



الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

– المدرسة الوطنية العليا للتكنولوجيا والهندسة – عنابة

ECOLE NATIONALE SUPERIEURE DE TECHNOLOGIE ET D'INGENIERIE – ANNABA

Département Génie Industriel

MEMOIRE

En vue d'obtention du diplôme d'INGÉNIEUR D'ETAT

Domaine : Science et Technologie

Filière : Génie Industriel

Spécialité : Maintenance et Fiabilité des Systèmes Industriels

Présenté par

MOUSSAOUI FADI ABDERAHMANE

APPLICATION DE L'APPRENTISSAGE AUTOMATIQUE POUR L'ANALYSE DES DONNÉES CND ET L'OPTIMISATION DES INSPECTIONS

Encadré par

Dr. AYAD Amar

ENSTI Annaba

Membres du jury :

Dr. Nour Elislem KARABADJI

Président

ENSTI Annaba

Dr. Nouredine KHELIFA

Examineur

ENSTI Annaba

Dr. Salim KEBIR

Examineur

ENSTI Annaba

Remerciement

Je tiens à exprimer ma gratitude envers les nombreuses personnes qui ont contribué à la réalisation de ce mémoire. Leur expertise et leur encouragement ont été essentiels pour mener à bien ce projet.

Je tiens tout d'abord de remercier à la fois l'ingénieur DJENDEL Mahmoud et l'ingénieur KELKOULI Mourad, qui ont participé activement à mon étude, sans lesquels cette recherche n'aurait pas été possible. Leur contribution a été inestimable, de même que celle de tout le personnel qui a facilité mes recherches en mettant à ma disposition les ressources nécessaires.

Je tiens à remercier aussi mon encadreur, M. AYAD Amar, pour sa guidance précieuse tout au long de cette aventure.

Je n'oublie pas non plus de remercier mes amis et ma famille pour Votre encouragement constant m'a motivée à persévérer, même dans les moments difficiles.

Merci à tous ceux qui ont joué un rôle dans la réalisation de ce mémoire

Dédicaces

À ceux qui m'ont encouragé et soutenu moralement et matériellement pendant les moments les plus difficiles de ma vie :

Je tiens à exprimer ma profonde gratitude envers ma très chère mère et mon père, qui m'ont toujours apporté la paix de vivre et n'ont jamais cessé de prier pour moi.

À mes très chers frères et à mes très chères sœurs, votre soutien a été inestimable. Vous avez été mes piliers dans les moments de doute et de découragement.

À toute ma grande famille, je vous remercie pour votre amour inconditionnel et votre présence constante.

À mes très chers amis, vos encouragements et votre amitié ont illuminé mes journées les plus sombres.

Enfin, à toutes mes connaissances, je vous adresse mes vœux de gratitude. Votre présence dans ma vie a été précieuse.

MOUSSAOUI Fadi

Résumé

Résumé : L'inspection par ressuage fluorescent (FPI) est une méthode de contrôle non destructive utilisée pour détecter les défauts sur les pièces. Cette revue vise à démontrer l'efficacité d'un système d'inspection automatisé basé sur la vision pour automatiser l'étape d'inspection du processus FPI. L'étude évalue plusieurs architectures de Machine Learning pour la détection automatisée des défauts, en utilisant des photos prises sous différents angles pour créer un ensemble de données complet. Le système, conçu pour réduire la charge de travail des opérateurs humains, utilise l'intelligence artificielle pour améliorer la fiabilité des tests sur les pièces. Les résultats montrent que l'extraction de caractéristiques avant l'utilisation d'un classificateur d'apprentissage automatique est essentielle pour obtenir une classification précise, surtout avec un ensemble de données limité.

Mots clés : Inspection par ressuage fluorescent, intelligence artificielle, Machine Learning

Abstract: Fluorescent Penetrant Inspection (FPI) is a non-destructive testing method used to detect defects in parts. This review aims to demonstrate the effectiveness of an automated vision-based inspection system to automate the inspection step of the FPI process. The study evaluates several machine learning architectures for automated defect detection, using photos taken from different angles to create a comprehensive dataset. The system, designed to reduce the workload of human operators, employs artificial intelligence to enhance the reliability of tests on parts. The results show that feature extraction before using a machine learning classifier is essential for achieving accurate classification, especially with a limited dataset.

Keywords: Fluorescent Penetrant Inspection, Artificial Intelligence, Machine Learning

ملخص : التفتيش بواسطة الرشوة الفلورية (FPI) هو طريقة للتحكم غير التدميري تُستخدم لاكتشاف العيوب في الأجزاء. تهدف هذه المراجعة إلى إثبات فعالية نظام تفتيش آلي يعتمد على الرؤية لأتمتة خطوة التفتيش في عملية FPI. تقم الدراسة العديد من هياكل التعلم الآلي للكشف الآلي عن العيوب، باستخدام صور مأخوذة من زوايا مختلفة لإنشاء مجموعة بيانات شاملة. النظام، المصمم لتقليل عبء العمل على المشغلين البشريين، يستخدم الذكاء الاصطناعي لتحسين موثوقية الاختبارات على الأجزاء. تُظهر النتائج أن استخراج الميزات قبل استخدام المصنف التعلم الآلي أمر أساسي لتحقيق تصنيف دقيق، خاصةً مع مجموعة بيانات محدودة.

