

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche
scientifique
جامعة سعد دحلب البلدية-1
Université SAAD DAHLAB de BLIDA-1
كلية التكنولوجيا
Faculté de Technologie
قسم الإلكترونيك
Département d'électronique



Mémoire de Master

Filière télécommunication
Spécialité : Systèmes de télécommunication

Présenté par

ADDAOUD Hicham

Classification des défauts multiples détectés par les ultrasons en utilisant les réseaux de neurones convolutifs

Encadré par : M. KECHIDA Ahmed et M. AIT SAADI Hocine

Année Universitaire 2020-2021

Remerciements

D'abord, je tiens à remercier Dieu pour tout le savoir que j'ai acquis. Je profite aussi de cette occasion pour adresser mes sincères remerciements à mon promoteur **Mr. KECHIDA Ahmed** Directeur du Centre de Recherche et Technologies Industrielles qui m'a fait bénéficier de ses conseil et de ses connaissances, soulignant ainsi l'intérêt constat qu'il porte à mon travail. Je le remercie pour la confiance qu'il a eue en moi, sa patience et sa disponibilité à chaque fois que j'avais besoins de lui.

Je remercie aussi mon Co-promoteur **Mr. AIT SAADI Hocine** qui n'a ménagé aucun effort pour que ce mémoire puisse voir le jour. Je lui exprime ma gratitude de m'avoir dirigé, encouragé et surtout aidé afin de réaliser ce travail.

Je remercie aussi **Mr .BOUGUETTAYA Abdelmalek** pour son aide, sa patience et ses conseils.

J'adresse mes remerciements à l'ensemble du cadre administratif du département de génie électrique.

Mes pensées vont aussi à toutes les personnes que j'ai rencontrées durant ces dernier mois pour leur aide.

Je tiens à remercier tous les enseignants qui ont accepté de jugé ce travail.

Je tiens à remercier tous ceux qui ont contribué à l'aboutissement de ce travail, ainsi que toute la promotion systèmes et outils de télécommunication 2020 /2021

Table de matières

Table des matières	I
Liste des Figures	II
Liste des tableaux	III
Liste symboles	IV
Liste des abréviations	V
Introduction générale	01
Chapitre I : Généralités sur le contrôle non destructif CND (Les ultrasons)	
1- Le contrôle non destructif : méthodes d'examen et de contrôle.	04
1-1. Introduction	04
2- Les techniques du contrôle non destructif	05
2-1. L'examen visuel	05
2-2. Ressuage	05
2-3. Magnétoscopie	06
2-4. Radiographie	06
2-5. Thermographie	07
2-6. CND par courants de Foucault	07
2-7. Les ultrasons	08
3- Classement et performances des procédés de CND	09
4- Le contrôle non destructif par ultrasons	11
4-1. Définition Le contrôle non destructif par ultrasons	11
4-2. Propagation des ondes	12
4-3. Production des ondes ultrasonores	12
4-4. Palpeurs piézoélectriques	13
4-5. Différents types d'ondes des ultrasons	14
4-6. Vitesse, directivité, atténuation	15
4-7. Changement de milieu : réflexion, transmission	19
4-8. Réfraction	20
4-9. Méthodes de contrôle ultrasonore	21
4-10. Mode de contrôle par ultrasons	23
4-11. Appareillage d'émission-réception des ondes	24

Table de matières

4-12. Étalonnage	25
4-13. Principe de contrôle par ultrasons	26
4-14. Champ d'application du contrôle ultrasonore	27
4-15. La nature des pièces et des défauts détectés par les ultrasons	28
4-16. Évolution du contrôle ultrasonore	28
4-17. Avantages et inconvénients du contrôle non destructif par ultrasons	29
4-18. Problématique des ultrasons	29
5- Conclusion	31
Chapitre II : Généralité sur Les réseaux de neurones (les réseaux de neurones convolutifs CNN)	
1- Introduction	33
2- L'intelligence artificielle (IA)	33
2-1. Les origines de l'intelligence artificielle	34
2-2. L'importance de l'intelligence artificielle	34
2-3. Les applications de l'IA	35
3- Le Machine Learning	37
3-1. Définition du Machine Learning	37
3-2. Fonctionnement du Machine Learning	38
3-3. Les différents types d'algorithmes de Machine Learning	39
3-4. L'utilité du Machine Learning	41
4- Deep Learning	42
4-1. Définition du Deep Learning	42
4-2. Domaine d'application	43
5- Les Réseaux de neurones	44
5-1. Principe de Fonctionnement des réseaux de neurones	45
5-2. Les principaux composants du réseau de neurones	46
5-3. Le perceptron	48
5-4. Les différents types de réseaux de neurones	50
6- Convolution Neural Network (CNN)	51
6-1 Le principe de la CNN	51
6-2. Les dimensions de la CNN	52

