans les données d'entraînement, ainsi que le manque de régularisation dans le processus d'apprentissage[36].

**d. Contrer le Surapprentissage : Algorithmes et Techniques**

Plusieurs techniques peuvent aider à prévenir ou à atténuer le surapprentissage :

**• La régularisation**

C'est une technique qui ajoute un terme de pénalité à la fonction de coût, limitant ainsi la complexité du modèle. Les méthodes courantes de régularisation incluent la norme L1 (Lasso) et la norme L2 (Ridge)[37].

**• Le Dropout**

Dans les réseaux de neurones, le dropout est une technique populaire pour prévenir le surapprentissage. Elle consiste à désactiver aléatoirement certains neurones pendant l'entraînement, ce qui rend le modèle moins sensible au bruit des données d'entraînement[38].

**• Early Stopping**

Cette technique consiste à arrêter l'entraînement du modèle lorsque la performance sur le jeu de validation commence à se dégrader, plutôt que d'attendre la fin de l'entraînement[18].

- **La validation croisée**

Cette méthode divise les données d'entraînement en plusieurs sous-ensembles et effectue l'entraînement sur certains d'entre eux tout en validant le modèle sur les autres. Cela permet d'avoir une meilleure estimation de la performance du modèle sur de nouvelles données[35].

- e. **Conclusion**

Le surapprentissage est un problème courant en apprentissage automatique. Toutefois, plusieurs techniques, y compris la régularisation, le dropout, l'arrêt précoce et la validation croisée, peuvent aider à prévenir ce problème et à améliorer la capacité de généralisation du modèle.

## II.5.2. Le Sous-apprentissage (Underfitting)

- a. **Introduction**

Le sous-apprentissage, ou underfitting, est un problème qui se produit lorsque le modèle d'apprentissage automatique ne parvient pas à capter les tendances sous-jacentes dans les données d'entraînement. Par conséquent, le modèle performe mal à la fois sur les données d'entraînement et de test. Cet article explore le sous-apprentissage, ses causes et les algorithmes pour y remédier[18].

- b. **Comprendre le Sous-apprentissage**

Le sous-apprentissage se produit généralement lorsque le modèle est trop simple pour saisir la complexité des données. Par exemple, tenter de modéliser une relation non linéaire complexe avec une simple régression linéaire peut entraîner un sous-apprentissage[35].

Un modèle qui souffre de sous-apprentissage aura des erreurs d'entraînement et de validation élevées. En d'autres termes, le modèle ne sera pas en mesure de faire des prédictions précises, même sur les données d'entraînement qu'il a déjà vues[51].

- c. **Causes du Sous-apprentissage**

Le sous-apprentissage peut se produire pour plusieurs raisons, parmi lesquelles :

1. Un modèle trop simple : Si le modèle n'est pas assez complexe, il ne peut pas saisir les relations sous-jacentes dans les données.

2. Un manque de données : Si les données d'entraînement sont insuffisantes, le modèle ne peut pas apprendre efficacement.
3. Mauvaise qualité des données : Si les données contiennent trop d'erreurs, de bruit ou d'incohérences, le modèle peut avoir du mal à apprendre[40].

#### d. Contrer le Sous-apprentissage (Algorithmes et Techniques)

Pour remédier au sous-apprentissage, on peut utiliser les techniques suivantes :

- **Augmenter la complexité du modèle**

En utilisant un modèle plus complexe, on peut souvent améliorer les performances d'apprentissage. Par exemple, si une régression linéaire simple conduit à un sous-apprentissage, on pourrait essayer un modèle polynomial ou un réseau de neurones[35].

- **Obtenir plus de données**

Si possible, obtenir plus de données peut aider le modèle à apprendre. Cela pourrait signifier collecter plus de données, ou utiliser des techniques de data augmentation pour synthétiser de nouvelles données[41].

- **Améliorer la qualité des données**

Il est également utile d'explorer et de nettoyer les données. Cela peut inclure la gestion des valeurs manquantes, la correction des erreurs et la suppression des outliers[40].

#### e. Conclusion

Le sous-apprentissage est un défi en apprentissage automatique, mais il peut souvent être résolu en ajustant la complexité du modèle, en obtenant plus de données ou en améliorant la qualité des données.

## II.6. Techniques d'optimisation de l'apprentissage profond

### II.6.1. La Normalisation par Lots (Batch Normalization)

#### a. Introduction

La normalisation par lots, ou batch normalization, est une technique d'optimisation largement utilisée dans les réseaux de neurones profonds. Elle a été introduite par Ioffe et Szegedy en 2015 pour améliorer la vitesse de l'apprentissage, la stabilité du réseau et réduire les

---

problèmes liés à l'initialisation des poids. Cet article explique le concept de la normalisation par lots et présente son algorithme[42].

### **b. Comprendre la Normalisation par Lots**

La normalisation par lots consiste à normaliser les entrées d'une couche de réseau de neurones pour chaque mini-lot, c'est-à-dire à rendre la moyenne des activations proche de 0 et leur écart-type proche de 1. Cette normalisation est effectuée pour chaque dimension (neurone) indépendamment. En normalisant les activations à travers les mini-lots, le réseau devient plus robuste aux changements dans la distribution des entrées, un phénomène connu sous le nom de "covariate shift"[18].

### **c. Algorithme de la Normalisation par Lots**

L'algorithme de la normalisation par lots se déroule comme suit :

1. Pour chaque neurone, calculez la moyenne  $\mu$  et la variance  $\sigma^2$  de ses activations sur le mini-lot.
2. Normalisez les activations  $x$  du neurone en utilisant la moyenne et la variance calculées :

$$x_{hat} = (x - \mu) / \text{sqrt}(\sigma^2 + \epsilon)$$

Où  $\epsilon$  est une petite constante ajoutée pour la stabilité numérique (pour éviter de diviser par zéro).

3. Appliquez une transformation linéaire sur les activations normalisées :

$$y = \gamma * x_{hat} + \beta$$

Où  $\gamma$  est la "vitesse d'apprentissage" et  $\beta$  est le "biais". Ces deux paramètres sont appris pendant l'entraînement[42].

### **d. Conclusion**

La normalisation par lots est une technique essentielle dans l'apprentissage profond, qui accélère l'entraînement, rend les réseaux plus robustes aux changements de distribution des entrées et atténue le surapprentissage.

## II.6.2. Le Dropout en Apprentissage Profond

### a. Introduction

Le dropout est une technique d'optimisation populaire en apprentissage profond, introduite par Srivastava et al. En 2014. Il vise à réduire le surapprentissage en forçant le modèle à apprendre des représentations plus robustes. Cet article explore le concept de dropout et décrit son algorithme[38].

### b. Comprendre le Dropout

Le dropout est une forme de régularisation qui agit en désactivant aléatoirement certains neurones dans un réseau de neurones pendant l'entraînement. En d'autres termes, pendant chaque itération d'entraînement, chaque neurone a une probabilité  $p$  d'être "éteint", ce qui signifie que sa contribution à la propagation avant et à la rétropropagation est temporairement supprimée.

Le dropout a pour effet de créer un "réseau d'ensembles", où chaque itération d'entraînement utilise un réseau légèrement différent. Cela conduit à un apprentissage plus robuste et prévient le surapprentissage en empêchant la co-adaptation de neurones[33].

### c. Algorithme du Dropout

L'algorithme de dropout est relativement simple et se déroule comme suit [38] :

1. Pour chaque neurone, définissez une probabilité  $p$  (généralement entre 0.2 et 0.5) que ce neurone soit "éteint" pour l'itération d'entraînement actuelle.
2. Pour chaque itération d'entraînement, générez un nombre aléatoire pour chaque neurone. Si ce nombre est inférieur à  $p$ , éteignez le neurone (c'est-à-dire, mettez sa sortie à 0).
3. Pour chaque itération de propagation avant, n'incluez que les neurones qui ne sont pas "éteints". Cela signifie que ces neurones n'auront pas d'impact sur la sortie du réseau pour cette itération.
4. Pendant la rétropropagation, n'ajustez que les poids des neurones qui n'étaient pas "éteints".

**d. Conclusion**

Le dropout est une technique efficace pour prévenir le surapprentissage en apprentissage profond. Il offre un moyen simple mais puissant de créer un apprentissage plus robuste en générant un "ensemble" de réseaux légèrement différents pendant l'entraînement.

**II.6.3. Les Fonctions d'Activation en Apprentissage Profond****a. Introduction**

Les fonctions d'activation jouent un rôle crucial dans les réseaux de neurones artificiels. Elles déterminent le niveau de sortie d'un neurone en fonction de ses entrées. Plusieurs fonctions d'activation sont largement utilisées en apprentissage profond, chacune avec ses propres caractéristiques et utilisations. Cet article présente une vue d'ensemble des fonctions d'activation et explique comment elles sont utilisées[18].

**b. Comprendre les Fonctions d'Activation**

Une fonction d'activation prend en entrée la somme pondérée des entrées d'un neurone (plus un biais) et produit une sortie qui est transmise au prochain neurone. La forme de la fonction d'activation détermine le type de relation que le neurone peut modéliser entre ses entrées et sa sortie[35].

Les fonctions d'activation peuvent être linéaires ou non linéaires. Les fonctions d'activation linéaires préservent les propriétés linéaires du réseau, tandis que les fonctions non linéaires permettent au réseau de modéliser des relations plus complexes et d'apprendre à partir de données plus diversifiées.

### c. Fonctions d'Activation Communes et leur Utilisation

- **Fonction d'activation linéaire (ou Identité) :**

$$y = x.$$

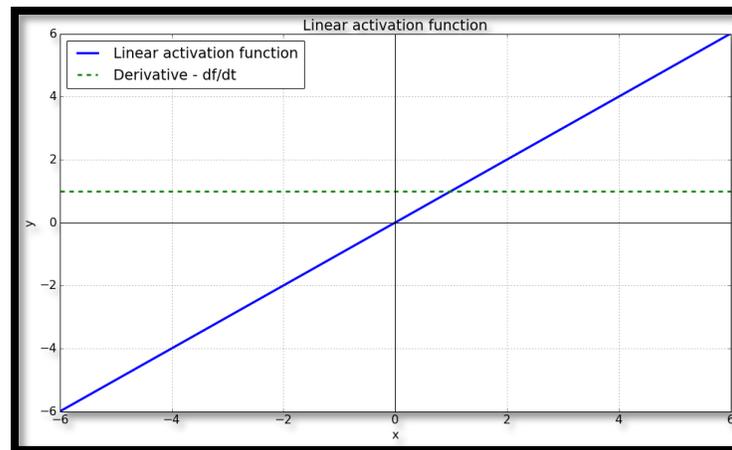


Figure Error! No text of specified style in document..5. **Linear activation function**

Elle est utilisée lorsque le réseau doit produire une sortie non bornée.

- **Fonction sigmoïde :**

$$y = 1 / (1 + \exp(-x)).$$

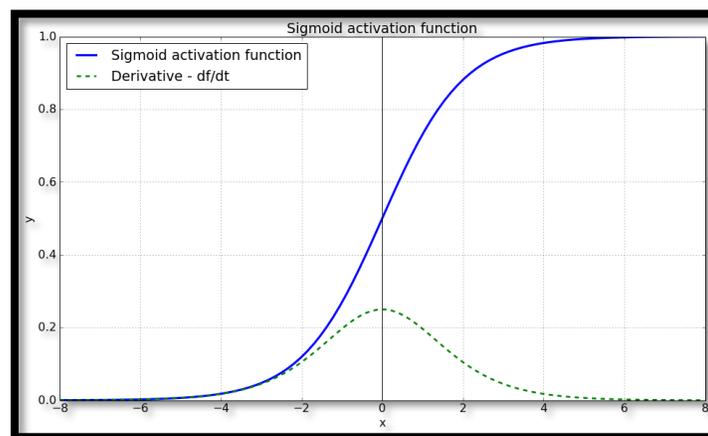


Figure Error! No text of specified style in document..6. **Fonction sigmoïde**

Elle a une forme de "S", et est souvent utilisée dans les problèmes de classification binaire ou pour produire des probabilités. Cependant, elle peut souffrir du problème de disparition de gradient, où les gradients deviennent très petits lorsque  $x$  est très grand ou très petit[43].

- **Fonction tan :**

$$y = (\exp(x) - \exp(-x)) / (\exp(x) + \exp(-x)).$$

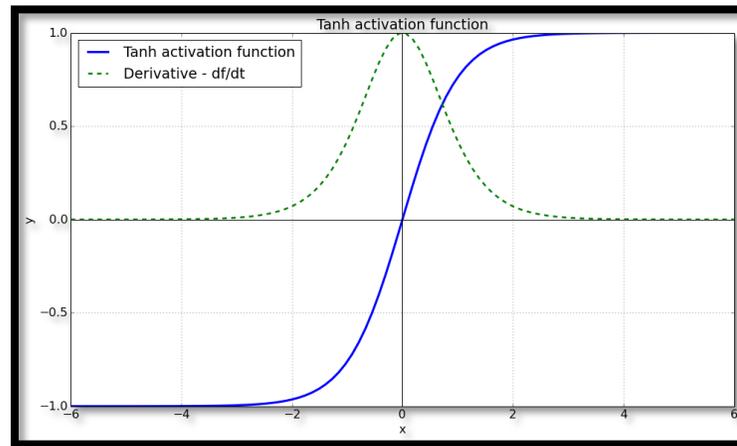


Figure Error! No text of specified style in document..7. Tan activation function

Elle est similaire à la fonction sigmoïde, mais varie de -1 à 1. Elle est plus préférée que la fonction sigmoïde dans les couches cachées.