الكلمات المفتاحية: لتفتيش بواسطة الرشوة الفلورية، الذكاء الاصطناعي، التعلم الآلي

Liste des figures et tableaux

Figure 1 : Organigramme général du FPI.....	14
Figure 2 : Organigramme d'automatisation FPI	14
Figure 3 : Première architecture système (de base) analysée par un réseau de neurones....	15
Figure 4 : Deuxième architecture du système pour l'identification des taches.....	16
Figure 5 : Architecture du classificateur de points directs	17
Figure 6 : Architecture du classificateur de points indirects	17
Figure 7 : Échantillons prélevés à partir de l'ensemble de données disponible.....	19
Figure 8 : Division de l'ensemble de données	20
Figure 9 : Courbes de convergence d'entraînement et de test direct	22
Figure 10 : Évolution des performances du meilleur réseau neuronal obtenu à partir des 25 essais indépendants	22
Figure 11 : Courbes de convergence d'entraînement et de test indirect	23
Figure 12 : Évolution des performances du meilleur réseau neuronal obtenu à partir de 25 essais indépendants	24
Figure 13 : Exemples de classification.....	26
Tableau 1 : Nombre d'échantillons dans l'ensemble de données considéré.....	20

Table des matières

Remerciement.....	1
Dédicaces.....	3
Résumé.....	4
Liste des figures et tableaux.....	5
Table des matières.....	6
INTRODUCTION GENERALE	8
CHAPITRE 1 : Aperçu générale sur l’IA et le ML.....	10
1- Intelligence artificielle et apprentissage automatique.....	10
1-1. Concepts fondamentaux de l’IA et du Machine Learning.....	10
1-2. Techniques d’apprentissage.....	10
2. Apprentissage non supervisé	10
3. Apprentissage par renforcement	10
1-3. Applications Industrielles de l’IA et du ML.....	10
2- Application du ML au CND	11
2-1. Travaux de recherche et solutions existantes.....	11
2-2. Techniques de ML pour la détection de défauts.....	11
2-2.1 Détection de défauts.....	11
2-2.2 Classification des matériaux	11
2-3. Avantages de l'Utilisation du ML.....	11
2-4. Défis.....	11
3- Revue des études théoriques et des solutions existantes dans la littérature scientifique.....	12
3-1. Méthodes et techniques de contrôle non destructif	12
3-1.1 Revue des principales méthodes de CND utilisées dans l’industrie :.....	12
3-1.2 Description des types de données générées par les techniques de CND : ..	12
3-1.3 Défis et limites de l’analyse traditionnelle des données de CND :	12

3-2.	Modèles d'apprentissage automatique pour l'analyse des données de CND .	12
3-2.1	Sélection des algorithmes d'apprentissage automatique adaptés à l'analyse des données de CND :	12
3-2.2	Développement de modèles de prédiction de défauts basés sur les données de CND :	12
3-2.3	Utilisation de l'apprentissage automatique pour l'optimisation des procédures d'inspection et de maintenance :	13
CHAPITRE 2 : Solutions adoptées		14
1-	Système automatisé (FPI)	14
2-	Techniques d'apprentissage automatique pour l'identification des taches.....	16
2-1.	Classificateur de spot direct.....	16
2-2.	Classificateur de spot indirect.....	17
3-	Incrustation stochastique des voisins distribués en t (t-DSNE).....	18
Chapitre 3 : Evaluation des solutions adoptées		21
1-	Classificateur de taches direct.....	21
2-	Classifieur de taches indirectes	23
3-	Validation et Comparaison des Résultats.....	25
4-	Comparaison avec les méthodes traditionnelles d'analyse	25
Conclusion générale et perspectives		27
Bibliographie		28

INTRODUCTION GENERALE

Avec l'avènement de l'industrie 4.0, l'intégration de l'intelligence artificielle (IA) et de l'apprentissage automatique (ML) transforme les processus industriels, notamment en améliorant la qualité et l'efficacité des essais non destructifs (END). Ces technologies assurent l'intégrité des matériaux et des structures sans les endommager, chose cruciale pour la sécurité et la fiabilité.

ANABIB, un leader dans la fabrication de tuyauterie métallique, vise à intégrer la ML à l'analyse des données de contrôle non destructif (CND) pour optimiser ses procédures d'inspection. La ML, une branche de l'IA, utilise des algorithmes avancés pour analyser de vastes ensembles de données et en extraire des informations précieuses. Cela permet de reconnaître des modèles complexes et de détecter des anomalies que les méthodes traditionnelles pourraient manquer.

Cette revue examine l'application de la ML à différents types de données CND, telles que les images ultrasoniques, les balayages térahertz et les résultats de contrôle par ressuage. Ces techniques permettent une détection plus précise des défauts, essentielle pour prévenir les défaillances matérielles.

En mettant en œuvre la ML dans les procédures CND, les entreprises comme ANABIB peuvent améliorer la précision et la rapidité de leurs tests, augmentant ainsi la productivité et réduisant les coûts. De plus, la ML peut contribuer à la maintenance prédictive en analysant les données historiques pour identifier les défauts potentiels avant qu'ils ne causent des problèmes majeurs. Les techniques traditionnelles de CND ont des limites en termes de précision et d'efficacité, que l'IA peut surmonter en révolutionnant ce domaine.

Les algorithmes d'IA peuvent analyser de grandes quantités de données et faire des prédictions basées sur des modèles difficiles à détecter pour les humains. L'apprentissage automatique (ML), un sous-ensemble de l'IA, est particulièrement utile pour le CND, car il apprend des données passées pour améliorer la précision et l'efficacité des futurs tests.

Un des algorithmes d'IA populaires en CND est la machine à vecteurs de support (SVM), qui sépare les données en différentes catégories. Les forêts aléatoires utilisent plusieurs arbres de décision pour améliorer la précision de la classification et de la prédiction.