Table de matières

6-3. Les principaux composants du CNN	53
7- Conclusion	57
 Chapitre III : expérimentation et résultats	
1- Introduction	59
2- La phase d'apprentissage	59
2-1 Base de données d'apprentissage	59
2-2. Création de classe	59
2-3. La normalisation des données	61
2-4. L'Entrainements et le test de l'architecture	61
2-5. Le choix des paramètres	63
2-6. Résultats d'apprentissage	67
3- La phase de validation	71
3-1. Génération d'une base de données réelle	71
3-2. Validation de l'architecture	80
3-3. Résumé d'algorithme	80
4- Conclusion	81
Conclusion générale	VI
Références bibliographiques	VII

Liste des figures

Figure 1.1 - Principe du ressuage	05
Figure 1.2 - Principe de la magnétoscopie	06
Figure 1.3 - Principe de la radiographie	07
Figure 1.4 - principe de la détection par courants de Foucault	08
Figure 1.5 - Principe du contrôle par Ultrasons	12
Figure 1.6 - Structure d'un palpeur ultrasonore	13
Figure 1.7 - Types d'ondes et modes de propagation des ultrasons	15
Figure 1.8 – Divergence du faisceau d'ultrasons	17
Figure 1.9 – Intensité acoustique sur l'axe du faisceau	18
Figure 1.10 – Distribution de l'amplitude perpendiculairement à l'axe	18
Figure 1.11 – Réflexion et réfraction des ondes ultrasonores	21
Figure 1.12 - Contrôle ultrasonore par échographie (ondes longitudinales)	22
Figure 1.13 – Contrôle des soudures par la méthode tandem (ondes transversales)	22
Figure 1.14 – Différents modes de présentation	23
Figure 1.15 - Schéma de principe d'un appareil classique de contrôle par ultrasons	25
Figure 1.16 - Principe de contrôle par ultrasons	26
Figure 1.1 la Différence entre AI, Machine Learning et le deep Learning	34
Figure 2.2 La différence entre la classification et la régression	40
Figure 2.3 Le principe de l'apprentissage renforcé	41
Figure 2.4 - La différence entre l'apprentissage supervisé et non-supervisé	41
Figure 2.5 - Représentation du réseau de neurones humain	44
Figure 2.6 - Représentation du réseau de neurones artificiel	45
Figure 2.7 - Représentation d'un simple réseau de neurones perceptron	49
Figure 2.8 - exemple d'un filtre de convolution 1D	53
Figure 2.9 - Les fonctions D'activation	54
Figure 2.10 - Exemple sur le Maxpooling	55
Figure 2.11 - Représentation des fully-connected Layers	55
Figure 2.12 - exemple sur le fonctionnement des Dropout Layers	56

Liste des figures

Figure 3.1 - la base de données des signaux qui contiennent 0 défauts	60
Figure 3.2 - représente la base de données des signaux qui contiennent 1 défaut	60
Figure 3.3 - représente la base de données des signaux qui contiennent 2 défauts	61
Figure 3.4 - les bibliothèques utilisées dans l'architecture	63
Figure 3.5 - l'algorithme de notre architecture	65
Figure 3.6 - les paramètres entraînés dans le modèle	65
Figure 3.7 - l'architecture du modèle CNN	66
Figure 3.8 - la courbe de l'accuracy de l'architecture (Learning Rate = 0.001, epoch = 100)	67
Figure 3.9 - la courbe du Loss de l'architecture (Learning Rate = 0.001, epoch = 100)	68
Figure 3.10 - la courbe de l'accuracy de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 600)	68
Figure 3.11 - la courbe du Loss de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 600)	69
Figure 3.12 - l'évaluation de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 600)	69
Figure 3.13 - la courbe de l'accuracy de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)	69
Figure 3.14 - la courbe du Loss de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)	70
Figure 3.15 - l'évaluation de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)	70
Figure 3.16 - Une pièce en Aluminium avec les dimensions (25,8cm x 3,3cm x 2,6cm)	71
Figure 3.17 - Une pièce en Aluminium avec les dimensions (32,5cm x 7,7cm x 2,1cm)	71
Figure 3.18 - Une pièce en Acier avec les dimensions (19,8cm x 17,8cm x 3cm)	71
Figure 3.19 - Une pièce en Acier avec les dimensions (25,5cm x 9,9cm x 2,4cm)	72
Figure 3.20 - l'interface de l'OmniScan MX	72