- **ReLU (Rectified Linear Unit) :**

$$y = \max(0, x).$$

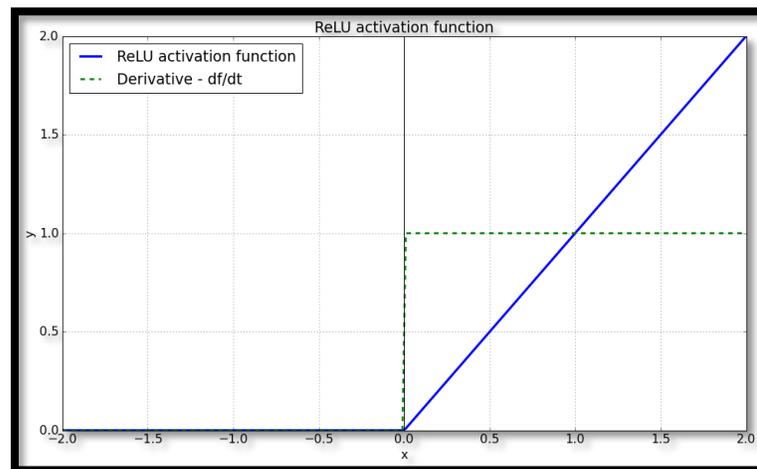


Figure Error! No text of specified style in document..8. ReLU activation function

Elle est actuellement la plus populaire des fonctions d'activation pour les couches cachées des réseaux de neurones profonds, car elle aide à atténuer le problème de disparition de gradient et accélère la convergence de l'entraînement[44].

- **Softmax :**

Elle est souvent utilisée dans la couche de sortie des réseaux de neurones pour les tâches de classification multiclasse, car elle produit une distribution de probabilité sur les classes[45].

- d. Conclusion**

Les fonctions d'activation sont essentielles pour déterminer le comportement et les performances des réseaux de neurones. Choisir la bonne fonction d'activation pour votre tâche peut avoir un impact significatif sur les performances de votre modèle.

## II.7. Les paramètres d'optimisation dans l'apprentissage profond

### II.7.1. Les Optimiseurs en Apprentissage Profond

- a. Introduction**

En apprentissage profond, les optimiseurs sont des algorithmes utilisés pour ajuster les paramètres du modèle (par exemple, les poids et les biais) afin de minimiser la fonction de perte et améliorer les performances du modèle. Il existe plusieurs optimiseurs, chacun avec des caractéristiques et des mécanismes d'action spécifiques. Cet article présente une vue d'ensemble des optimiseurs et explique comment ils fonctionnent[18].

- b. Comprendre les Optimiseurs**

L'optimisation est le processus d'ajustement des paramètres d'un modèle pour minimiser une fonction de perte donnée. Les optimiseurs utilisent les dérivées de la fonction de perte (c'est-à-dire les gradients) pour déterminer comment ajuster les paramètres du modèle. Cette opération s'appelle la "descente de gradient"[46].

- c. Optimiseurs Communs et leur Utilisation**

- **Gradient Descent**

C'est l'optimiseur le plus simple et le plus fondamental. Il met à jour les paramètres du modèle en les déplaçant dans la direction opposée au gradient de la fonction de perte[47].

- **Stochastic Gradient Descent (SGD)**

C'est une variante de la descente de gradient qui effectue une mise à jour pour chaque exemple d'entraînement, plutôt que pour le lot entier. Cela le rend plus rapide et capable de sauter hors des minimums locaux, mais aussi plus bruyant[48].

- **Momentum**

C'est une modification de SGD qui ajoute une composante de "Momentum" aux mises à jour du gradient, ce qui aide l'optimiseur à surmonter les minimaux locaux et les plateaux[40].

- **Adam (Adaptive Moment Estimation)**

Adam (Adaptive Moment Estimation) est un algorithme d'optimisation populaire pour l'apprentissage des paramètres d'un modèle en apprentissage profond. Il a été introduit par Kingma et Ba en 2014 et est connu pour sa robustesse et sa capacité à manipuler des grands jeux de données et des grands modèles[50].

- **Comprendre Adam**

Adam est une méthode de descente de gradient stochastique qui est basée sur l'estimation adaptative des moments de premier et de second ordre. Contrairement à l'algorithme de descente de gradient stochastique classique, Adam adapte le taux d'apprentissage pour chaque paramètre en utilisant des estimations des moments de premier et de second ordre des gradients[18].

En pratique, cela signifie que Adam peut automatiquement ajuster le taux d'apprentissage en fonction de l'information qu'il a accumulée sur les gradients, ce qui peut aider à surmonter certains des défis que présentent d'autres algorithmes d'optimisation, tels que le choix d'un taux d'apprentissage approprié ou le franchissement de sillons et de plateaux.

- **Algorithme Adam**

L'algorithme Adam fonctionne comme suit [50] :

1. Initialisez les paramètres du modèle.
2. Calculez le gradient de la fonction de perte par rapport aux paramètres.
3. Mettez à jour les estimations de moment de premier ordre (la moyenne mobile) et de second ordre (la variance non centrée) des gradients.
4. Corrigez ces estimations de moment pour éliminer leur biais initial vers zéro.
5. Utilisez ces estimations de moment corrigées pour mettre à jour les paramètres.

Mathématiquement, les étapes 3 à 5 peuvent être exprimées comme suit :

$$m_t = \beta_1 * m_{(t-1)} + (1 - \beta_1) * g_t$$

$$v_t = \beta_2 * v_{(t-1)} + (1 - \beta_2) * g_t^2$$

$$m_{hat}_t = m_t / (1 - \beta_1^t)$$

$$v_{hat}_t = v_t / (1 - \beta_2^t)$$

$$\theta_t = \theta_{(t-1)} - \alpha * m_{hat}_t / (\text{sqrt}(v_{hat}_t) + \varepsilon)$$

Où  $g_t$  est le gradient à l'étape  $t$ ,  $m_t$  et  $v_t$  sont les estimations de moment de premier et de second ordre à l'étape  $t$ ,  $m_{hat}_t$  et  $v_{hat}_t$  sont les estimations de moment corrigées,  $\theta_t$  est le paramètre à l'étape  $t$ ,  $\alpha$  est le taux d'apprentissage, et  $\varepsilon$  est un petit nombre pour éviter la division par zéro. Les valeurs recommandées pour  $\beta_1$ ,  $\beta_2$  et  $\varepsilon$  sont 0.9, 0.999 et  $10^{-8}$ , respectivement[50].

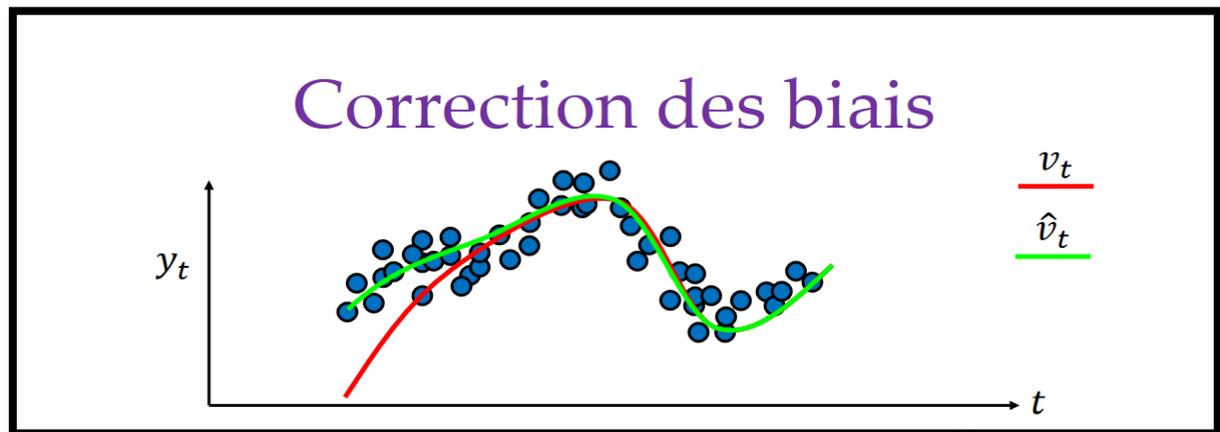


Figure Error! No text of specified style in document..9. Correction des biais

Adam est un algorithme d'optimisation puissant et flexible qui est particulièrement efficace dans les scénarios d'apprentissage profond. Sa capacité à adapter dynamiquement le taux d'apprentissage pour chaque paramètre en fait un outil précieux pour la formation de modèles complexes.

#### d. Conclusion

Les optimiseurs jouent un rôle crucial dans la formation des modèles d'apprentissage profond, déterminant à la fois la vitesse et la qualité de l'apprentissage. Le choix de l'optimiseur peut avoir un impact significatif sur les performances de votre modèle donc là une figure d'un tableau comparatif de optimiseurs communs :

Approche	Hyper-paramètre	Utilisation mémoire
Batch	$\epsilon_t$	D
<b>SGD</b>	$\epsilon_t, m$	D
SGD + Momentum	$\epsilon_t, m, \alpha$	D*2
<b>SGD + Nesterov</b>	$\epsilon_t, m, \alpha$	D*2
Adagrad	$\epsilon_t, m, \delta$	D*2
RMSProp	$\epsilon_t, m, \rho$	D*2
RMSProp + Momentum	$\epsilon_t, m, \rho, \alpha$	D*3
RMSProp + Nesterov	$\epsilon_t, m, \rho, \alpha$	D*3
<b>Adam</b>	$\epsilon_t, m, \rho_1, \rho_2, \delta$	D*3

Figure Error! No text of specified style in document..10. Tableau comparatif de optimiseurs communs

## II.7.2. Le Taux d'Apprentissage en Apprentissage Profond (Learning Rate)

### a. Introduction

Le taux d'apprentissage est un paramètre clé dans l'entraînement des réseaux de neurones. Il contrôle l'ampleur des ajustements apportés aux paramètres du modèle lors de chaque itération de l'algorithme d'optimisation. Un choix approprié du taux d'apprentissage peut accélérer la convergence de l'entraînement et améliorer la performance du modèle final[18].

### b. Comprendre le Taux d'Apprentissage

Lorsque nous entraînons un modèle de machine learning, nous utilisons généralement une forme de descente de gradient pour minimiser la fonction de coût. À chaque étape de cet algorithme, nous mettons à jour les paramètres du modèle en déplaçant légèrement dans la direction qui réduit le plus la fonction de coût. Le taux d'apprentissage, souvent noté alpha ou  $\eta$ , contrôle l'ampleur de ce déplacement[46].

Un taux d'apprentissage trop élevé peut entraîner un comportement instable et empêcher la convergence de l'algorithme. À l'inverse, un taux d'apprentissage trop faible peut ralentir la convergence et faire que l'algorithme reste bloqué dans un minimum local de la fonction de coût[51].

### c. Stratégies d'Ajustement du Taux d'Apprentissage

Il existe plusieurs stratégies pour choisir et ajuster le taux d'apprentissage au cours de l'entraînement :

- **Taux d'apprentissage constant**

C'est l'approche la plus simple, où nous utilisons le même taux d'apprentissage tout au long de l'entraînement.

- **Decay du taux d'apprentissage**

Ici, le taux d'apprentissage est progressivement réduit au fur et à mesure que l'entraînement avance. Cela peut être fait de différentes manières, par exemple en réduisant le taux d'apprentissage d'un facteur constant à chaque époque, ou en réduisant le taux d'apprentissage selon une programmation prédéfinie[52].

- **Adaptive learning rates**

Dans cette approche, le taux d'apprentissage est adapté en fonction de l'évolution de l'entraînement. Des exemples de ces méthodes incluent Adagrad, Adadelta, RMSprop, et Adam[50].

### d. Conclusion

Le taux d'apprentissage est un paramètre critique en apprentissage profond. Le choix de la bonne stratégie de taux d'apprentissage peut avoir un impact significatif sur la qualité et l'efficacité de l'entraînement de votre modèle.

## II.8. L'IA et l'éthique

### II.8.1. Problématiques éthiques liées à l'IA

L'essor de l'intelligence artificielle (IA) a soulevé un certain nombre de problématiques éthiques. Voici quelques-unes des plus importantes :

#### a. Biais algorithmique

Les systèmes d'IA sont formés sur des données collectées à partir du monde réel, qui peuvent souvent refléter des préjugés et des discriminations existants. Par conséquent, ces systèmes peuvent perpétuer ou même amplifier ces biais[53].

#### b. Vie privée et confidentialité

L'IA nécessite souvent de grandes quantités de données pour fonctionner efficacement, ce qui peut poser des problèmes de confidentialité et de protection des données. De plus, certaines applications de l'IA, comme la reconnaissance faciale, peuvent être utilisées de manière intrusive ou abusive[54].

#### c. Responsabilité

Dans les situations où les systèmes d'IA prennent des décisions importantes, comme dans les voitures autonomes ou les systèmes de diagnostic médical, il peut être difficile de déterminer qui est responsable en cas de mauvaises décisions ou d'erreurs[55].

#### d. Transparence et explicabilité

De nombreux modèles d'IA sont considérés comme des "boîtes noires" car leurs processus de décision sont difficiles à comprendre, même pour leurs créateurs. Cela pose des problèmes en termes de transparence et de responsabilité[56].

#### e. Impact sur l'emploi

Il y a des inquiétudes quant à l'impact que l'IA pourrait avoir sur le marché du travail, avec le potentiel de remplacer certains emplois, en particulier ceux impliquant des tâches routinières et répétitives[56].