Le choix de l'algorithme dépend de l'application spécifique du CND. Par exemple, les réseaux neuronaux sont idéaux pour l'analyse d'images, tandis que les SVM sont efficaces pour la classification de données avec un grand nombre de dimensions.

Le développement des méthodes de CND a énormément progressé, et avec les technologies avancées, leur champ d'application s'est élargi. Les tendances récentes incluent des systèmes CND plus intelligents et autonomes, capables d'apprendre et de s'adapter en permanence pour de meilleures performances.

Ces systèmes intelligents utilisent des algorithmes d'IA et de ML pour analyser les données d'inspection. Ils identifient des modèles et des anomalies non visibles à l'œil nu, détectant ainsi les défauts des matériaux et des structures avec plus de précision et de rapidité, améliorant ainsi l'efficacité des inspections, réduisant ainsi le risque d'erreurs et économisant du temps et des ressources. Ils peuvent également être déployés dans des environnements dangereux ou inaccessibles.

Malgré les avancées en CND et l'expertise humaine à maîtriser des systèmes complexes, l'erreur humaine reste une réalité. Les technologies évoluent rapidement, mais la faillibilité humaine persiste. Les algorithmes sophistiqués visent à prédire et prévenir les erreurs, mais les humains, sujets à la fatigue et aux erreurs de jugement, restent une variable imprévisible. Cela soulève des questions sur la dépendance à la technologie et l'équilibre entre collaboration homme-machine, nécessitant des mesures pour atténuer les conséquences de nos limites.

Le développement de systèmes CND intelligents et autonomes est crucial pour améliorer la qualité et la fiabilité des inspections. Ces systèmes permettent aux industries d'assurer la sécurité et l'intégrité de leurs actifs tout en réduisant les coûts et les temps d'arrêt. À mesure que la technologie évolue, des systèmes CND encore plus avancés continueront de repousser les limites du possible dans ce domaine.

CHAPITRE 1 : Aperçu générale sur l'IA et le ML

1- Intelligence artificielle et apprentissage automatique

1-1. Concepts fondamentaux de l'IA et du Machine Learning

L'IA comprend les technologies qui cherchent à reproduire l'intelligence humaine. L'apprentissage automatique ou le Machine Learning (ML) en anglais est une discipline de l'intelligence artificielle qui permet aux systèmes informatiques d'acquérir des connaissances à partir de données sans nécessiter de programmation explicite. Les algorithmes de Machine Learning repèrent des modèles à partir des données afin de prendre des décisions ou de prédire. [1]

Les principaux algorithmes de ML utilisés en CND comprennent :

1. **Les réseaux neuronaux** : Ils simulent le fonctionnement du cerveau humain pour reconnaître des modèles dans les données.
2. **Machines à vecteurs de support (SVM)** : Elles classent les données en trouvant la ligne optimale ou l'hyper plan qui sépare les différentes classes.
3. **Forêts aléatoires** : Elles utilisent plusieurs arbres de décision pour classer les données et réduire le risque de surajustement.
4. **Réseaux neuronaux convolutifs (CNN)** : Ils sont conçus pour analyser les données visuelles, telles que les images et les vidéos, en utilisant des filtres pour extraire des caractéristiques et des modèles.

1-2. Techniques d'apprentissage

On dénombre trois types d'apprentissage :

1. **Apprentissage supervisé** : Utilise des données étiquetées pour entraîner un modèle, permettant de faire des prédictions ou des classifications. [2]
2. **Apprentissage non supervisé** : Travaille avec des données non étiquetées pour découvrir des structures cachées ou des regroupements dans les données. [2]
3. **Apprentissage par renforcement** : L'agent apprend à effectuer des tâches dans un environnement en maximisant une récompense à travers des essais et erreurs. [3]

1-3. Applications Industrielles de l'IA et du ML

Au sein de l'industrie, l'intelligence artificielle et le machine learning sont employés afin d'améliorer les processus, de prédire la maintenance, de détecter les fraudes, de personnaliser les services, de reconnaître des images, de recommander des produits, et bien d'autres encore. [4]

2- Application du ML au CND

2-1. Travaux de recherche et solutions existantes

La recherche sur l'utilisation du Machine Learning (ML) dans le domaine du Contrôle Non Destructif (CND) a pour objectif d'améliorer la précision, la rapidité et la fiabilité des inspections. Les recherches portent sur l'emploi de méthodes de machine learning avancées afin de modifier la façon dont les défauts sont repérés et évalués dans les matériaux. [5]

2-2. Techniques de ML pour la détection de défauts

Des techniques de ML comme les réseaux de neurones et les arbres de décision sont utilisées pour détecter des défauts dans les matériaux, classer les types de matériaux et prédire la durée de vie restante des structures. [6] [7]

2-2.1 Détection de défauts

Les algorithmes de machine learning sont employés afin de détecter de façon précise et efficace les anomalies ou les défauts présents dans les matériaux qui subissent des inspections non destructives. Ces méthodes permettent une détection plus rapide et plus fiable des imperfections en utilisant des modèles d'apprentissage supervisé ou non supervisé.

2-2.2 Classification des matériaux

Le machine Learning est aussi utilisé afin de trier les divers types de matériaux en fonction de leurs caractéristiques intrinsèques. Les systèmes de machine Learning peuvent classer les matériaux en groupes homogènes en utilisant des modèles de classification, ce qui facilite l'analyse et la prise de décision dans le domaine du CND.