Liste des figures

Figure 3.21 –Palpeur A11 (Sonde 5 Mhz-32 éléments)	73
Figure 3.22 –le déroulement du contrôle	75
Figure 3.23 - le contrôle ultrasonores d'une pièce à l'aide d'une unité d'inspection ultrasonores multiéléments (Le OmniScan MX)	75
Figure 3.24 - l'interface du logiciel TomoView	76
Figure 3.25 - l'écho d'un signal sans défaut sur 640 points	77
Figure 3.26 - l'écho d'un signal sans défaut sur 320 points	77
Figure 3.27 - l'écho d'un signal avec 1 défaut sur 640 points	78
Figure 3.28 – l'écho d'un signal avec 1 défaut sur 320 points	78
Figure 3.29 – l'écho d'un signal avec 2 défauts sur 640 points	79
Figure 3.30 - l'écho d'un signal avec 2 défauts sur 320 points	79
Figure 3.31 - le code de prédiction de classe	80

Liste des tableaux

Tableau 1.1 – le classement des procédés de contrôle non destructif : caractéristiques	09
Tableau 1.2 – la vitesse et l'impédance des ondes ultrasonores	16
Tableau 3.1 – le nombre des signaux d'entraînement et de test	62

Liste des symboles

σ : Coefficient de Poisson.

α : Coefficient d'atténuation.

f : Fréquence de la vibration.

d : Le diamètre de grain homogène.

I_R : Intensités acoustiques réfléchies.

I_T : Intensités acoustiques transmises.

I_0 : Intensité initiale.

Λ : Longueur d'onde.

L : La longueur de la zone de Fresnel.

D : Le diamètre de la source.

Θ : L'angle d'étalement.

d : Le diamètre de grain homogène.

E : Module d'Young.

ρ : Masse volumique.

V : Vitesse de propagation.

V : Vitesse des ultrasons.

V_L : Vitesses de propagation des ondes ultrasonores longitudinales.

V_T : Vitesses de propagation des ondes ultrasonores transversales.

V_R : Vitesses de propagation des ondes ultrasonores Rayleigh.

x : Epaisseur traversée.

Z : Impédance acoustique.

Z_1 : Impédance acoustique du milieu 1.

Z_2 : Impédance acoustique du milieu 2.

Liste des abréviations

CND : Contrôle non destructif.

UV : Ultras violet.

CF : Courant de Foucault.

F.E.M : Force électromotrice.

US : Ultrasonore.

SAFT : Synthetic Aperture Focusing Technique

AVG : AbstandVertarkung Grosse

IA : Intelligence Artificielle.

UE : Union Européen.

CRM : Customer Relationship management.

NLP: Natural Language Processing.

NTIC : Nouvelles technologies de l'information et de la communication.

ANN: Artificial Neural Network.

RNN: Recurrent Neural Network.

CNN: Convolution Neural Network.

FC: Fully Connected.

1D : 1 dimensionnel.

2D : 2 dimensions.

3D : Tridimensionnel

IRM : Imagerie par résonance magnétique

Introduction

Introduction générale

Le contrôle non destructif (CND) joue un rôle très important dans le domaine d'industrie, il permet de contrôler les matériaux utilisés et de détecter les défauts sans endommager les pièces inspectées. De nombreux domaines industriels ont recours à ce type de contrôle comme : le domaine maritime, l'industrie de canalisation dans les secteurs du pétrole et du gaz, le nucléaire et l'aéronautique

Ce type de contrôle a pour but de détecter les défauts présents dans les pièces, ensuite de les dimensionner et les identifier. Par exemple les fissures, les inclusions, le manque de fusion et le manque de pénétration Ect.