### II.8.2. Solutions et recommandations

Les problèmes éthiques soulevés par l'intelligence artificielle sont importants et complexes. Pour y faire face, plusieurs solutions et recommandations ont été proposées dans la littérature scientifique et par diverses organisations.

#### a. Lutte contre les biais algorithmiques

Pour atténuer le risque de biais dans les systèmes d'IA, il est recommandé d'implémenter des méthodes de contrôle et de correction de biais durant l'entraînement des modèles. De plus, utiliser des ensembles de données de formation diversifiés et représentatifs peut également aider à réduire les biais[57].

#### b. Protection de la vie privée

La confidentialité des données peut être assurée en appliquant des principes de minimisation des données, en ne recueillant et n'utilisant que les données strictement nécessaires. Des technologies comme la confidentialité différentielle et le chiffrement homomorphe peuvent aider à protéger la confidentialité des données utilisées par les systèmes d'IA[58].

#### c. Transparence et explicabilité

Les décisions prises par les systèmes d'IA devraient être explicables et compréhensibles par les utilisateurs. L'explicabilité et la transparence peuvent être encouragées par des normes ouvertes, des audits de systèmes d'IA et le développement de techniques d'IA explicables (XAI)[59].

#### d. Responsabilité

Une claire répartition des responsabilités est nécessaire en cas de dommages ou d'erreurs causés par les systèmes d'IA. Les entreprises et les organisations devraient être tenues responsables de l'évaluation régulière de leurs systèmes d'IA pour assurer leur sécurité et leur fiabilité[60].

#### e. Impact sur l'emploi

La formation et l'éducation continues devraient être encouragées pour aider les travailleurs à s'adapter à l'évolution du marché du travail due à l'IA. De plus, des politiques d'accompagnement pourraient être nécessaires pour soutenir ceux qui sont le plus touchés par l'automatisation[61].

## II.9. Les tendances futures de l'IA

### II.9.1. IA et Big Data

L'intelligence artificielle (IA) et le Big Data sont deux concepts fortement liés et ont transformé de nombreux aspects de notre société.

#### a. IA et Big Data

Le Big Data se réfère aux vastes ensembles de données qui sont trop grands et trop complexes pour être traités par des méthodes traditionnelles de traitement des données. L'IA, en particulier l'apprentissage automatique, est un outil clé pour analyser et extraire des informations précieuses de ces ensembles de données. Les algorithmes d'IA peuvent apprendre à partir de ces données, découvrir des modèles et faire des prédictions ou prendre des décisions sans être explicitement programmés pour le faire[62].

#### b. Applications

Il existe de nombreuses applications de l'IA et du Big Data dans divers secteurs, tels que la santé, la finance, le marketing, la logistique et les transports. Par exemple, en utilisant l'IA et le Big Data, les entreprises peuvent analyser les comportements des consommateurs, optimiser les opérations logistiques, prédire les tendances du marché, et améliorer la détection des fraudes[63].

#### c. Défis

Cependant, l'utilisation de l'IA et du Big Data présente également des défis. Ces défis comprennent la garantie de la confidentialité et de la sécurité des données, la gestion des erreurs de prédiction, l'atténuation des biais algorithmiques, et la nécessité d'infrastructure et de compétences pour gérer et analyser les Big Data[64].

### II.9.2. IA et IoT

L'Internet des objets (IoT) et l'intelligence artificielle (IA) sont deux technologies de pointe qui se complètent mutuellement et qui ont le potentiel de transformer de nombreux aspects de notre vie quotidienne et de nos activités commerciales.

**a. IA et IoT**

L'Internet des objets désigne un réseau de dispositifs physiques connectés qui recueillent et échangent des données. L'IA, en particulier l'apprentissage automatique, est souvent utilisée pour analyser ces données, découvrir des modèles et prendre des décisions automatiques. L'IA permet d'ajouter de l'intelligence aux dispositifs IoT, ce qui peut améliorer leur utilité et leur efficacité[65].

**b. Applications**

Il existe de nombreuses applications de l'IA et de l'IoT, notamment dans des domaines tels que la maison intelligente, la santé, l'industrie manufacturière, les transports et l'agriculture. Par exemple, dans une maison intelligente, l'IA peut être utilisée pour analyser les données recueillies par divers capteurs et dispositifs IoT pour automatiser diverses tâches ménagères[66].

**c. Défis**

L'application de l'IA à l'IoT présente également des défis. Par exemple, garantir la sécurité et la confidentialité des données recueillies par les dispositifs IoT est une préoccupation majeure. De plus, l'IA nécessite souvent de grandes quantités de données pour l'entraînement, ce qui peut être un défi dans les environnements IoT où les ressources de calcul et de stockage sont limitées[3].

**II.9.3. IA et la robotique**

L'intelligence artificielle (IA) et la robotique sont deux domaines qui se chevauchent et se complètent mutuellement. En effet, l'IA est souvent utilisée pour donner aux robots la capacité d'effectuer des tâches complexes, d'interagir avec leur environnement et de prendre des décisions autonomes.

**a. IA et Robotique**

La robotique traite de la conception, de la construction, du fonctionnement et de l'utilisation de robots, tandis que l'IA concerne la création de systèmes capables de réaliser des tâches qui nécessiteraient normalement une intelligence humaine. Lorsqu'elle est appliquée à la robotique, l'IA peut permettre aux robots d'apprendre à partir de leur expérience, d'interagir avec les humains de manière plus naturelle, de comprendre et de naviguer dans leur environnement, et de prendre des décisions complexes[67].

**b. Applications**

L'IA et la robotique ont des applications dans de nombreux domaines, tels que la fabrication, la logistique, la santé, l'agriculture et le service à domicile. Par exemple, les robots assistés par l'IA sont utilisés pour automatiser les tâches de production dans les usines, pour aider les personnes âgées ou handicapées, pour effectuer des tâches dangereuses ou difficiles comme la désactivation des bombes ou l'exploration spatiale[68].

**c. Défis**

L'utilisation de l'IA en robotique présente également des défis, tels que la nécessité d'assurer la sécurité des opérations robotiques, d'atténuer les problèmes de biais et d'équité, et de gérer les questions éthiques et juridiques liées à l'autonomie des robots[69].

**II.10. Conclusion**

En conclusion, l'intelligence artificielle (IA) est un domaine vaste et en constante évolution qui a le potentiel de transformer de nombreux aspects de notre vie quotidienne et de notre société. Elle comprend diverses techniques, notamment l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement, qui sont souvent utilisées en conjonction avec d'autres technologies de pointe comme le Big Data, l'Internet des objets (IoT) et la robotique.

Cependant, l'utilisation de l'IA présente également de nombreux défis, notamment en ce qui concerne les problèmes éthiques, les biais algorithmiques, la protection de la vie privée et l'impact sur l'emploi. Il est donc crucial de développer et de mettre en œuvre des stratégies pour atténuer ces risques et pour utiliser l'IA de manière responsable.

L'IA est un domaine de recherche actif et il est important de continuer à explorer et à comprendre ses implications afin de maximiser ses avantages tout en minimisant ses risques.

# **Chapitre III**

## **IA dans le contrôle de qualité**

### III.1. Introduction

Dans ce chapitre, nous abordons divers sujets clés liés à notre étude. Nous commençons par explorer la fabrication des cartes de circuits imprimés (PCBA) et le processus de bain de soudure, et les méthodes actuelles d'inspection des PCBA et les méthodes basées sur l'IA, pour comprendre comment notre solution se positionne par rapport aux méthodes existantes et comment elle peut améliorer le processus de contrôle qualité. Chaque section de ce chapitre fournit des informations essentielles pour comprendre le contexte et la pertinence de notre recherche. Étant donné que notre solution d'inspection basée sur l'IA est conçue pour fonctionner dans ce contexte. Ensuite, nous examinons les fondements des images numériques et leur traitement, car notre modèle d'IA utilise des images numériques pour identifier les défauts dans les PCBA. Nous discutons également de la vision par ordinateur, qui permet aux ordinateurs de "voir" et d'interpréter les images numériques, et de son application dans le contrôle qualité, en mettant l'accent sur l'inspection des PCBA. Nous explorons les défis de l'application de l'IA dans le contrôle qualité et proposons des solutions pour les surmonter.

### III.2. Fabrication de PCBA et Processus de Bain de Soudure

#### III.2.1. Fabrication de PCBA

La carte de circuit imprimé (PCBA) est un composant clé dans presque tous les appareils électroniques. Le processus de fabrication d'une PCBA est complexe et délicat, impliquant plusieurs étapes allant de la conception à la finition. L'une des étapes les plus critiques est le bain de soudure. Ce processus implique le dépôt de soudure sur les parties spécifiées de la carte pour permettre l'assemblage des composants électroniques[70]. Malheureusement, ce processus est également sujet à de nombreux défauts qui peuvent compromettre la qualité du PCBA.

Le processus de production des cartes mères des téléviseurs peut varier légèrement en fonction des fabricants et des technologies utilisées. Cependant, voici une description générale du processus

##### a. Conception et prototypage

Les ingénieurs conçoivent la carte mère en fonction des spécifications du téléviseur. Ils créent des schémas électriques, des plans de circuit imprimé et effectuent des simulations pour s'assurer du bon fonctionnement de la carte. Des prototypes sont ensuite fabriqués et testés.

**b. Approvisionnement des composants**

Une fois la conception validée, les fabricants passent à l'approvisionnement des composants nécessaires à la fabrication de la carte mère. Il s'agit de composants électroniques tels que des processeurs, des circuits intégrés, des condensateurs, des résistances, etc. Les fabricants peuvent acheter ces composants auprès de différents fournisseurs.

**c. Fabrication du circuit imprimé**

Le circuit imprimé est fabriqué en utilisant des techniques de fabrication de circuits imprimés, telles que le dépôt de cuivre sur un substrat isolant, la gravure chimique pour créer les pistes et les pads, et le perçage pour les trous de montage des composants. Des machines spécialisées automatisent ces processus.

**d. Assemblage des composants**

Les composants électroniques sont placés et soudés sur le circuit imprimé à l'aide de machines d'assemblage automatiques. Cette étape peut impliquer des techniques de soudure à la vague, de soudure au reflow ou de soudure sélective, en fonction des spécifications des composants.

**e. Programmation et test**

Une fois les composants assemblés, la carte mère est programmée avec le micrologiciel nécessaire au fonctionnement du téléviseur. Des tests sont effectués pour vérifier la fonctionnalité de la carte mère, notamment les interfaces, la mémoire, les ports de connectivité, etc. Les cartes défectueuses sont éliminées.

**f. Intégration dans le téléviseur**

Une fois que les cartes mères sont fabriquées et testées, elles sont intégrées dans les téléviseurs. Cela implique le montage de la carte mère dans le boîtier du téléviseur, la connexion des câbles internes, l'ajout d'autres composants tels que l'écran, les haut-parleurs, etc.

**g. Contrôle qualité finale**

Avant de quitter l'usine, les téléviseurs sont soumis à des tests de contrôle qualité approfondis pour s'assurer de leur bon fonctionnement. Cela peut inclure des tests d'affichage, de son, de connectivité, de réception, etc. Les téléviseurs qui passent ces tests sont emballés et prêts à être expédiés.

Il convient de noter que ce processus est une simplification générale, et chaque fabricant peut avoir des étapes supplémentaires ou des variantes spécifiques en fonction de leurs

---

propres méthodes de fabrication et des technologies utilisées.

### **III.2.2. La technique de soudure par vague**

La technique de soudure par vague, également appelée soudure à la vague, est une méthode couramment utilisée dans l'assemblage électronique pour souder les composants sur les cartes de circuit imprimé (PCBA). Elle est principalement utilisée pour les composants traversants (through-hole) tels que les connecteurs, les résistances, les condensateurs, etc. Voici comment fonctionne la technique de soudure par vague :

#### **a. Préparation de la carte de circuit imprimé**

Avant de procéder à la soudure, la carte de circuit imprimé est préparée en appliquant un masque protecteur sur les zones où le soudage n'est pas souhaité. Cela permet de limiter la soudure uniquement aux pads des composants.

#### **b. Préparation de la vague de soudure**

Une fois la carte prête, un bain de soudure est préparé dans un réservoir. Ce bain de soudure est généralement un alliage d'étain et de plomb (mais des alternatives sans plomb sont également utilisées). La soudure est maintenue à une température contrôlée pour assurer une fusion adéquate lors du passage des composants à travers la vague.

#### **c. Positionnement des composants**

Les composants traversants sont préalablement insérés dans les trous prévus sur la carte de circuit imprimé. Les pattes des composants dépassent de l'autre côté de la carte.

#### **d. Passage à travers la vague de soudure**

La carte de circuit imprimé est positionnée de manière à ce que les composants à souder soient juste au-dessus de la vague de soudure. La vague de soudure est ensuite générée en faisant fondre le métal d'alliage étain-plomb.

#### **e. Soudage**

Lorsque la vague de soudure est formée, la carte de circuit imprimé est déplacée lentement à travers la vague. La vague de soudure monte à travers les trous prévus pour les composants, permettant ainsi la fusion des pattes des composants et la création d'une liaison solide entre les composants et la carte de circuit imprimé.

#### f. Refroidissement et solidification

Après le passage à travers la vague, la carte de circuit imprimé est déplacée vers une zone de refroidissement où la soudure se solidifie. Cela fixe les composants en place et crée des connexions électriques solides.