2-3. Avantages de l'Utilisation du ML

L'application du ML dans le CND permet une analyse plus approfondie des données, une détection plus précise des défauts, une réduction des erreurs humaines et une optimisation des processus d'inspection [8]

2-4. Défis

Les défis incluent la qualité et la quantité des données disponibles, la complexité des modèles de ML, l'interprétabilité des résultats, la maintenance des modèles et la confidentialité des données. Une attention particulière doit être portée à la préparation des données pour garantir des résultats fiables. [8] [9]

3- Revue des études théoriques et des solutions existantes dans la littérature scientifique

3-1. Méthodes et techniques de contrôle non destructif

3-1.1 Revue des principales méthodes de CND utilisées dans l'industrie :

Le Contrôle Non Destructif (CND) est un ensemble de méthodes qui permettent de caractériser l'intégrité des structures ou des matériaux, sans les dégrader, que ce soit pendant la production, pendant l'utilisation, ou dans le cadre de la maintenance. Les principales méthodes de CND comprennent l'inspection visuelle, l'inspection par ressuage (PT), l'inspection par particules magnétiques (MT), le contrôle radiographique (RT), le contrôle par courants de Foucault (ET), et le contrôle par ultrasons (UT). [10]

3-1.2 Description des types de données générées par les techniques de CND :

Le contrôle non destructif (CND) est une méthode d'évaluation utilisée dans divers domaines industriels pour caractériser l'état d'intégrité des structures ou des matériaux sans les dégrader. Les techniques de CND comprennent l'utilisation d'images, de signaux et de mesures pour détecter les défauts et évaluer l'intégrité structurelle. Ces techniques se basent sur des phénomènes physiques tels que les ondes optiques, les ondes élastiques et les phénomènes électromagnétiques. Les principales techniques de CND incluent la radiographie, la thermographie infrarouge et les ultrasons. [10]

3-1.3 Défis et limites de l'analyse traditionnelle des données de CND :

L'analyse traditionnelle des données de CND peut être longue et nécessite des connaissances approfondies. Elle peut également être moins efficace pour détecter des défauts subtils ou complexes. [9]

3-2. Modèles d'apprentissage automatique pour l'analyse des données de CND

3-2.1 Sélection des algorithmes d'apprentissage automatique adaptés à l'analyse des données de CND :

Dans l'étude de Y. Sun, Z. Wang et C. Deng [11], on a examiné les résultats de différents algorithmes d'apprentissage automatique utilisés pour analyser des données de CND. Selon les auteurs, il est possible d'évaluer les algorithmes sur divers ensembles de données de CND et de conclure qu'il n'y a pas d'algorithme optimal unique pour toutes les applications de cela. L'algorithme choisi est déterminé par la tâche particulière et les caractéristiques des données.

3-2.2 Développement de modèles de prédiction de défauts basés sur les données de CND :

Dans l'étude de Q. Zhang, N. Zhang et H. Wang [12], les auteurs ont travaillé sur une méthode basée sur l'intelligence artificielle pour prédire les imperfections dans les données de CND. Les auteurs ont mis au point un modèle de réseau de neurones profonds qui peut détecter et classer de manière efficace les défauts présents dans différentes images de CND. Les résultats

obtenus par le modèle sont précis et peuvent être exploités afin d'améliorer l'efficacité et la fiabilité des inspections de CND.

3-2.3 Utilisation de l'apprentissage automatique pour l'optimisation des procédures d'inspection et de maintenance :

Un modèle d'apprentissage automatique est proposé par les auteurs afin de prédire la durée de vie résiduelle des composants et d'optimiser les calendriers d'inspection. Cette méthode pourrait contribuer à diminuer les dépenses liées à l'inspection et à renforcer la fiabilité des systèmes de CND. [13]

CHAPITRE 2 : Solutions adoptées

1- Système automatisé (FPI)

Dans le cadre de l'initiative de recherche et d'innovation Horizon 2020 de l'Union européenne, la technique d'apprentissage automatique proposée est présentée dans le cadre du projet d'inspection par ressuage fluorescent automatisé (AutoFPI), un programme de recherche financé par l'initiative MANUNET. Il a pour but de créer un système automatisé pour analyser les pannes dans les pièces et composants industriels.

Comme mentionné précédemment, les FPI sont des méthodes de contrôle non destructif (CND), avec une série d'opérations qui peut être généralement décrite par le diagramme de flux présenté dans la Figure 1. Leur principal désavantage réside dans le fait qu'à la dernière étape (l'évaluation), il est nécessaire qu'un opérateur expert travaille dans une pièce sombre afin de traiter manuellement les pièces. [14]



Figure 1 : Organigramme général du FPI

L'objectif du système automatisé est d'améliorer l'environnement de travail du collaborateur et la qualité de l'évaluation. En fait, les experts peuvent être remplacés par des robots qui photographient chaque pièce sous différents angles dans une pièce sombre. Ces images sont ensuite analysées avec des techniques de traitement d'image appropriées, comme le montre la figure 2. [14]