Le choix d'une méthode de contrôle dépend de la structure à examiner, les conditions du contrôle et les contraintes du temps et coût. Les techniques du contrôle sont complémentaires que concurrentes et ont été développées afin de répondre aux besoins des domaines industriels. A ce titre on peut citer des différentes techniques de contrôle : le contrôle visuel, la radiographie, la magnétoscopie et les ultrasons qui font l'objet de notre étude

Le contrôle par ultrasons est l'une des techniques les plus utilisées dans la détection des défauts. Elle se base sur la propagation des ondes ultrasonores dans les pièces et la réflexion lors que les ondes rencontrent un défaut. L'écho du signal réfléchi contient toutes les informations nécessaires du défaut.

L'utilisation des ultrasons a été généralisée en 1945 où les ultrasons ont été utilisés pour la détection des sous-marins, puis cette technique a évolué et occupé plusieurs domaines tels que la médecine, l'aéronautique et l'industrie. Les ultrasons ont connu le sommet de leurs évolutions avec l'évolution de l'électronique.

Dans certaines situations, la détection et la classification des défauts multiples proches est difficile car on ne peut pas distinguer entre les échos des défauts dans les signaux quand ils sont superposés. Jusqu'à l'heure actuelle, plusieurs travaux ont été réalisés afin de résoudre ce problème comme le SPLIT SPECTRUM PROCESSING et d'autres méthodes qui permettent de détecter et localiser les défauts multiples.

Introduction générale

Mon objectif à travers ce mémoire est de développer une technique basée sur les réseaux de neurones convolutifs qui font partie de l'intelligence artificielle capable de traiter les signaux ultrasonores et de détecter les défauts multiples présents dans toutes les conditions.

Dans cette technique nous allons construire une architecture de réseau de neurones convolutif avec des différents paramètres. Cette architecture sera entraînée et testée par une base de données simulée par matlab contenant des signaux ultrasonores qui représentent trois classes de défauts. Ensuite pour valider notre architecture nous allons effectuer un contrôle ultrasonore sur diverses pièces afin d'utiliser les informations acquises dans la prédiction des défauts multiples

Les réseaux de neurones, branche de l'Informatique fondamentale s'est développée avec pour objectif la simulation des comportements du cerveau humain. Les premières tentatives de modélisation du cerveau sont anciennes et précèdent même l'ère informatique. C'est en 1943 que Mc Culloch (neurophysiologiste) et Pitts (logicien) ont proposé les premières notions de neurone formel. Ce concept fut ensuite mis en réseau avec une couche d'entrée et une sortie par Rosenblatt en 1959 pour simuler le fonctionnement rétinien et tacher de reconnaître des formes. C'est l'origine du perceptron. Cette approche dite connexionniste a atteint ses limites technologiques, compte tenu de la puissance de calcul de l'époque, mais aussi théoriques au début des années 70.

Aujourd'hui, les réseaux de neurones ont de nombreuses applications dans des domaines très variés, on peut citer quelque domaine comme le domaine de traitement d'image (compression d'images, reconnaissance de caractères et de signatures, reconnaissance de formes et de motifs, classification), le domaine traitement du signal (traitement de la parole, identification de sources, filtrage, classification) et le domaine de contrôle industriel (diagnostic de pannes, commande de processus, contrôle qualité, robotique, détection des défauts dans les machines)

Chapitre I :

Généralités sur le contrôle non destructif CND (Les ultrasons)

1- Le contrôle non destructif : méthodes d'examen et de contrôle.

1-1. Introduction :

On regroupe sous le vocable essais non destructifs ou encore contrôles non destructifs (ce dernier évoquant mieux l'aspect qualité industrielle que le premier qui évoque plutôt les examens en laboratoire) l'ensemble des techniques et procédés aptes à fournir des informations sur la santé d'une pièce ou d'une structure sans qu'il en résulte des altérations préjudiciables à leur utilisation ultérieure. Le terme de santé, s'il souligne une certaine parenté avec le domaine des examens d'aide au diagnostic médical, comme la radiologie ou l'échographie, délimite bien l'objectif des contrôles non destructifs qui est la mise en évidence de toutes les défauts susceptibles d'altérer la disponibilité, la sécurité d'emploi et/ou, plus généralement, la conformité d'un produit à l'usage auquel il est destiné. En ce sens, le contrôle non destructif (CND) apparaît comme un élément majeur du contrôle de la qualité des produits. Il se différencie de l'instrumentation de laboratoire et industrielle puisque l'objet est de détecter des hétérogénéités et anomalies plutôt que de mesurer des paramètres physiques tels que le poids ou les cotes d'une pièce. Taux de croissance sur le moyen terme.