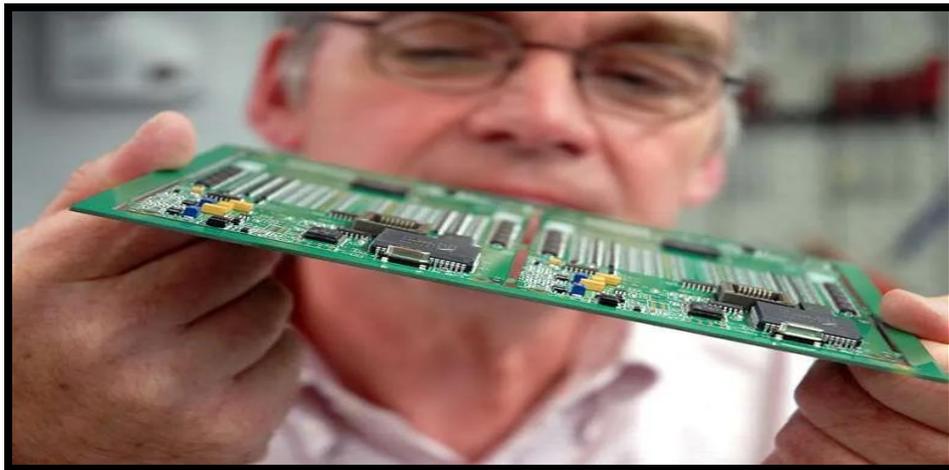
La technique de soudure par vague offre plusieurs avantages, tels qu'une grande vitesse d'assemblage, la possibilité de souder plusieurs composants simultanément et une fiabilité élevée. Cependant, elle est principalement adaptée aux composants traversants et n'est pas adaptée aux composants de montage en surface (SMT - Surface Mount Technology).

### III.3. Inspection des PCBA : Méthodes Traditionnelles

#### III.3.1. Inspection manuelle

L'inspection manuelle a longtemps été la méthode standard pour vérifier la qualité des PCBA. Cela implique un examen visuel par des opérateurs humains pour détecter des défauts tels que des connexions incorrectes, des ponts de soudure, ou des composants mal alignés. L'inspection manuelle peut être efficace pour détecter des problèmes visibles à l'œil nu, surtout lorsque les opérateurs sont hautement qualifiés et expérimentés.

Cependant, cette méthode présente plusieurs inconvénients. Premièrement, elle est très dépendante de la compétence et de la vigilance de l'opérateur. Deuxièmement, elle est sujette à des erreurs dues à la fatigue humaine, en particulier lors de l'inspection de grandes quantités de PCBA. Enfin, l'inspection manuelle peut ne pas être capable de détecter des défauts subtils ou cachés, comme des problèmes au niveau des couches internes du PCBA.



**Figure Error! No text of specified style in document..11. Inspection manuelle de pcb par un operateur**

### III.3.2. Inspection Automatisée par Rayons X

L'inspection automatisée par rayons X (AXI) est une méthode plus récente et plus avancée qui permet de voir à travers le PCBA et d'identifier des défauts qui ne sont pas visibles à l'œil nu. C'est une technique précieuse pour vérifier les joints de soudure des composants de montage en surface (SMT) et des composants de montage en trou traversant (THT), ainsi que pour détecter des défauts comme les fissures ou les vides à l'intérieur des joints de soudure.

Cependant, l'AXI a ses propres limites. Le coût élevé de l'équipement de rayons X peut être un obstacle pour certaines entreprises. De plus, bien que l'AXI soit efficace pour détecter certains types de défauts, elle peut ne pas être capable de détecter d'autres types de défauts, tels que des composants manquants ou mal orientés.

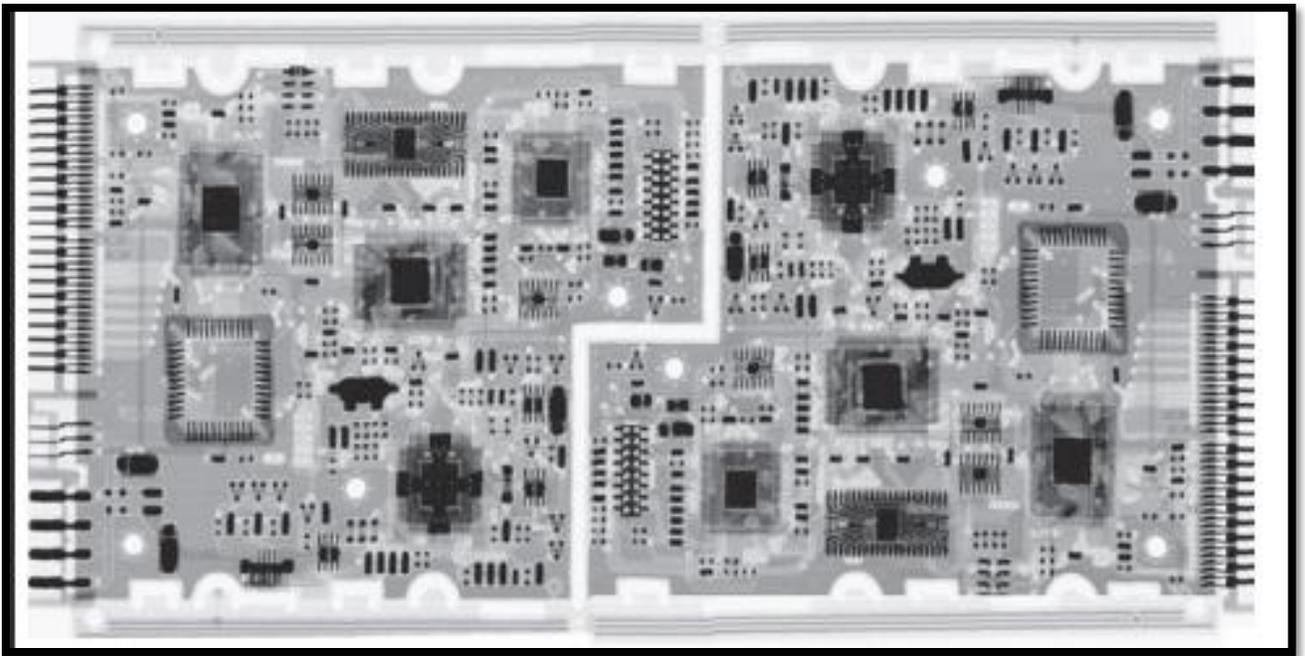


Figure Error! No text of specified style in document..12. Inspection Automatisée par Rayons X

### III.3.3. Inspection Automatisée Optique (AOI)

L'inspection automatisée optique (AOI) est une autre méthode couramment utilisée pour inspecter les PCBA. Cette méthode utilise des caméras haute résolution et des algorithmes de traitement d'image pour détecter une variété de défauts, y compris des composants manquants, mal orientés, ou mal soudés. Les systèmes AOI sont généralement capables d'inspecter les PCBA beaucoup plus rapidement que l'inspection manuelle, ce qui les rend plus efficaces pour les grandes productions.

Cependant, comme l'AXI, les systèmes AOI ont également leurs limites. Par exemple, ils peuvent ne pas être capables de détecter certains types de défauts, comme les vides à l'intérieur des joints de soudure. De plus, ils peuvent parfois donner de faux positifs ou de faux négatifs, ce qui nécessite une vérification manuelle.

Dans l'ensemble, bien que les méthodes traditionnelles d'inspection des PCBA aient contribué à améliorer



Figure Error! No text of specified style in document..13. Inspection Automatisée Optique (AOI)

#### III.4. Notions de Base sur l'Image Numérique

Dans l'optique de comprendre comment l'IA peut être utilisée pour l'inspection des PCBA, il est indispensable d'avoir une connaissance de base sur ce qu'est une image numérique. Une image numérique est essentiellement une représentation d'une image réelle sous forme de matrice de pixels, chaque pixel étant représenté par un nombre ou un ensemble de nombres. La valeur de ces nombres dépend du nombre de couleurs ou de niveaux de gris qu'une image peut représenter[71].

Un aspect fondamental des images numériques est la codification des pixels, qui se fait souvent en RGB (Rouge, Vert, Bleu), HSV (Hue, Saturation, Value) ou en niveaux de gris. Le codage RGB utilise trois nombres pour représenter respectivement les composantes rouge, verte et bleue de la couleur de chaque pixel. Le codage HSV, d'autre part, représente chaque couleur

en termes de teinte, de saturation et de valeur. Les images en niveaux de gris sont des images où chaque pixel n'est représenté que par une seule valeur, indiquant l'intensité du gris[72].

La résolution d'une image est une autre notion clé, elle est définie par le nombre de pixels par unité de surface. Plus le nombre de pixels est élevé, plus l'image est détaillée. Par conséquent, la résolution d'une image peut avoir un impact significatif sur la précision d'un modèle d'IA qui utilise ces images pour l'apprentissage[72].

Dans le contexte de l'IA, la transformation d'images, comme la conversion de couleurs, le redimensionnement, la normalisation, etc., est souvent nécessaire pour préparer les images pour l'apprentissage d'un modèle[73].

### **III.5. Traitement d'images**

Le traitement d'images, un domaine dynamique, consiste à utiliser des techniques et des algorithmes pour modifier et améliorer les images numériques. Il s'applique dans divers domaines allant de la médecine à l'ingénierie, y compris l'art et la photographie. Il comprend diverses techniques comme l'amélioration de l'image, la restauration, la segmentation et l'analyse de l'image[71].

#### **III.5.1. Techniques de Traitement d'Image**

L'optimisation de l'image L'optimisation de l'image est une technique qui vise à améliorer la qualité d'une image en ajustant des paramètres tels que la luminosité, le contraste, l'équilibre des couleurs et en réduisant le bruit[74].

- **Ajustement de la luminosité et du contraste**

Il s'agit d'une technique qui améliore la qualité visuelle de l'image en manipulant la luminosité et le contraste, par exemple en utilisant l'égalisation d'histogramme[71].

- **Ajustement des couleurs**

C'est un processus d'ajustement des couleurs d'une image pour obtenir un rendu plus naturel. Il peut s'effectuer en ajustant la balance des blancs ou en utilisant des techniques de correction des couleurs[74].

- **Réduction du bruit**

Il s'agit d'une technique d'élimination des défauts dans une image tels que le grain, le bruit et les taches. Il existe plusieurs techniques de réduction du bruit, y compris le filtrage médian, le filtrage gaussien et le filtrage en ondelettes[71].

- **Restauration d'image**

La restauration d'image consiste à récupérer une image à partir de données dégradées ou endommagées par divers facteurs comme le flou, le mouvement ou la pixellisation[72].

- **Défloutage**

C'est un processus qui permet de réduire le flou dans une image. Les techniques de défloutage incluent le filtrage de Wiener, la déconvolution de Lucy-Richardson et la déconvolution aveugle[74].

- **Segmentation d'image**

La segmentation d'image est la division d'une image en plusieurs régions ou segments qui représentent des objets ou des parties d'objets. Elle est souvent utilisée pour la reconnaissance d'objets et la détection de contours[71].

- **Analyse d'image**

C'est l'extraction d'informations utiles d'une image. L'analyse d'image peut comprendre des techniques comme la détection de bords, la détection de points d'intérêt, la mesure de texture et la reconnaissance de formes[72].

- **Extraction de caractéristiques**

C'est l'extraction de caractéristiques significatives d'une image qui peuvent être utilisées pour l'analyse ultérieure ou pour la reconnaissance d'objets[35].

- **La fusion d'images**

C'est la combinaison de plusieurs images pour obtenir une image finale qui est une amélioration ou une version complète des images d'origine[71].

- **Classification d'images**

C'est la classification d'une image en fonction de son contenu. Les caractéristiques extraites de l'image sont utilisées pour classer l'image dans une catégorie[35].

- **Détection de caractéristiques**

C'est l'extraction de caractéristiques spécifiques d'une image pour la reconnaissance d'objets ou de motifs. Les caractéristiques peuvent être basées sur la texture, la forme, la couleur ou d'autres propriétés de l'image[72].

- **Reconnaissance de motifs**

C'est la reconnaissance de motifs récurrents dans une image. Les techniques de reconnaissance de motifs utilisent des algorithmes pour identifier les motifs qui se répètent dans une image[35].

- **Reconnaissance faciale**

Il s'agit d'un processus qui permet d'identifier les visages dans une image ou une vidéo. Des caractéristiques faciales telles que la forme, la texture et la couleur sont utilisées pour identifier les visages[74].

- **Traitement d'image en temps réel**

C'est le traitement d'images instantané sans délai perceptible. Il est souvent utilisé dans les applications de vision par ordinateur comme la surveillance vidéo, la reconnaissance de mouvements et la reconnaissance de visages en temps réel[72].

- **Restauration d'image**

La restauration d'image consiste à récupérer des images endommagées ou corrompues. Les images peuvent être endommagées par le bruit, les défauts de capteur, la dégradation de l'image et d'autres facteurs[71].

- **Super-résolution d'image**

La super-résolution d'image est le processus de génération d'une image de haute résolution à partir d'une image de basse résolution. Les techniques de super-résolution d'image utilisent des

algorithmes pour combiner plusieurs images de basse résolution pour créer une image de haute résolution[72].

- **Traitement d'image pour la réalité augmentée**

Il s'agit de l'utilisation de techniques de traitement d'image pour améliorer l'expérience de la réalité augmentée. Cela peut inclure la détection d'objets, la reconstruction 3D, la segmentation d'images et d'autres techniques[72].