Figure 2 : Organigramme d'automatisation FPI

En particulier, le système a été conçu pour améliorer la fiabilité des évaluations des pièces en mettant en place une interface homme-machine spécialement conçue et en utilisant des techniques d'intelligence artificielle adaptées. Celles-ci permettent d'apprendre des opérateurs experts comment évaluer la qualité des pièces et identifier leurs caractéristiques sous la lumière UV. L'utilisation d'un système robotisé de manipulation des pièces et d'un algorithme de prise

de décision rapide devrait vraisemblablement accroître l'efficacité du FPI, ce qui réduira le temps d'inspection et permettra de traiter un plus grand nombre de pièces chaque jour. Cela rendra le processus d'inspection plus fiable, permettant une meilleure localisation et dimensionnement des défauts ainsi que la génération de rapports détaillés et de statistiques sur la production. De plus, les opérateurs auront la possibilité de vérifier et de valider la qualité globale du processus en utilisant un PC, même à distance. Toutes ces améliorations visent à minimiser les coûts du processus tout en améliorant les conditions de travail des opérateurs, en évitant le traitement manuel des pièces et les tâches monotones. [12]

Dans ce contexte, il est envisageable de mettre en œuvre des processus d'apprentissage automatique pour évaluer automatiquement l'état des pièces. Cependant, la principale contrainte réside dans le faible nombre d'échantillons disponibles. Pour pallier cela, des architectures multi-étapes ont été explorées pour réduire le nombre d'échantillons requis lors de la phase d'entraînement. Une analyse d'image préliminaire a été effectuée pour identifier et éliminer les signaux dans les petites boîtes, ce qui aidera à organiser les données à traiter par les réseaux neuronaux. [13]

L'analyse des pièces commence par une analyse déterministe de base des images, identifiant et extrayant les points dans de petites boîtes. La précision de cette étape dépend du niveau de bruit des photos originales. Un nettoyage approprié entraîne généralement un faible bruit. L'option de taille de boîte permet aux utilisateurs d'équilibrer la quantité de données dans chaque boîte avec le temps de calcul nécessaire à la formation du système. [12]

Cette stratégie offre l'avantage d'utiliser des techniques de multiplication d'images pour élargir l'ensemble de données disponible. L'architecture principale repose sur la méthode d'identification des points illustrée dans la figure 3, qui consiste à traiter directement chaque point trouvé dans l'image originale à l'aide d'un réseau neuronal. Le nombre de pixels dans la boîte sert de taille d'entrée du réseau et la catégorisation des spots sert de sortie. [6]




Figure 3 : Première architecture système (de base) analysée par un réseau de neurones

Les perceptrons multicouches et les réseaux neuronaux profonds peuvent être utilisés avec cette architecture. Par rapport aux situations précédentes, l'ensemble de données nécessaire est plus petit et plus facile à obtenir : en fait, plusieurs indications peuvent exister pour une seule image.

Le processus de reconnaissance ponctuelle et la logique heuristique permettant de déterminer l'état final de l'échantillon sont les deux processus déterministes de ce scénario qui doivent être correctement définis.

Une autre phase déterministe a été ajoutée dans une architecture de conception alternative (Figure 4). Plus précisément, certains attributs sont extraits de manière déterministe pour chaque point et utilisés comme entrée du réseau neuronal, les caractéristiques extraites de manière déterministe de chaque point sont analysées avec un réseau de neurones. [13]




Figure 4 : Deuxième architecture du système pour l'identification des taches

2- Techniques d'apprentissage automatique pour l'identification des taches

Il est possible d'utiliser efficacement les techniques d'apprentissage automatique (ML), notamment les réseaux neuronaux, pour détecter l'état de défaut. Le but du système de machine learning est de classer chaque tache repérée dans l'image initiale. On fournit la couche d'entrée sous forme d'une image en noir et blanc de 60×60 pixels.

La sortie du système consiste à classer la tâche dans l'une des trois classes possibles qui ont été identifiées dans l'application envisagée : "healthy" (quand aucun défaut n'est détecté) ; "linear defect" ; et "crack" (selon la forme du défaut). [15]

Deux classificateurs distincts sont présentés dans cette partie : le premier est le classificateur de tache directe, le second est le classificateur de tache indirect. Une étape supplémentaire d'extraction de caractéristiques déterministe est requise pour cette dernière approche.

2-1. Classificateur de spot direct

Le classificateur de points directs, représenté sur la figure 5, reçoit directement en entrée l'image dans où il y a l'endroit. Ainsi, sa couche d'entrée comporte 60×60 neurones.




Figure 5 : Architecture du classificateur de points directs

Le réseau neuronal développé n'a qu'une seule couche cachée pour réduire la possibilité de encourus en cas de surentraînement, tandis que la couche de sortie est composée de trois neurones, un pour chaque état cible de la pièce. Le réseau est formé avec le gradient conjugué mis à l'échelle algorithme utilisant l'indice d'erreur d'entropie croisée. [15]

2-2. Classificateur de spot indirect

La technique indirecte, qui est le deuxième classificateur proposé, implique l'extraction de certaines caractéristiques déterministes de l'image après qu'elle a subi une analyse préliminaire.

Suite aux entretiens avec des utilisateurs professionnels, les attributs ont été choisis. Il a été découvert que la superficie de la tâche et le rapport d'aspect sont les facteurs les plus cruciaux pour la classification.

La superficie de la tâche, les axes principal et mineur de l'ellipse qui entoure la tâche, son excentricité et enfin, l'orientation de la tache sont les nouvelles caractéristiques qui ont été choisies. L'architecture de ce système indirect est représentée dans la Figure 6. [15]




Figure 6 : Architecture du classificateur de points indirects

3- Incrustation stochastique des voisins distribués en t (t-DSNE)

L'incrustation stochastique des voisins distribués en t (t-DSNE) est une méthode d'apprentissage automatique qui combine des éléments de l'incrustation stochastique des voisins distribués (t-SNE) et de l'incrustation stochastique des voisins (SNE). Elle est conçue pour résoudre des problèmes d'apprentissage non supervisé, en particulier pour la visualisation de données de haute dimensionnalité.