À travers son objectif, on aura compris que le contrôle non destructif est essentiel pour la bonne marche des industries qui fabriquent, mettent en œuvre ou utilisent les matériaux, les produits, les structures de toutes natures. À l'heure où la qualité est devenue un impératif difficilement contournable, le champ d'application des CND ne cesse de s'étendre au-delà de son domaine d'emploi traditionnel constitué par les industries métallurgiques et les activités où la sécurité est primordiale, telles que le nucléaire et l'aéronautique.

Les méthodes de CND sont utilisées soit pour évaluer des grandeurs caractéristiques du produit (épaisseur, conductivité . . .), soit pour déceler la présence de défauts et les caractériser. Parmi les méthodes les plus utilisées, on peut citer les ultrasons, les méthodes utilisant des rayonnements ionisants (radioscopie) et les méthodes électromagnétiques (magnétoscopie, courants de Foucault . . .). Le choix d'une méthode dépend d'un grand nombre de facteurs tels que la nature des matériaux constituant les pièces à contrôler, la nature de l'information recherchée (défaut débouchant ou enfoui ...), les conditions de mise en œuvre . . . etc.

Dans ce chapitre, nous présentons les différentes techniques du contrôle non destructif (CND) existantes, leurs principes de fonctionnement, leurs avantages et leurs inconvénients. On va se baser sur les ultrasons, cette technique d'inspection sera présentée de manière détaillée.

2- Les techniques du contrôle non destructif :

2-1. L'examen visuel

L'examen visuel est le premier des procédés de contrôle et le plus général, En examen préalable, l'inspection visuelle d'un objet, d'une structure, d'un assemblage tel qu'une soudure permettra de guider un observateur expérimenté dans la définition d'une autre technique : choix de l'angle de tir en radiographie, direction de magnétisation, fréquence ultrasonore. L'examen visuel direct des pièces peut constituer un contrôle suffisant pour la détection des défauts débouchant en surface et surtout des hétérogénéités locales et superficielles (tâches de différentes natures) constituant. [1]

2-2. Ressuage

Cette méthode complète l'examen visuel en faisant apparaître des défauts de surface dans un contraste coloré ou fluorescent. Son principe est simple et se déroule en plusieurs étapes. La première consiste à bien nettoyer la pièce à contrôler. Ensuite Un liquide coloré ou fluorescent dit "pénétrant" est appliqué sur la surface à contrôler. Il va s'infiltrer à l'intérieur des défauts (fissures, porosités...). L'excès de pénétrant est ensuite éliminé par un lavage adapté. La surface est alors recouverte d'une fine couche de "révélateur" qui absorbe le pénétrant contenu dans les défauts et donne une tache colorée en surface plus large que le défaut, permettant ainsi de la localiser (voir la figure 1.1). [2]




Figure 1.1 - Principe du ressuage

2-3. Magnétoscopie

C'est une technique qui révèle les défauts débouchant ou sous-cutanés. Toutefois, elle ne s'applique qu'aux matériaux et alliages ferromagnétiques (fer, acier, fonte,...). Cette technique consiste à soumettre la pièce à un champ magnétique de valeur définie en fonction de la pièce. Une poudre magnétique est ensuite projetée à la surface et se répartit de façon homogène si la pièce est saine, les discontinuités superficielles provoquent à leur endroit des fuites magnétiques. Lorsqu'un défaut est présent dans la pièce au voisinage de la surface, l'orientation du flux de l'induction magnétique est modifiée localement et son intensité augmente en surface. Il apparaît alors une concentration de particules magnétiques qui révèle la présence du défaut comme l'illustre la figure 1.2. [1-2]




Figure 1.2 - Principe de la magnétoscopie

2-4. Radiographie

Le principe de la radiographie est le même que pour le domaine médical. La méthode met à profit l'absorption par la matière des rayonnements électromagnétiques ionisants.

L'examen de la structure ou de l'état interne d'un objet par radiographie consiste à le faire traverser par un rayonnement électromagnétique de très courte longueur d'onde (rayon X, ou γ) et à recueillir le rayonnement résiduel non absorbé sur un récepteur approprié, un film dans la plupart des cas, comme l'illustre la figure 1.3. [1-2]




Figure 1.3 - Principe de la radiographie

2-5. Thermographie

La thermographie repose sur l'étude de la diffusion de la chaleur dans la cible à contrôler. Une quantité de chaleur est une quantité d'énergie stockée dans la matière et la température en est un indicateur mesurable.