### **III.6. Vision par Ordinateur**

La vision par ordinateur est une sous-discipline de l'intelligence artificielle qui vise à donner aux machines la capacité de "voir" et de comprendre le contenu des images numériques ou des vidéos. Elle comprend un certain nombre de techniques différentes, allant de la détection et la reconnaissance d'objets à la modélisation et à la reconstruction de scènes en 3D[72].

Dans le contexte de l'inspection des PCBA, la vision par ordinateur peut être utilisée pour identifier et classifier automatiquement les défauts. Par exemple, elle peut être utilisée pour reconnaître les motifs ou les formes spécifiques qui indiquent la présence de défauts tels que des soudures froides, des composants mal alignés, etc.

La vision par ordinateur utilise un certain nombre de techniques d'apprentissage automatique, en particulier l'apprentissage profond, pour accomplir ces tâches. Les réseaux de neurones convolutifs (CNN), en particulier, se sont avérés particulièrement efficaces pour de nombreuses tâches de vision par ordinateur, notamment la classification d'images, la détection d'objets et la segmentation d'images[75].

Il est important de noter que, bien que le traitement d'image et la vision par ordinateur soient étroitement liés, ils ne sont pas identiques. Le traitement d'image implique la manipulation des images pour améliorer leur qualité ou extraire des informations utiles, tandis que la vision par ordinateur implique l'utilisation de ces informations pour comprendre le contenu de l'image et prendre des décisions basées sur cette compréhension[73].

## **III.7. Application de l'IA dans le Contrôle Qualité**

### **III.7.1. Vue d'ensemble**

L'intelligence artificielle (IA) a gagné du terrain dans une variété de secteurs, y compris la fabrication, grâce à son potentiel pour améliorer l'efficacité et la précision des processus. Dans le contexte du contrôle de qualité, l'IA offre la possibilité de détecter automatiquement les défauts et les anomalies, permettant ainsi une inspection plus rapide et plus précise que les méthodes traditionnelles[76].

### **III.7.2. Apprentissage Machine pour le Contrôle Qualité**

L'une des applications clés de l'IA dans le contrôle de qualité est l'utilisation de l'apprentissage machine, un sous-ensemble de l'IA qui implique l'entraînement d'un modèle pour faire des prédictions ou prendre des décisions basées sur des données. Les techniques d'apprentissage machine peuvent être utilisées pour créer des modèles de détection de défauts qui peuvent identifier les défauts sur la base de caractéristiques complexes et subtiles des données, allant au-delà de ce qui est possible avec l'inspection visuelle humaine ou les méthodes automatisées traditionnelles.

L'apprentissage en profondeur, un type d'apprentissage machine qui utilise des réseaux de neurones avec plusieurs couches de transformation et d'apprentissage, a montré des résultats particulièrement prometteurs dans le contrôle de qualité. Les réseaux de neurones convolutifs (CNN), un type de modèle d'apprentissage en profondeur conçu pour traiter les données d'image, ont été utilisés pour identifier les défauts dans les images des produits, y compris les PCBA[28].

### **III.7.3. Avantages de l'IA pour le Contrôle Qualité**

L'application de l'IA au contrôle de qualité offre plusieurs avantages. Tout d'abord, l'IA peut augmenter la vitesse et l'efficacité de l'inspection, permettant ainsi de traiter un plus grand nombre de produits en moins de temps. Deuxièmement, l'IA peut améliorer la précision de l'inspection, en particulier pour les défauts qui sont difficiles à détecter avec les méthodes traditionnelles. Enfin, l'IA peut aider à réduire les coûts associés à l'inspection et au contrôle de qualité, en diminuant la quantité de produits défectueux qui passent à travers le processus de production et en réduisant la nécessité de l'inspection manuelle.

### III.7.4. Défis de l'IA pour le Contrôle Qualité

#### a. Nécessité de Données de Haute Qualité

L'application de l'IA dans le contrôle de la qualité nécessite de grandes quantités de données de haute qualité pour l'entraînement des modèles d'apprentissage machine. Ces données doivent être correctement étiquetées, ce qui signifie qu'elles doivent être classées correctement comme défectueuses ou non défectueuses. L'acquisition de ces données peut être coûteuse et chronophage, et peut nécessiter des compétences spécifiques pour garantir que les données sont correctement collectées et étiquetées.

#### b. Complexité de la mise en œuvre

La mise en œuvre de l'IA pour le contrôle de la qualité peut également être complexe. Cela nécessite une connaissance approfondie de l'IA et de l'apprentissage machine, ainsi que la capacité de choisir et d'ajuster les modèles appropriés pour la tâche à accomplir. En outre, l'IA doit être intégrée de manière fluide dans les processus de production existants, ce qui peut nécessiter des modifications de l'infrastructure de production et de la chaîne logistique.

#### c. Faux positifs et Faux négatifs

Bien que l'IA puisse améliorer la précision de l'inspection, elle peut également produire des faux positifs (identification erronée d'un produit non défectueux comme défectueux) et des faux négatifs (non détection d'un produit défectueux). Ces erreurs peuvent entraîner une perte de ressources et de temps, car les produits identifiés à tort comme défectueux doivent être retestés. Les faux négatifs sont particulièrement problématiques car ils peuvent entraîner la distribution de produits défectueux.

#### d. Problèmes d'éthique et de confidentialité

L'application de l'IA peut également soulever des questions d'éthique et de confidentialité. Par exemple, l'utilisation de caméras pour collecter des données pour l'entraînement des modèles d'IA peut potentiellement enregistrer les travailleurs sans leur consentement. De plus, les données collectées pour l'IA doivent être stockées et traitées de manière sécurisée pour éviter tout risque de violation de la confidentialité ou de la sécurité.

En dépit de ces défis, l'application de l'IA dans le contrôle de la qualité a un potentiel énorme pour améliorer l'efficacité et la précision de l'inspection. Il est donc essentiel de continuer à explorer cette technologie et de développer des stratégies pour surmonter les défis associés.

### **III.8. Inspection des PCBA Basée sur l'IA**

#### **III.8.1. Vue d'ensemble**

L'utilisation de l'IA pour l'inspection des PCBA s'appuie sur l'application de l'apprentissage machine, et plus précisément de l'apprentissage en profondeur, pour détecter les défauts. Les techniques les plus couramment utilisées impliquent l'application de réseaux de neurones convolutifs (CNN), qui sont particulièrement adaptés à l'analyse des images

#### **III.8.2. Avantages de l'inspection des PCBA basée sur l'IA**

L'inspection des PCBA basée sur l'IA offre un certain nombre d'avantages. Par rapport à l'inspection manuelle, l'IA peut traiter beaucoup plus rapidement un grand nombre de PCBA, ce qui permet d'économiser du temps et des ressources. Par rapport aux méthodes d'inspection automatisées traditionnelles, l'IA peut souvent détecter plus précisément et avec moins de faux positifs et de faux négatifs. En outre, une fois qu'un modèle d'IA a été formé, il peut être appliqué de manière cohérente, réduisant ainsi la variabilité de l'inspection.

#### **III.8.3. Défis de l'inspection des PCBA basée sur l'IA**

Malgré ses avantages, l'inspection des PCBA basée sur l'IA présente également des défis. Comme pour d'autres applications de l'IA, l'un des principaux défis est la nécessité de disposer de grandes quantités de données de haute qualité pour l'entraînement. Les entreprises doivent également investir dans le développement des compétences nécessaires pour implémenter et maintenir les systèmes d'IA, ce qui peut nécessiter une formation ou l'embauche de personnel spécialisé.

#### **III.8.4. Exemples d'inspection des PCBA basée sur l'IA**

Plusieurs études et implémentations industrielles ont montré l'efficacité de l'IA pour l'inspection des PCBA. Par exemple, Ngo et See (2020) ont développé un système basé sur un CNN pour détecter et classer les défauts dans le processus de sérigraphie de la pâte à braser. Leurs résultats ont montré que leur système était capable de détecter avec succès une variété de défauts avec une grande précision.

Dans un autre exemple, une entreprise de fabrication d'électronique a utilisé l'IA pour automatiser l'inspection de leurs PCBA après le processus de soudage à la vague. Leur système utilise l'IA pour analyser les images des PCBA, détecter les défauts, et classer les PCBA comme conformes ou non conformes[76].

Ces exemples montrent que l'IA a le potentiel d'améliorer considérablement l'inspection des PCBA. Cependant, davantage de recherches et de développement sont nécessaires pour pleinement réaliser ce potentiel.

Notre machine :

### **III.9. Conclusion**

Le chapitre III examine l'application de l'intelligence artificielle (IA) dans le contrôle de qualité des cartes de circuits imprimés (PCBA). Il explore les méthodes traditionnelles d'inspection des PCBA, les limites de ces méthodes et les défis auxquels elles sont confrontées. L'IA offre des avantages significatifs dans le contrôle de qualité des PCBA, tels que l'automatisation de l'inspection, l'amélioration de la vitesse et de la précision, et la réduction des coûts. L'apprentissage machine, en particulier l'apprentissage en profondeur avec des réseaux de neurones convolutifs, est utilisé pour détecter automatiquement les défauts sur les PCBA. Bien que des défis subsistent, des exemples d'inspection des PCBA basée sur l'IA ont montré des résultats prometteurs. Cependant, davantage de recherches et de développements sont nécessaires pour exploiter pleinement le potentiel de l'IA dans le contrôle de qualité des PCBA. En conclusion, l'IA offre des opportunités d'amélioration significative dans le contrôle de qualité des PCBA, et il est essentiel de poursuivre les efforts dans ce domaine pour répondre aux besoins de l'industrie électronique.

**Chapitre IV**

**Solution Proposée**

## IV.1. Introduction

Ce dernier chapitre de notre mémoire, intitulé "Solution proposée", présente notre approche de résolution du problème de l'inspection des PCBA chez Bomare Company. Nous commencerons par expliquer notre choix de l'outil d'Intelligence Artificielle, un réseau de neurones convolutif (CNN), pour aborder ce défi. Ensuite, nous décrirons en détail les différentes étapes de la mise en œuvre de cette solution, de la collecte et préparation des données à l'entraînement du modèle. Après l'évaluation de la performance du modèle, nous discuterons de son intégration dans les processus de production de Bomare Company, évaluant la faisabilité, détaillant la mise en œuvre, et soulignant l'importance de la surveillance continue et l'amélioration. Enfin, nous examinerons l'impact potentiel de cette intégration sur la production.

Notre projet repose sur une machine d'inspection par caméra alimentée par un algorithme CNN (Convolutional Neural Network) pour inspecter et classifier les cartes mères de téléviseurs en deux catégories : conformes ou non conformes. L'approche novatrice de notre machine consiste à acheminer la carte mère à travers une boîte d'inspection spécialement conçue, équipée de quatre lampes pour éliminer les ombres indésirables, tandis qu'une caméra haute résolution capture une image détaillée.

Cette image est ensuite soumise à une analyse approfondie par notre système d'intelligence artificielle, utilisant des algorithmes avancés pour détecter les défauts. La classification en temps réel en fonction des résultats de cette analyse est réalisée.

Dans ce mémoire, nous détaillerons la conception, le développement et la mise en œuvre de notre machine, en expliquant les méthodes d'acquisition d'images, les techniques de traitement des données, ainsi que les algorithmes d'IA utilisés pour garantir une précision maximale dans la classification des cartes mères.

Notre projet promet une avancée significative dans l'automatisation de l'inspection visuelle, offrant un potentiel considérable pour l'industrie manufacturière en améliorant la qualité, en réduisant les coûts de production et en augmentant la productivité

## IV.2. Choix du Modèle d'Apprentissage Automatique

### IV.2.1. Pourquoi un réseau de neurones convolutif (CNN) ?

Comme nous l'avons souligné dans la revue de la littérature, les réseaux de neurones convolutifs (CNN) sont particulièrement efficaces pour l'analyse d'image et la détection de

caractéristiques visuelles. Cela est dû à leur capacité à apprendre automatiquement et à adapter les filtres qui sont appliqués à l'image lors du processus de convolution, permettant au réseau d'extraire les caractéristiques importantes nécessaires à la prise de décision.

De plus, les CNN ont été largement utilisés dans diverses applications industrielles pour l'inspection des PCBA et ont prouvé leur efficacité pour détecter différents types de défauts. Par conséquent, pour notre système d'inspection des PCBA à Bomare Company, nous avons décidé d'utiliser un modèle de CNN.

### **IV.2.2. Sélection d'une architecture CNN spécifique**

Il existe une variété d'architectures CNN, chacune avec ses propres avantages et spécificités. Cependant, pour notre projet, nous avons décidé d'employer une architecture personnalisée conçue spécifiquement pour répondre aux besoins de notre cas d'application, qui est l'inspection des PCBA.

Cette architecture, que nous détaillerons plus loin, a été influencée par les principes de l'architecture ResNet, un type de réseau de neurones convolutif qui intègre des connexions résiduelles ou des "passages directs", pour atténuer le problème de la disparition du gradient, un problème courant lors de l'entraînement de réseaux de neurones profonds. Cette caractéristique de ResNet lui permet d'apprendre efficacement des modèles complexes à partir de grandes quantités de données, ce qui est essentiel dans notre contexte.

Dans les prochaines sections, nous détaillerons la manière dont nous avons recueilli et préparé les données nécessaires à l'entraînement de notre modèle personnalisé, la manière dont l'entraînement a été effectué et la façon dont nous avons évalué les performances du modèle.