C'est un algorithme d'apprentissage automatique utilisé pour la visualisation de données de haute dimension [9]. Il s'agit d'une technique de réduction de dimensionnalité non linéaire bien adaptée pour incorporer des données de haute dimension dans un espace de deux ou trois dimensions pour la visualisation. Plus précisément, elle modélise chaque objet de haute dimension par un point à deux ou trois dimensions de telle manière que les objets similaires soient représentés par des points proches et les objets différents soient modélisés par des points éloignés avec une probabilité élevée.

Cette méthode a été implémentée pour analyser et valider la distribution des échantillons à trois niveaux différents de la classification : lors de la première étape, lorsque les images des taches ont été analysées ; puis, après l'extraction des caractéristiques déterministes ; et enfin, à la fin du processus de classification, comme indiqué dans la section suivante. [14]

Le jeu de données considéré est composé de boîtes de 60×60 pixels, chacune contenant une seule tache. Ces boîtes sont en noir et blanc car les images couleur originales ont été prétraitées avec un algorithme de seuillage pour réduire le bruit de l'image.

Le jeu de données est donc composé de taches individuelles qui ont été classées par les opérateurs experts dans trois classes possibles : fissures ; indications linéaires ; et indications saines.

La Figure 7 montre quelques taches du jeu de données disponible : la couleur de la boîte est représentative du type de défaut : en vert, les indications saines ; en orange, les indications linéaires ; et en rouge, les fissures. [14]




Figure 7 : Échantillons prélevés à partir de l'ensemble de données disponible

La couleur de la boîte représente le type de défaut : en vert, the healthy indications ; en orange, he linear ones ; et en rouge, les cracks.

Étant donné que la classification a été effectuée manuellement, il est possible qu'il y ait des échantillons mal classés. Les images repérées disponibles ont été sélectionnées afin d'avoir le même nombre d'indications pour les trois classes.

À partir de cet ensemble de données, les ensembles d'entraînement, de validation et de test ont été extraits. Dans ce cas également, la taille de chaque classe est la même dans tous les sous-ensembles. Cela a créé une division de l'ensemble de données comme illustré dans la Figure 8. Pour toutes les analyses effectuées, l'ensemble d'entraînement était composé de 65% des échantillons ; l'ensemble de validation de 15% ; et l'ensemble de test de 20% - pour un total de 1502 images, comme détaillé dans le Tableau 1. [15]




Figure 8 : Division de l'ensemble de données

Set	Training	Validation	Test	Total
Healthy	326	75	100	501
Crack	325	75	100	500
Linear	326	75	100	501
Total	977	225	300	1502

Tableau 1 : Nombre d'échantillons dans l'ensemble de données considéré

Chapitre 3 : Evaluation des solutions adoptées

Une analyse numérique a été réalisée sur l'ensemble de données décrit, en considérant les deux approches précédemment présentées, c'est-à-dire le classificateur de tâches direct et indirect, respectivement. De plus, les résultats de la classification ont été comparés à l'aide de l'approche t-DSNE décrite dans la Section 3 du chapitre 2, afin de comparer graphiquement et valider l'efficacité des techniques proposées.

Toutes les techniques d'apprentissage automatique ont été implémentées dans Matlab R2019a à partir de la Neural Network Toolbox, en modifiant correctement les caractéristiques du réseau pour qu'elles soient adaptées au problème spécifique.

Ce jeu de données a été utilisé pour entraîner les deux réseaux de classification des architectures décrites dans les Figures 3 et 4. En particulier, le premier était une classification directe des tâches car le réseau était directement alimenté avec les valeurs des pixels, tandis que le deuxième était une classification indirecte des tâches car l'image était prétraitée de manière déterministe. [14]

1- Classificateur de tâches direct

Le réseau de neurones était composé :

- D'une couche d'entrée avec 360 neurones, un pour chaque pixel ;
- D'une couche cachée avec 150 neurones, conçue après une analyse de sensibilité préliminaire ;
- D'une couche de sortie finale avec trois neurones, renvoyant la probabilité qu'une tâche appartienne à chaque type de classification.

Comme mentionné dans la Section 3, la fonction d'erreur utilisée pour l'entraînement du réseau de neurones était l'entropie croisée [15], et l'algorithme d'entraînement utilisé était le gradient conjugué mis à l'échelle. Le critère de terminaison sélectionné était la vérification de la validation. Vingt-cinq essais indépendants ont été effectués et la Figure 9 montre les courbes de convergence de l'entraînement et des tests.

Le meilleur réseau obtenu selon les résultats des tests a été analysé. Il a atteint la meilleure performance de validation à l'époque 77, comme indiqué dans la Figure 10, où les performances d'entraînement (ligne bleue), de validation (ligne verte) et de test (ligne rouge) sont présentées. Il est possible de voir que les performances d'entraînement sont bien meilleures que celles de la validation et des tests, ce qui montre que le réseau a une capacité de généralisation relativement réduite.




Figure 9 : Courbes de convergence d'entraînement et de test direct




Figure 10 : Évolution des performances du meilleur réseau neuronal obtenu à partir des 25 essais indépendants

Selon le graphique, les trois courbes illustrent comment l'erreur évolue au fil des phases d'entraînement pour un réseau neuronal. Les erreurs sur les données d'entraînement sont représentées par la courbe bleue, les erreurs sur les données de validation par la courbe rouge et les erreurs sur les données de test par la courbe verte. Chacune d'entre elles débute avec un taux d'erreur élevé et diminue progressivement, ce qui suggère que le modèle apprend et s'améliore au fil du temps. Dans la zone encadrée, la convergence des trois courbes indique que le modèle a atteint une performance stable et que poursuivre l'entraînement au-delà de ce point pourrait ne pas être avantageux.