La thermographie consiste en l'interprétation des cartes thermiques (thermogrammes) des surfaces observées. Une distinction est faite entre la thermographie passive qui résulte de la simple observation des gradients thermiques sur une pièce, et la thermographie active lorsqu'une perturbation thermique a été volontairement générée pour le contrôle (par une source laser par exemple).

Les discontinuités dans la pièce se traduisent par des différences de température sur l'image. L'acquisition des images thermiques s'obtient alors à l'aide d'une caméra thermographique. [2]

2-6. CND par courants de Foucault

Cette méthode s'applique à tous les matériaux conducteurs de l'électricité. Elle consiste à placer une pièce conductrice dans un champ magnétique variable dans le temps. Celle-ci est alors parcourue par des courants induits. Ainsi, une bobine placée à proximité d'une pièce conductrice et parcourue par un courant variable, alternatif par exemple, génère de tels courants induits dans la pièce. Ces courants créent eux-mêmes un flux magnétique induit qui s'oppose au flux d'excitation, modifiant par là-même la F.E.M de la bobine.

C'est l'analyse de cette variation de F.E.M qui fournira les informations exploitables pour un contrôle. (Voir figure I.4) [2]




Figure 1.4 - principe de la détection par courants de Foucault

2-7. Les ultrasons

Le contrôle par ultrasons consiste à émettre et faire se propager une onde ultrasonore dans la pièce à inspecter puis à recueillir et analyser l'onde à l'issue de son interaction avec le matériau. Sur la base de ce principe très général, il existe de nombreuses techniques spécifiques, suivant que le contrôle est effectué en transmission ou bien en réflexion, suivant que les dispositifs en émission et en réception sont confondus ou non, suivant le type et l'inclinaison des ondes ultrasonores utilisées, etc.

La modalité de contrôle la plus répandue, dite en réflexion, est comparable à l'échographie médicale. L'émetteur et le récepteur (confondus ou non) sont positionnés du même côté de la pièce. Le récepteur recueille les échos engendrés par réflexion ou diffraction sur les obstacles rencontrés par l'onde, tels que les défauts, les interfaces entre matériaux ou encore la surface de la pièce.

Son plus grand avantage c'est ça richesse d'information fournie et la Possibilité de localiser les défauts avec précision, de dimensionner les défauts et d'imager la région inspectée.

Son inconvénient c'est qu'il y a souvent une notion de bruit à prendre en compte. Son principe et les techniques utilisées seront développés dans les parties suivantes.

3- Classement et performances des procédés de CND

Il existe plusieurs techniques de contrôle et chaque technique à ses avantages, ses inconvénients, et son domaine d'utilisation comme illustre le tableau 1.1. [4]

Tableau 1.1 – le classement des procédés de contrôle non destructif : caractéristiques [4]

Type de procédés	Méthodes de contrôle	Principes physiques	Types de Défauts détectés	Domaine d'application	Points forts	Points faible
Optiques	Examen visuel direct ou assisté	Vision Perturbation d'une réflexion	Défauts débouchants, Chants, fissures, Criques, trous	Contrôle manuel de tous produits à surface accessible	souples	Productivité, fiabilité
	Contrôle laser			Contrôle automatisés de bandes et tôles	productivité	Taux de fausses alarmes
	Contrôle TV	Formation d'une image	Défauts d'aspect, taches	Contrôle automatique en fabrication des produits divers	Productivité	Défauts fins
	Interférométrie holographie	Détection de micro-déformation provoquées	Déaminations, décollements	Contrôle en atelier de parois non métalliques	Contrôle des composites	Interprétation, Productivité
	Thermographie infrarouge	Cartographie de perturbations thermiques	Délaminations, hétérogénéités divers	Idem Contrôle sur site	Cartographie	Caractérisation des défauts
Rassuage	Rassuage	Effet de capillarité	Défauts fins débouchants	Contrôle manuel de tous produits à surface accessible	Simplicité faible coût	Productivité, peu quantitatif
Flux de fuite magnétique	Magnétoscopie	Accumulation de poudre	Défauts fins débouchants et sous-cutanés	Produits ferromagnétiques (acier)	Sensibilités	Réservé aux acier peu quantitatif
	Détection de flux de fuite	Distorsion d'un flux magnétique	Défauts fins débouchants		Sensibilité Automatisation	Fragilité des sondes
Electro-magnétiques	Courants de Foucault	Perturbations d'un courant	Défauts fins débouchants	Contrôle en ligne et sur chantier de tous produits métalliques	Sensibilité Automatisation	Matériaux non conducteurs interprétation
	Potentiel	Perturbations	Mesure de profondeur de défauts	Tous produits	Simplicité	Contrôle