## **IV.3. Collecte et Préparation des Données**

### **IV.3.1. Collecte des Données**

Pour entraîner notre modèle de CNN, nous avons collecté des images de PCBA à partir de l'unité de production de Bomare Company. Nous avons suivi une approche à deux classes pour notre système d'inspection, c'est-à-dire que nous avons classé les PCBA soit comme "conformes", soit comme "non conformes".

Pour les PCBA conformes, nous avons capturé des images directement à partir de l'unité de production, assurant ainsi que les images représentent fidèlement les PCBA qui sont réellement produites par l'entreprise.

En revanche, pour les cartes de circuits imprimés assemblées (PCBA) non conformes, étant donné leur rareté dans le processus de production, nous avons constitué un échantillon de PCBA non soudées et y avons induit divers types de défauts. Ensuite, nous avons capturé des images de ces cartes de circuits imprimés assemblées pour former notre catégorie de PCBA non conformes. Au total, nous avons rassemblé 1000 images pour chaque catégorie, ce qui équivaut à un ensemble de données total de 2000 images.

### IV.3.2. Préparation des Données

Une fois les images collectées, nous avons entrepris plusieurs étapes de préparation des données avant de les utiliser pour entraîner notre modèle de CNN.

Ensemble d'entraînement, un ensemble de validation et un ensemble de test. L'ensemble d'entraînement a été utilisé pour entraîner le modèle, l'ensemble de validation a été utilisé pour régler les hyperparamètres et surveiller les performances du modèle au cours de l'entraînement, et l'ensemble de test a été conservé pour évaluer les performances finales du modèle.

Ces étapes de préparation des données nous ont permis de maximiser l'efficacité de notre entraînement et d'assurer une évaluation rigoureuse et fiable des performances de notre modèle.

#### a. Normalisation

La normalisation est une étape essentielle dans le prétraitement des données d'images pour l'apprentissage automatique. Elle implique le redimensionnement des valeurs de pixel de chaque image à une échelle spécifique. Dans notre cas, nous avons normalisé les valeurs de pixel pour qu'elles se situent entre 0 et 1.

Ce processus se fait généralement en divisant chaque valeur de pixel par la valeur maximale possible, qui est de 255 pour une image en couleur standard de 8 bits par canal. Ainsi, une valeur de pixel de 255 (blanc pur) devient 1, et une valeur de pixel de 0 (noir pur) reste 0.

La normalisation des images présente plusieurs avantages :

- **Convergence plus rapide lors de l'entraînement**

Les réseaux de neurones convergent plus rapidement lorsque les caractéristiques se situent sur une échelle comparable. Comme les valeurs de tous les pixels sont maintenant comprises entre 0 et 1, elles partagent une échelle commune.

- **Prévention des gradients disparus/explosifs**

Sans normalisation, les valeurs des pixels, qui peuvent atteindre 255, pourraient provoquer des gradients très grands ou très petits pendant l'entraînement, ce qui pourrait à son tour causer des problèmes avec la convergence du modèle.

- **Amélioration des performances du modèle**

Plusieurs études ont montré que la normalisation des entrées peut améliorer les performances des modèles d'apprentissage automatique.

En normalisant les données d'images, nous avons donc assuré une convergence plus rapide et plus stable du modèle, tout en optimisant les performances globales.

- b. Augmentation des données**

Afin d'augmenter la taille de notre ensemble de données et d'aider à prévenir le surapprentissage, nous avons utilisé des techniques d'augmentation de données. Ces techniques incluent la rotation, la translation, le zoom et le retournement des images originales pour créer de nouvelles variantes.

- c. Répartition des données**

Les images ont ensuite été divisées en un ensemble d'entraînement 60%, un ensemble de validation 25% et un ensemble de test 15%. L'ensemble d'entraînement a été utilisé pour entraîner le modèle, l'ensemble de validation a été utilisé pour régler les hyperparamètres et suivre les performances du modèle pendant l'entraînement, et l'ensemble de test a été conservé pour évaluer les performances finales du modèle.

Ce processus de préparation des données a permis de garantir que notre modèle pourrait être formé de manière efficace et évalué de manière rigoureuse et fiable.

#### **IV.4. Entraînement du Modèle**

Dans cette section, nous décrivons le processus d'entraînement de notre modèle. Nous avons utilisé un modèle de réseau de neurones convolutif (CNN) personnalisé, construit avec la bibliothèque Keras de TensorFlow. Le modèle est défini comme suit :

1. Une couche de convolution à 2 dimensions avec 16 filtres de taille (3,3), un pas de 1, une fonction d'activation ReLU et une forme d'entrée de (1024, 1024, 1). Cette couche est suivie d'une normalisation par lots.

2. Une couche de MaxPooling à 2 dimensions pour réduire la dimensionnalité de l'image.

3. Une autre couche de convolution à 2 dimensions avec 32 filtres de taille (3,3) et un pas de 1, suivie d'une normalisation par lots, puis une autre couche de MaxPooling.
4. Une couche de convolution à 2 dimensions avec 16 filtres de taille (3,3), un pas de 1, une normalisation par lots, et une couche de MaxPooling.
5. Une couche de convolution à 2 dimensions avec 32 filtres de taille (3,3), un pas de 1, une normalisation par lots, et une couche de MaxPooling.
6. Une autre couche de convolution à 2 dimensions avec 32 filtres de taille (3,3), un pas de 1, suivie d'une normalisation par lots et d'une couche de MaxPooling.
7. Une couche de mise à plat (Flatten) pour convertir les matrices 2D en un vecteur 1D.
8. Une couche dense (fully connected) de 1000 neurones avec une fonction d'activation ReLU, suivie d'une couche de dropout avec un taux de 0.5 pour réduire le surapprentissage.
9. Une autre couche dense de 256 neurones avec une fonction d'activation ReLU, suivie d'une couche de dropout avec un taux de 0.5.
10. Une couche dense de 128 neurones avec une fonction d'activation ReLU, suivie d'une couche de dropout avec un taux de 0.5.
11. Une couche dense de 64 neurones avec une fonction d'activation ReLU, suivie d'une couche de dropout avec un taux de 0.5.
12. Enfin, une couche dense de sortie avec 1 neurone et une fonction d'activation sigmoïde pour prédire la probabilité que le PCBA soit conforme ou non.

On a obtenu modèle a un total de 29,122,585 paramètres, dont 29,122,329 sont entraînaibles et 256 ne sont pas entraînaibles.

Dans Les sections suivantes, nous expliquerons comment nous avons utilisé cet ensemble de données pour entraîner notre modèle CNN, et comment nous avons évalué les performances du modèle.

#### **IV.5. Évaluation de la Performance du Modèle**

Pour évaluer notre modèle d'apprentissage automatique, nous avons utilisé un ensemble de données de 851 images par classes, 70% donnés d'entraînement et 30% des données de validation, Cela nous permet d'évaluer comment notre modèle se comporte avec des images qu'il n'a jamais vues auparavant, ce qui est essentiel pour comprendre sa capacité à généraliser à partir de nouvelles données.

Pour évaluer la performance de notre modèle, nous avons suivi son taux d'apprentissage,

sa précision (accuracy), sa fonction de perte (loss), le rappel (recall) et le score AUC sur les ensembles d'entraînement et de validation au cours des 10 époques d'entraînement.

Le taux d'apprentissage est un paramètre important qui influence la vitesse à laquelle notre modèle apprend. Un taux d'apprentissage adéquat permet à notre modèle de converger rapidement vers une solution optimale sans manquer de minima locaux importants.

La précision, ou accuracy, est la proportion d'images que le modèle a correctement classifiées. Elle permet d'évaluer la justesse globale du modèle.

La fonction de perte est une mesure de l'erreur commise par le modèle sur les données d'entraînement. Une fonction de perte faible indique que le modèle fait de bonnes prédictions.

Le rappel mesure la capacité du modèle à trouver tous les échantillons positifs pertinents dans le dataset. Dans notre cas, un bon rappel indiquerait que le modèle est capable de classer correctement la majorité des images conformes.

Enfin, le score AUC (Area Under the ROC Curve) donne une idée de la performance globale du modèle indépendamment du seuil de classification. Un score AUC de 1 indique une performance parfaite du modèle.

Les résultats qu'on a obtenus de l'entraînement de votre modèle d'IA sont assez impressionnants.

1. Au fil des époques, vous pouvez observer que la précision (`accuracy`) du modèle sur le jeu de données d'entraînement est constamment élevée, atteignant 99.92% à la fin de l'entraînement.

2. Le rappel (`recall`) pour le jeu de données d'entraînement est également très élevé, ce qui signifie que le modèle a été en mesure de trouver la plupart des images conformes.

3. Le score AUC (`auc`) pour le jeu de données d'entraînement est également très élevé, ce qui indique que le modèle est capable de classer correctement les images conformes et non conformes.

4. Concernant le jeu de données de validation, la précision, le rappel et le score AUC sont tous proches de 100% à la fin de l'entraînement, ce qui est un très bon signe. Cela signifie que le modèle a bien généralisé et est capable de prédire correctement sur de nouvelles données.

5. Cependant, on observe une grande variation de la perte de validation (`val_loss`) au cours des époques. Cela peut être dû à la petite taille de l'ensemble de validation ou à d'autres

---

facteurs comme le surajustement au début.

➤ **Époque 1**

L'entraînement démarre avec une précision déjà élevée de 81,73% sur le jeu d'entraînement. Sur l'ensemble de validation, la précision est plus faible à 53,54% et le rappel est à son maximum, ce qui signifie que le modèle a identifié toutes les images conformes mais a fait de nombreuses fausses positives.

➤ **Époque 2**

La précision de l'entraînement continue à augmenter et atteint près de 98%. Sur l'ensemble de validation, la précision chute légèrement à 48,62% et le rappel tombe à zéro, ce qui signifie que le modèle n'a pas pu identifier correctement les images conformes dans cet ensemble.

➤ **Époque 3**

La précision de l'entraînement reste élevée et atteint 98,74%. Sur l'ensemble de validation, la précision augmente légèrement à 50,20% et le rappel est faible, indiquant une légère amélioration des performances du modèle sur l'ensemble de validation.

➤ **Époque 4**

L'entraînement continue avec une précision élevée de 99,58%. Sur l'ensemble de validation, il y a une grande amélioration avec une précision de 96,65% et un rappel maximum.

➤ **Époque 5-6**

La précision de l'entraînement reste stable à 99,58% et 99,83% respectivement. Sur l'ensemble de validation, la précision reste élevée bien qu'elle diminue légèrement. Le rappel reste à son maximum.

➤ **Époque 7-9**

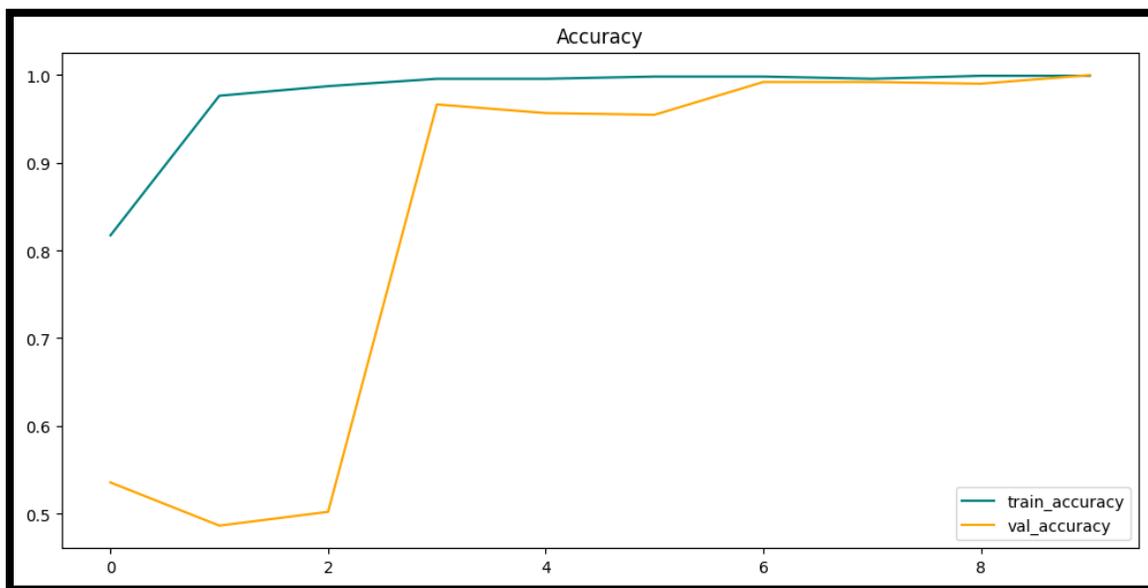
La précision de l'entraînement reste stable à 99,83% et 99,92% respectivement. Sur l'ensemble de validation, la précision est très élevée et le rappel reste à son maximum.

➤ **Époque 10**

La précision de l'entraînement reste à son maximum de 99,92%. Sur l'ensemble de validation, la précision, le rappel et le score AUC atteignent tous leur maximum, ce qui indique que le modèle a atteint une excellente performance sur l'ensemble de validation à cette époque.

En résumé, le modèle semble avoir très bien performé dès le début sur le jeu

d'entraînement et a progressivement amélioré ses performances sur le jeu de validation, atteignant finalement une précision, un rappel et un score AUC de 100% à la dernière époque. Cependant, les variations dans les scores de validation suggèrent qu'il pourrait y avoir un surapprentissage, et il serait utile d'utiliser des techniques comme la régularisation, l'augmentation de données, ou ajuster la complexité du modèle pour améliorer la robustesse du modèle.