Cela témoigne d'une diminution du taux d'erreur au fil du temps. Les trois courbes sont proches l'une de l'autre, ce qui suggère un point de convergence où la performance du modèle s'est stabilisée, comme le montre un cercle vert.

En résumé, le graphique met en évidence que le réseau neuronal a été entraîné à un niveau où il est capable de prédire de manière fiable des résultats avec un faible taux d'erreur, ce qui est crucial pour des applications nécessitant des prédictions précises, telles que les scénarios de tests non destructifs dans le domaine industrie. [14]

2- Classifieur de tâches indirectes

Le réseau neuronal est maintenant constitué d'une couche d'entrée de cinq neurones, un pour chaque caractéristique, d'une couche cachée de 10 neurones (mesurée par une analyse de sensibilité) et d'une couche de sortie finale de trois neurones, avec le même sens que précédemment. Comme dans le cas précédent, on utilise l'entropie croisée comme fonction d'erreur et on utilise le gradient conjugué échelonné comme algorithme d'entraînement.




Figure 11 : Courbes de convergence d'entraînement et de test indirect

En comparant ces résultats avec ceux d'un classifieur direct précédemment proposé, il est possible de constater que l'erreur d'entropie croisée est significativement plus faible, surtout en ce qui concerne les performances de test. Dans ce cas, une fois de plus, le meilleur réseau obtenu selon les résultats de test a été analysé. Ses courbes de convergence détaillées sont présentées dans la Figure 12. Ainsi, la distance entre la performance d'entraînement et celle de test est beaucoup plus faible qu'auparavant, ce qui signifie qu'une capacité de généralisation plus élevée du système a été atteinte.




Figure 12 : Évolution des performances du meilleur réseau neuronal obtenu à partir de 25 essais indépendants

Cette figure représente l'évolution des performances d'un réseau neuronal au cours de son processus d'entraînement sur un certain nombre d'époques. Le graphique comprend trois courbes représentant différents ensembles de données : la courbe d'entraînement (bleue), la courbe de validation (verte) et la courbe de test (rouge). L'axe des abscisses, étiqueté "Époque d'entraînement", montre le nombre de cycles d'entraînement que le réseau neuronal a effectués. L'axe des ordonnées, étiqueté "Erreur - $\log(\text{cross-entropy})$ ", mesure l'erreur de prédiction du modèle, avec des valeurs plus faibles indiquant une meilleure performance.

Comme on peut le constater, les trois courbes commencent avec des taux d'erreur plus élevés à gauche du graphique et montrent une forte diminution à mesure que l'entraînement progresse. Cette diminution indique que le réseau neuronal apprend efficacement à partir des données. Les courbes commencent à se stabiliser à mesure qu'elles se déplacent vers la droite, suggérant que le modèle atteint sa performance optimale.

La zone mise en évidence par le cercle d'annotation près de la convergence des trois courbes est particulièrement importante. Elle suggère que ce point est celui où la performance du modèle s'est stabilisée et que des entraînements supplémentaires pourraient ne pas entraîner d'améliorations significatives.

En conclusion, le graphique démontre que le réseau neuronal a été entraîné à un niveau où il peut prédire de manière fiable des résultats avec un faible taux d'erreur. Cela est essentiel pour des applications où des prédictions précises sont nécessaires, comme dans les scénarios de tests non destructifs dans l'industrie. [14]

3- Validation et Comparaison des Résultats

Afin d'évaluer la véritable contribution du processus d'extraction de caractéristiques à la classification par rapport à celle du réseau neuronal, on a utilisé la méthode d'intégration stochastique des voisins t-distribués, comme décrit dans la Section 3.

Pour réécrire l'explication en mettant en avant que le graphique 2 est supérieur au graphique 1, on pourrait dire :

Le graphique 11 illustre une amélioration significative par rapport au graphique 9 en termes de performance d'entraînement du réseau neuronal. Dans le graphique 11, la convergence des courbes d'erreur est non seulement atteinte plus rapidement mais aussi à un taux d'erreur inférieur, ce qui indique une efficacité accrue dans l'apprentissage et la généralisation du modèle. De plus, la zone de convergence est plus étroite, suggérant une meilleure cohérence entre les données d'entraînement, de validation et de test.

Cette performance optimisée est cruciale pour les applications industrielles de tests non destructifs (CND), où la précision des prédictions peut directement influencer la sécurité et l'intégrité des matériaux et structures. Le graphique 11, avec sa performance supérieure, démontre un réseau neuronal qui a non seulement appris de manière plus efficace mais qui est également plus robuste face à des données inédites, ce qui est un atout majeur pour l'industrie.

En conclusion, le graphique 11, grâce à son apprentissage optimisé et à sa meilleure performance de généralisation, se présente comme une solution plus fiable et plus précise pour les scénarios exigeants de l'industrie, surpassant ainsi le graphique 9 qui, bien qu'efficace, n'atteint pas le même niveau d'excellence. [14]

4- Comparaison avec les méthodes traditionnelles d'analyse

Les techniques de contrôle non destructif présentent des bénéfices importants par rapport aux méthodes d'analyse classiques, en particulier en ce qui concerne la précision, l'efficacité et la non destruction des échantillons. Ces techniques jouent un rôle crucial dans la surveillance et l'entretien des structures, et peuvent contribuer à anticiper la durée de vie résiduelle des matériaux et des structures. [15]




Figure 13 : Exemples de classification

La couleur de la bordure de l'image est relative à la classe cible, tandis que la couleur du cercle est relative à la classe prédite : (a), (b) et (c) montrent des exemples de classification correcte, tandis que (d), (e) et (f) montrent une mauvaise classification.