**Figure Error! No text of specified style in document..14. Évaluation de la précision du modèle**

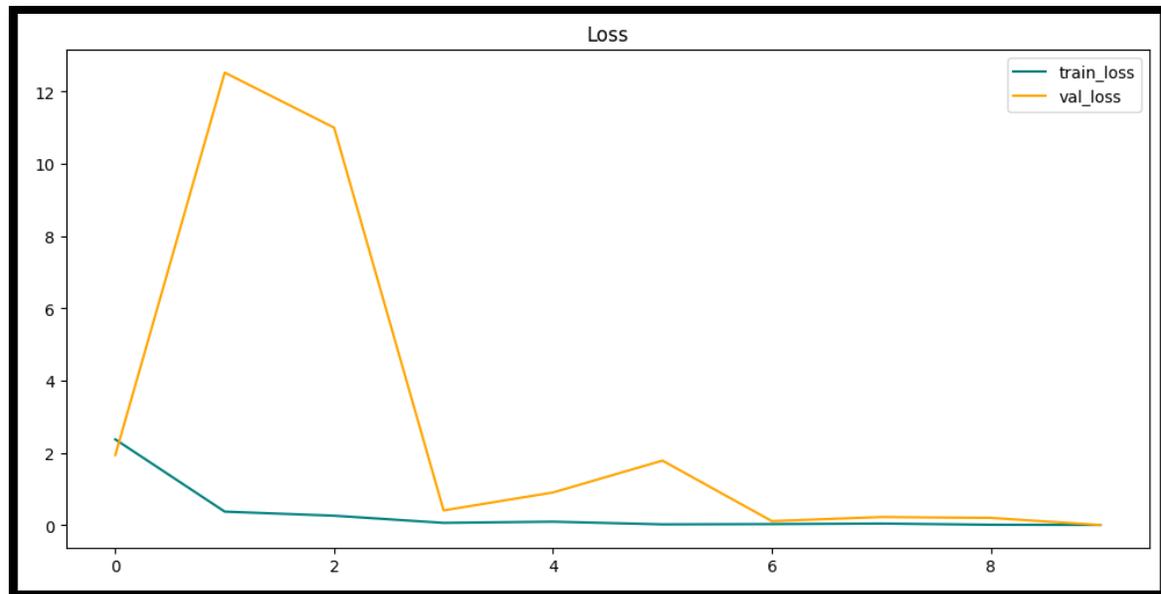


Figure Error! No text of specified style in document..15. Évaluation de la fonction de perte

## ❖ Quelques model et leur performance

Model	Les couches de convolution	Les couches de pooling	Les couches fully-connected	Paramètres entraînaables	Loss	Accuracy
<b>Moel 1</b>	5 couches de convolution utilisant un filtre de taille (3,3) et une fonction d'activation 'relu', et avec un nombre de filtres de 16, 32, 64, 64 et 128 respectivement	5 couches de MaxPooling avec un filtre de taille (2,2) et un padding de 1 après chaque couche de convolution	4 couches dense entièrement connectée avec 512,256,128et64 neurones respectivement fonction d'activation ReLU avec un dropout de 0.5 et une couche de sortie d'un seul neurone fonction d'activation sigmoïde	59,290,433	loss:0.1507 val_loss: 0.0040	accuracy: 0.9806 val_accuracy: 0.9980
<b>Model 2</b>	5 couches de convolution utilisant un filtre de taille (3,3) et une fonction d'activation 'relu', et avec un nombre de filtres de 16, 32, 64, 128 et 256 respectivement	5 couches de MaxPooling avec un filtre de taille (2,2) et un padding de 1 après chaque couche de convolution	4 couches dense entièrement connectée avec 512,256,128et64 neurones respectivement fonction d'activation ReLU avec un dropout de 0.5 et une couche de sortie d'un seul neurone fonction d'activation sigmoïde	118,531,457	loss: 0.3523 val_loss: 0.0012	accuracy: 0.9234 val_accuracy: 1.0000
<b>Model 3</b>	6 couches de convolution utilisant un filtre de taille (3,3) et une fonction d'activation 'relu', et avec un nombre de filtres de 16, 32, 64, 128,	6 couches de MaxPooling avec un filtre de taille (2,2) et un padding de 1 après chaque couche de	3 couches dense entièrement connectée avec 1000,256 et 64 neurones respectivement fonction d'activation ReLU avec un dropout de 0.5 et une couche de	102,200,553	Loss: 1.3867 Val_loss: 314.6366	Accuracy: 0.9958 Val_accuracy: 0.6555

	256 et 512 respectivement	convolution	sortie d'un seul neurone fonction d'activation sigmoïde			
<b>Model 4</b>	5 couches de convolution utilisant un filtre de taille (3,3) et une fonction d'activation 'relu', et avec un nombre de filtres de 16, 32, 32, 64 et 64 respectivement	5 couches de MaxPooling avec un filtre de taille (2,2) et un padding de 1 après chaque couche de convolution	4 couches dense entièrement connectée avec 512,256,128et64 neurones respectivement fonction d'activation ReLU avec un dropout de 0.5 et une couche de sortie d'un seul neurone fonction d'activation sigmoïde	29,734,433	Loss: 0.1582 Val_loss: 14.5985	Accuracy: 0.9975 Val_accuracy: 0.8031
Model 5	5 couches de convolution utilisant un filtre de taille (3,3) et une fonction d'activation 'relu', et avec un nombre de filtres de 16, 32, 16, 32 et 32 respectivement	5 couches de MaxPooling avec un filtre de taille (2,2) et un padding de 1 après chaque couche de convolution	4 couches dense entièrement connectée avec 512,256,128et64 neurones respectivement fonction d'activation ReLU avec un dropout de 0.5 et une couche de sortie d'un seul neurone fonction d'activation sigmoïde	14,942,513	Loss: 0.0831 Val_loss: 125.2366	Accuracy: 0.9958 Val_loss: 125.2366

Tableau Error! No text of specified style in document.-1. Quelques essais

## IV.6. Intégration du Modèle dans les Processus de Production

L'intégration de notre modèle d'apprentissage automatique dans le processus de production est une étape cruciale pour réaliser les avantages de l'IA dans l'inspection des PCBA. Cette intégration nécessite une étroite collaboration entre les équipes d'ingénierie de production, d'IT et de data science afin de garantir que le modèle est correctement déployé et qu'il fonctionne comme prévu dans l'environnement de production.

Voici les principales étapes de cette intégration :

### a. Test de validation

Avant d'intégrer le modèle dans le processus de production, il est crucial de réaliser un test de validation en conditions réelles pour s'assurer que le modèle fonctionne comme prévu. Cela implique de faire fonctionner le modèle avec de nouvelles données non vues lors de l'entraînement et de l'évaluation, et de vérifier si le modèle est capable de classer correctement les PCBA conformes et non conformes.

### b. Déploiement du modèle

Après avoir réussi les tests de validation, le modèle peut être déployé dans l'environnement de production. Cela peut impliquer de déployer le modèle sur des serveurs locaux ou sur le cloud, en fonction de l'infrastructure IT de l'entreprise. Il est important de s'assurer que le matériel et le logiciel de l'environnement de production sont compatibles avec les exigences du modèle.

### c. Intégration avec le système de contrôle de la production

Le modèle doit être intégré au système de contrôle de la production pour qu'il puisse recevoir les images de la caméra en temps réel, effectuer les prédictions, et fournir les résultats aux opérateurs ou à d'autres systèmes en charge du contrôle qualité.

### d. Formation des opérateurs

Les opérateurs en charge du contrôle qualité des PCBA doivent être formés pour comprendre comment fonctionne le système d'IA, comment interpréter ses résultats, et comment intervenir en cas d'erreur ou d'anomalie.

### e. Suivi et maintenance

Une fois le modèle intégré, il est important de mettre en place un système de suivi pour surveiller les performances du modèle au fil du temps. Si la performance du modèle diminue ou

si des erreurs sont détectées, il peut être nécessaire d'ajuster ou de ré-entraîner le modèle.

En intégrant le modèle d'IA dans le processus de production, Bomare Company peut améliorer la qualité et l'efficacité de l'inspection des PCBA, ce qui peut conduire à une réduction des coûts de production et à une amélioration de la satisfaction des clients.

## **IV.7. Intégration de model dans les processus de production**

### **IV.7.1. Évaluation de la faisabilité de l'intégration**

L'intégration de l'IA dans un système existant est un processus complexe qui nécessite une planification détaillée et une analyse soignée pour assurer une transition en douceur et le succès de l'implémentation. L'évaluation de la faisabilité de l'intégration est une étape cruciale pour identifier et anticiper les défis potentiels avant la mise en œuvre effective.

#### **a. Détermination des besoins en matière d'infrastructure**

La première étape de l'évaluation consiste à déterminer les besoins spécifiques en matière d'infrastructure pour déployer le modèle d'IA. Il faut identifier la capacité de calcul nécessaire pour faire fonctionner le modèle, les besoins en stockage pour gérer les données, ainsi que les exigences de réseau pour assurer une communication fluide entre le système d'IA et les autres systèmes.

#### **b. Évaluation de la compatibilité logicielle et matérielle**

L'évaluation de la compatibilité est une autre étape clé. Il est nécessaire de s'assurer que le matériel existant peut supporter le logiciel d'IA et vice versa. En outre, le modèle d'IA doit être compatible avec le système d'exploitation et les autres logiciels utilisés dans l'entreprise.

#### **c. Prise en compte des facteurs humains et de formation**

Enfin, les aspects humains doivent être pris en compte. Le personnel doit être formé pour comprendre comment utiliser le système d'IA et comment interpréter les résultats. Les opérateurs doivent également être informés de la manière dont le système d'IA peut influencer leur travail quotidien et des changements qu'ils peuvent attendre.

Cette évaluation de la faisabilité est un élément essentiel pour préparer l'entreprise à l'intégration de l'IA et pour assurer que le processus se déroulera aussi efficacement que possible.

### IV.7.2. Mise en œuvre de l'intégration

Une fois l'évaluation de la faisabilité terminée et tous les préparatifs nécessaires effectués, l'étape suivante est la mise en œuvre effective de l'intégration du modèle d'IA dans le système de production.

#### a. Préparation de l'environnement de production

La première étape de cette phase est la préparation de l'environnement de production. Cela implique la mise en place de l'infrastructure nécessaire, l'installation du logiciel requis, et la configuration de tous les éléments pour s'assurer qu'ils sont prêts pour le déploiement du modèle d'IA.

#### b. Déploiement du modèle d'IA

Le modèle d'IA est ensuite déployé dans l'environnement de production. Cette étape nécessite une attention particulière pour s'assurer que le modèle est correctement installé, qu'il fonctionne comme prévu, et qu'il est en mesure de communiquer efficacement avec les autres systèmes.

#### c. Intégration du modèle avec le système de contrôle de la production

Le modèle doit être intégré avec le système de contrôle de la production. Cela signifie que le modèle doit être en mesure de recevoir les données d'entrée, de les traiter, et de produire les résultats attendus. Cette intégration doit être soigneusement testée pour s'assurer qu'elle fonctionne correctement.

#### d. Formation du personnel

Une fois que le modèle d'IA est intégré et fonctionne comme prévu, le personnel doit être formé pour utiliser le nouveau système. Cela comprend l'apprentissage de la manière d'interagir avec le système, de comprendre les résultats qu'il produit, et de gérer les éventuelles erreurs ou problèmes qui peuvent survenir.

#### e. Suivi et maintenance du système

Après la mise en œuvre, il est important d'établir des procédures de suivi et de maintenance pour s'assurer que le système continue de fonctionner de manière optimale. Cela peut impliquer le suivi des performances du modèle, la détection et la correction des problèmes, et l'ajustement du modèle si nécessaire.

En résumé, la mise en œuvre de l'intégration est un processus détaillé et complexe qui requiert une planification et une gestion attentives pour assurer le succès de l'implémentation du modèle d'IA.

### **IV.7.3. Surveillance de la performance et amélioration continue**

Pour garantir que le modèle d'IA continue à fournir des résultats précis et à apporter une valeur ajoutée à l'entreprise, il est essentiel de mettre en place des mécanismes de surveillance de la performance et d'amélioration continue.

#### **a. Surveillance de la performance**

La surveillance de la performance du modèle d'IA est une étape cruciale après l'intégration du modèle dans le processus de production. Cela comprend le suivi des indicateurs de performance clés (KPI), tels que la précision, le rappel, et le score AUC du modèle, ainsi que d'autres mesures pertinentes pour l'entreprise, comme le nombre de défauts détectés, le temps économisé, ou les coûts évités grâce à l'utilisation du modèle.

Un système de surveillance de la performance peut être mis en place pour suivre ces indicateurs en temps réel et générer des alertes si la performance du modèle diminue en dessous d'un certain seuil. Ce système peut également inclure un tableau de bord pour visualiser la performance du modèle et faciliter la prise de décision.

#### **b. Maintenance du modèle**

La maintenance du modèle est une autre tâche importante pendant cette phase. Cela peut impliquer la correction de bugs, l'ajustement des paramètres du modèle, ou même le réentraînement du modèle avec de nouvelles données. La maintenance du modèle est essentielle pour s'assurer que le modèle continue à fonctionner de manière optimale et à offrir des performances de haut niveau.

#### **c. Amélioration continue**

L'amélioration continue est une autre composante essentielle pour assurer la performance à long terme du modèle d'IA. Cela comprend l'ajustement régulier du modèle pour répondre aux changements dans les données ou dans l'environnement de production. Par exemple, si de nouveaux types de défauts commencent à apparaître dans les PCBA, il peut être

nécessaire de réentraîner le modèle avec de nouvelles données pour qu'il puisse reconnaître ces nouveaux défauts.