Conclusion générale et perspectives

Ce mémoire a exploré l'application des réseaux de neurones et du machine learning dans les tests non destructifs (CND), en mettant en lumière leur potentiel pour révolutionner ce domaine crucial de l'industrie. À travers une série d'expériences rigoureuses et une analyse approfondie des données, nous avons démontré que les algorithmes de machine learning, notamment les réseaux de neurones, peuvent améliorer significativement la précision et l'efficacité des processus de CND.

Notre recherche montre que l'optimisation méthodique des paramètres du réseau neuronal et l'utilisation de techniques avancées de machine learning permettent d'atteindre une convergence rapide des courbes d'erreur et une stabilisation optimale des performances. Ces avancées se traduisent par une capacité accrue à détecter les défauts matériels avec une précision et une fiabilité supérieure, minimisant ainsi le risque d'erreurs qui pourraient avoir des conséquences graves sur la sécurité et l'intégrité des structures industrielles.

De plus, notre étude a mis en évidence l'importance de l'apprentissage automatique dans l'amélioration continue des systèmes de CND. Les réseaux de neurones se sont révélés particulièrement efficaces pour traiter des ensembles de données complexes et volumineux, permettant de reconnaître des modèles et des anomalies invisibles à l'œil humain. Cette capacité à apprendre et à s'adapter en permanence ouvre de nouvelles perspectives pour la maintenance prédictive et l'optimisation des processus industriels.

En conclusion, ce mémoire démontre que l'intégration de l'intelligence artificielle et du machine learning dans les tests non destructifs est non seulement faisable, mais également bénéfique pour l'industrie. Les avancées réalisées dans ce domaine promettent d'améliorer la fiabilité et la précision des inspections, tout en réduisant les coûts et les temps d'arrêt. À mesure que la technologie continue d'évoluer, nous pouvons nous attendre à des systèmes de CND encore plus sophistiqués, capables de répondre aux défis toujours plus complexes de l'industrie moderne. Cette recherche ouvre la voie à de futures innovations et applications, renforçant le rôle central de l'intelligence artificielle dans l'innovation industrielle.

Bibliographie

- [1] S. J. Russell et P. Norvig, Intelligence artificielle : Une approche moderne, Malaysia: Pearson Education, 2016.
- [2] I. Goodfellow, Y. Bengio et A. Courville, deep learning, cambridge : MIT press, 2016.
- [3] R. S. Sutton et A. G. Barto, introduction à l'apprentissage par renforcement, Cambridge, MA: MIT press, 2018.
- [4] E. Brynjolfsson et A. McAfee, «L'entreprise de l'intelligence artificielle,» *Harvard Business Review*, pp. 1-4, 2017.
- [5] S. Gholizadeh, «Une revue des méthodes de contrôle non destructif des matériaux composites,» *Procedia Structural Integrity*, pp. 50-53, 2016.
- [6] Y. Murakami, «Identification des défauts matériels à l'aide de réseaux neuronaux,» *NDT & E International*, pp. 558-559, 2002.
- [7] G. Y. Tian, Z. Zhao et R. W. Baines, «La recherche de problèmes inverses dans les ordinateurs et les mesures,» *Journal of Measurement Science and Technology*, pp. 615-616, 1998.
- [8] B. Raj et L. Rajendran, «Rôle de l'intelligence artificielle dans la caractérisation et l'évaluation non destructive des matériaux,» *Transactions of the Indian Institute of Metals*, pp. 756-757, 2015.
- [9] A. Gonzalez Rodriguez, A. Gosselin, R. Rhéaume et N. Harrap, «Approches de l'intelligence computationnelle pour l'analyse de données, la prochaine étape de l'innovation pour les techniques avancées UT en CND,» pp. 11-12, 2018.
- [10] J. Dumont-Fillon, «Contrôle non destructif (CND),» *Techniques de l'Ingénieur*, pp. 1-3, 10 janvier 1996.
- [11] Y. Sun, Z. Wang et C. Deng, «Étude comparative des algorithmes d'apprentissage automatique pour l'analyse de données de CND,» *Revue X*, pp. 13-14, 2018.

- [12] Q. Zhang, N. Zhang et H. Wang, «Prédiction des défauts dans les données de CND à l'aide de techniques d'apprentissage automatique,» *Journal Y*, pp. 20-21, 2019.
- [13] S. Liu, W. Zhang et Y. Li, «Optimisation des procédures d'inspection et de maintenance dans les CND à l'aide de l'apprentissage automatique,» *Journal Z*, pp. 23-24, 2020.
- [14] A. Niccolai, D. Caputo, L. Chieco, F. Grimaccia et M. Mussetta, «Technique de détection fondée sur l'apprentissage automatique pour le CND dans la fabrication industrielle,» *Mathematics*, pp. 2-1, 2021.
- [15] C. FENDZI, *Contrôle Santé des Structures Composites : Application à la Surveillance des Nacelles Aéronautiques*, paris, 2015.
- [16] A. R. & H. G. A. Heravi, «Un nouvel algorithme de gradient conjugué correntropie pour l'amélioration de l'entraînement des réseaux neuronaux,» *IEEE Transactions on Neural Networks and Learning Systems*, pp. 325-326, 2018.