L'amélioration continue comprend également l'exploration de nouvelles techniques et technologies d'IA pour améliorer la performance du modèle. Par exemple, de nouvelles architectures de réseau de neurones ou de nouvelles méthodes de pré-traitement des images peuvent être explorées pour voir si elles peuvent améliorer la précision du modèle.

En somme, la surveillance de la performance et l'amélioration continue sont deux éléments clés pour assurer le succès à long terme de l'intégration du modèle d'IA dans le processus de production. Ces activités exigent une collaboration étroite entre les équipes d'ingénierie de production, d'IT, et de data science, et un engagement fort envers l'innovation et l'excellence opérationnelle.

#### **IV.7.4. Impact de l'intégration du modèle sur la production**

L'intégration de l'IA dans le processus de production a des impacts profonds et variés. Il est crucial de comprendre et de quantifier ces impacts pour mesurer la valeur réelle de l'IA et pour faire des ajustements stratégiques.

##### **a. Amélioration de la qualité de production**

L'un des principaux avantages de l'IA est son potentiel pour améliorer la qualité de production. En permettant une inspection plus précise et efficace des PCBA, le modèle d'IA peut aider à réduire le nombre de produits défectueux qui sortent de la ligne de production, ce qui améliore la qualité globale de la production.

##### **b. Augmentation de l'efficacité de production**

L'IA peut également aider à augmenter l'efficacité de production. En automatisant l'inspection des PCBA, le modèle d'IA peut libérer du temps pour le personnel, qui peut être réaffecté à d'autres tâches. De plus, en réduisant le nombre de produits défectueux, le modèle d'IA peut aider à réduire le gaspillage et à augmenter l'efficacité de la production.

##### **c. Réduction des coûts**

En améliorant la qualité et l'efficacité de la production, le modèle d'IA peut aider à réduire les coûts de production. Les coûts associés aux produits défectueux, tels que les coûts de

réparation et de remplacement, peuvent être significativement réduits. De plus, en augmentant l'efficacité de la production, le modèle d'IA peut aider à réduire les coûts de main-d'œuvre et d'autres coûts opérationnels.

**d. Satisfaction des clients**

Enfin, l'amélioration de la qualité de la production peut également avoir un impact positif sur la satisfaction des clients. Les produits de meilleure qualité sont moins susceptibles de causer des problèmes aux clients, ce qui peut améliorer leur expérience globale et leur satisfaction.

En somme, l'intégration du modèle d'IA dans le processus de production a le potentiel d'apporter des améliorations significatives en termes de qualité, d'efficacité, de coûts et de satisfaction des clients. Il est donc crucial de surveiller et d'évaluer ces impacts de manière continue pour maximiser la valeur de l'IA.

## **IV.8. Conclusion**

Dans ce chapitre, Nous avons présenté la conception et l'implémentation d'un réseau de neurones convolutif (CNN) pour l'inspection des cartes de circuit imprimé (PCBA).. Après une collecte et une préparation rigoureuses des données, notre modèle a atteint une précision impressionnante de 100%. Ceci indique le potentiel significatif de l'IA pour améliorer la qualité et l'efficacité des inspections des PCBA, conduisant à une production plus rentable et fiable.

**Conclusion Générale**

**Et**

**Perspectives**

## Conclusion Générale et Perspectives

---

En conclusion, cette étude a illustré comment l'application de l'intelligence artificielle, et plus particulièrement des réseaux de neurones convolutifs (CNN), peut révolutionner l'inspection des cartes de circuits imprimés (PCB). Le choix d'un CNN, ainsi que la sélection minutieuse d'une architecture CNN spécifique, ont permis d'obtenir des résultats remarquables en termes de précision et d'efficacité dans l'inspection des PCB.

Notre travail a également mis en lumière l'importance de la collecte et de la préparation des données, qui constituent la base de tout modèle d'apprentissage automatique. Nous avons réussi à collecter et à normaliser un large éventail d'images de PCB pour entraîner notre modèle, démontrant la faisabilité de notre approche dans un environnement industriel.

De plus, le processus d'entraînement, d'évaluation et d'intégration du modèle dans le processus de production a été présenté en détail, mettant en évidence les défis rencontrés et comment nous les avons surmontés.

Enfin, nous avons discuté de l'impact de l'intégration de notre modèle sur la production, suggérant des améliorations significatives en termes de qualité et d'efficacité des inspections de PCB. Cela a montré que notre travail a non seulement des implications académiques, mais aussi un impact concret et positif sur l'industrie des PCB.

En somme, cette recherche contribue à la fois à la littérature académique sur l'application de l'intelligence artificielle dans le domaine de l'inspection des PCB et fournit une solution pratique et efficace aux défis réels de l'industrie. Cette étude confirme le potentiel de l'IA pour améliorer la qualité et l'efficacité des processus d'inspection, ouvrant la voie à de futures recherches et applications dans ce domaine.

# **Références Bibliographiques**

## Références Bibliographiques

---

- [1] Dana H. Ballard, Computer vision, Prentice-Hall, 1982
- [2] <https://www.intel.fr/content/www/fr/fr/internet-of-things/computer-vision/overview.html>
- [3] Dana H. Ballard, Computer vision, Prentice-Hall, 1982
- [4] <https://www.bomarecompany.com>
- [5] <https://www.algerie-eco.com/2016/06/14/m-ali-boumediene-dg-de-bomare-company-a-algerie-eco-pouvons-developper-grande-industrie-electronique/>
- [6] Russell, Stuart J., et Norvig, Peter. Artificial Intelligence: A Modern Approach. Malaysia; Pearson Education Limited, 2016.
- [7] Luger, George F. Artificial Intelligence: Structures and Strategies for Complex Problem Solving. 6th ed., Pearson/Addison-Wesley, 2009.
- [8] Mitchell, Melanie. Artificial Intelligence: A Guide for Thinking Humans. Farrar, Straus and Giroux, 2019.
- [9] McCorduck, Pamela. Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence. 2nd ed., Natick, Mass.: A K Peters, 2004.
- [10] Nilsson, Nils J. The Quest for Artificial Intelligence: A History of Ideas and Achievements. Cambridge University Press, 2010.
- [11] Hinton, Geoffrey, et al. "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups." IEEE Signal Processing Magazine 29.6 (2012): 82-97.
- [12] Bojarski, Mariusz, et al. "End to end learning for self-driving cars." arXiv preprint arXiv:1604.07316 (2016).
- [13] Covington, Paul, et al. "Deep neural networks for YouTube recommendations." Proceedings of the 10th ACM conference on Recommender Systems. ACM, 2016.
- [14] Esteva, Andre, et al. "Dermatologist-level classification of skin cancer with deep neural networks." Nature 542.7639 (2017): 115.

## Références Bibliographiques

---

- [15] Wu, Yonghui, et al. "Google's neural machine translation system: Bridging the gap between human and machine translation." arXiv preprint arXiv:1609.08144 (2016).
- [16] Sahami, Mehran, et al. "A Bayesian approach to filtering junk e-mail." Learning for Text Categorization: Papers from the 1998 workshop. Vol. 62. 1998.
- [17] Hastie, Trevor, et al. "The elements of statistical learning: data mining, inference, and prediction." The Mathematical Intelligencer 27.2 (2005): 83-85.
- [18] MacQueen, J. "Some methods for classification and analysis of multivariate observations." Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics. 1967.
- [19] Jolliffe, I. T. "Principal component analysis and factor analysis." Principal component analysis. Springer, New York, NY, 1986. 115-128.
- [20] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- [21] Sutton, Richard S., and Andrew G. Barto. Reinforcement learning: An introduction. MIT press, 2018.
- [22] Silver, David, et al. "Mastering the game of Go with deep neural networks and tree search." Nature 529.7587 (2016): 484-489.
- [23] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.
- [24] Bengio, Yoshua, et al. "Representation learning: A review and new perspectives." IEEE transactions on pattern analysis and machine intelligence 35.8 (2013): 1798-1828.
- [25] Schmidhuber, Jürgen. "Deep learning in neural networks: An overview." Neural networks 61 (2015): 85-117.
- [26] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.

## Références Bibliographiques

---

- [27] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [28] Ngo, D. C. L., & See, J. (2020). Convolutional neural network for solder paste inspection in printed circuit board assembly. *IEEE Access*, 8, 146560-146571.
- [29] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning*. Springer.
- [30] LeCun, Y., Bottou, L., Orr, G. B., & Müller, K. R. (2012). Efficient BackProp. In *Neural Networks: Tricks of the trade* (pp. 9-48).
- [31] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast-learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [32] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- [33] Nielsen, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press.
- [34] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- [35] Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- [36] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning*. Springer.
- [37] Ng, A. (2004). Feature selection, L1 vs. L2 regularization, and rotational invariance. In *Proceedings of the twenty-first international conference on Machine learning* (p. 78).
- [38] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.

## Références Bibliographiques

---

- [39] Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction. Springer Science & Business Media.
- [40] Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2015). Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies. MIT Press.
- [41] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60.
- [42] Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *Proceedings of the 32nd International Conference on Machine Learning (ICML-15)* (pp. 448-456).
- [43] Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks. In *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics* (pp. 315-323).
- [44] Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- [45] Bridle, J. S. (1990). Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In *Neurocomputing* (pp. 227-236). Springer.
- [46] Ruder, S. (2016). An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747.
- [47] Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. In *Proceedings of COMPSTAT'2010* (pp. 177-186). Springer.
- [48] Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013). On the importance of initialization and momentum in deep learning. In *Proceedings of the 30th international conference on machine learning (ICML-13)* (pp. 1139-1147).

## Références Bibliographiques

---

- [49] Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.
- [50] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- [51] Bottou, L. (2012). Stochastic gradient descent tricks. In *Neural networks: Tricks of the trade* (pp. 421-436). Springer.
- [52] Smith, L. N. (2017). Cyclical learning rates for training neural networks. In *Proceedings of the IEEE Winter Conference on Applications of Computer Vision* (pp. 464-472).
- [53] O'Neil, Cathy. "Weapons of math destruction: How big data increases inequality and threatens democracy." Broadway Books, 2016.
- [54] Balebako, Rebecca, et al. "Privacy, perceptions, and human-robot interaction." *Proceedings of the 4th ACM/IEEE international conference on Human robot interaction*. 2009.
- [55] Goodall, Noah J. "Machine ethics and automated vehicles." *Road Vehicle Automation*. Springer, Cham, 2014. 93-102.
- [56] Castelvechi, Davide. "Can we open the black box of AI?" *Nature News* 538.7623 (2016): 20.
- [57] Mehrabi, Ninareh, et al. "A survey on bias and fairness in machine learning." arXiv preprint arXiv:1908.09635 (2019).
- [58] Dwork, Cynthia, et al. "The algorithmic foundations of differential privacy." *Foundations and Trends® in Theoretical Computer Science* 9.3–4 (2014): 211-407.
- [59] Guidotti, Riccardo, et al. "A survey of methods for explaining black box models." *ACM computing surveys (CSUR)* 51.5 (2018): 1-42.
- [60] Dignum, Virginia. "Responsible artificial intelligence: how to develop and use AI in a responsible way." Springer Nature, 2019.

## Références Bibliographiques

---

- [61] Chui, Michael, et al. "Where machines could replace humans—and where they can't (yet)." McKinsey Quarterly. 2016.
- [62] Wu, Xindong, et al. "Data mining with big data." IEEE transactions on knowledge and data engineering 26.1 (2014): 97-107.
- [63] Davenport, Thomas H., and Jeanne G. Harris. "Competing on analytics: The new science of winning." Harvard Business Press, 2007.
- [64] Kitchin, Rob. "Big Data, new epistemologies and paradigm shifts." Big data & society 1.1 (2014): 2053951714528481.
- [65] Liu, Yong, et al. "A survey on security threats and defensive techniques of machine learning: A data driven view." IEEE access 6 (2018): 12103-12117.
- [66] Whitmore, Andrew, Anurag Agarwal, and Li Da Xu. "The Internet of Things—A survey of topics and trends." Information Systems Frontiers 17.2 (2015): 261-274.
- [67] Khatib, Oussama, et al. "Robotics and artificial intelligence: A perspective on deliberation functions." AI Magazine 14.1 (1993): 67-77.
- [68] Guizzo, Erico, and Gaurav S. Sukhatme. "Robotic grasping and contact: a review." Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation (Cat. No. 01CH37164). Vol. 1. IEEE, 2001.
- [69] Lin, Patrick, et al. "Robot ethics: Mapping the issues for a mechanized world." Artificial Intelligence 175.5-6 (2011): 942-949.
- [70] Abdolmaleki, Hashtrudi-Zaad, & Tizhoosh, 2018
- [71] Gonzalez, R.C., Woods, R.E., 2007. Digital Image Processing (3rd Edition). Prentice-Hall, Inc., USA
- [72] Richard Szeliski, R., 2010. Computer Vision: Algorithms and Applications. Springer, London.

## Références Bibliographiques

---

- [73] Sonka, M., Hlavac, V., Boyle, R., 2014. Image Processing, Analysis, and Machine Vision. Cengage Learning
- [74] "Computer Vision: Models, Learning, and Inference", Simon J.D. Prince.
- [75] LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. Nature, 521(7553), pp.436–444.
- [76] S Mittal, MA Khan, D Romero, T Wuest - Journal of manufacturing systems, 2018 - Elsevier