	électrique	d'un courant		conducteurs	Faible coût	manuel Lent
	Hyperfréquences	Transmission ou réflexion radar	Hétérogénéités divers	Matériaux peu conducteurs	Contrôle sans contact	Interprétation du signal

Type de procédés	Méthodes de contrôle	Principes physiques	Types de Défauts détectés	Domaine d'application	Points forts	Points faible
Rayonnement s ionisants	Radiographie X	Atténuation d'un flux	Défauts internes	Contrôle en atelier et sur site de tous matériaux	Cartographie	Protction
	Radiographie Y				Souplesse de réglage	Détection des fissures
	Radioscopie en temps réel			Contrôle en ligne	Fortes épaisseurs	Profondeur des défauts
	Tomographie X				Productivité	Résolution limitée
	Neutronographie			Contrôle de structures non métalliques	Imagerie en coupe	Côt Productivité
	Diffusion Compton	Corps hydrogénés				
	Rétrodiffusion	Délamination	Contrôle des composites	Complète la Radiographie	Equipement Condition d'emploi	
Vibrations mécaniques	Ultrasons	Perturbation d'une onde Echographie	Défauts internes Défauts débouchants	Contrôle manuel ou automatique de la majorité des matériaux	Grande sensibilité Nombreuses méthodes d'ascultation	Conditions d'essai Interpretation des échos Couplage
	Emission acouqtisue	Emission provoquée par sollicitation mécanique	Criques fissures	Parois de gros récipients Structure divers	Contrôle global avec localisation des défauts	Inteprération Bruits parasites
	Essais dynamiques	Perturbation d'un amortissement Mesure de vitesse	Criques fissures	Contrôle de pièces moulées	productivité	Qualitatif
Tests d'étanchéité	Essais hydrostatiques	Détection de bulles	Défauts débouchants dans les joints ou parois, zone perméable	Tubes et enceintes en tous matériaux	Grande étendue de flux de fuite selon la méthode	Contingences divers selon la méthode
	Test avec gaz traceur –halogènes, hélium	Détection chimique				
	Détection sonor	Bruit acoustique				

4- Le contrôle non destructif par ultrasons

4-1. Définition Le contrôle non destructif par ultrasons

Le contrôle non destructif par ultrasons est un procédé de recherche du manque de matière (défaut) dans un matériau. Il permet de localiser et de dimensionner les discontinuités (défauts) à l'aide d'ondes acoustiques. Le contrôle US consiste à observer les échos produits par un manque de matière lors de la propagation d'une vibration de très haute fréquence et de très courte durée dans le matériau. (Voir figure 1.5)

La vibration est transmise et reçue par un même capteur appelé traducteur « palpeur » qui comporte un élément piézoélectrique apte à transformer un signal électrique en vibration mécanique et inversement. L'impulsion acoustique émise se propage dans tout le matériau et est réfléchiée par tout obstacle se trouvant sur son parcours. Le parcours de l'onde ultrasonore définit le faisceau acoustique : il est directif et limité dans l'espace. Il peut être utilisé sur pratiquement tout type de matériau.

Le contrôle de toute la pièce oblige l'opérateur à déplacer le traducteur qui est un dispositif électronique appelé aussi palpeur sur toute la surface de la pièce à contrôler.

Pour effectuer un examen ultrasonore d'une pièce mécanique l'opérateur doit fournir un certain nombre de choix :

- Matériels utilisés (appareil, traducteur, bloc de référence ...)
- L'exploration (balayage du traducteur)
- Sensibilité du contrôle
- Critères d'acceptation Le matériel utilisé en contrôle par ultrason est léger et portable

Le contrôle par ultrasons peut être facilement mis en œuvre sur le site de production. [4]

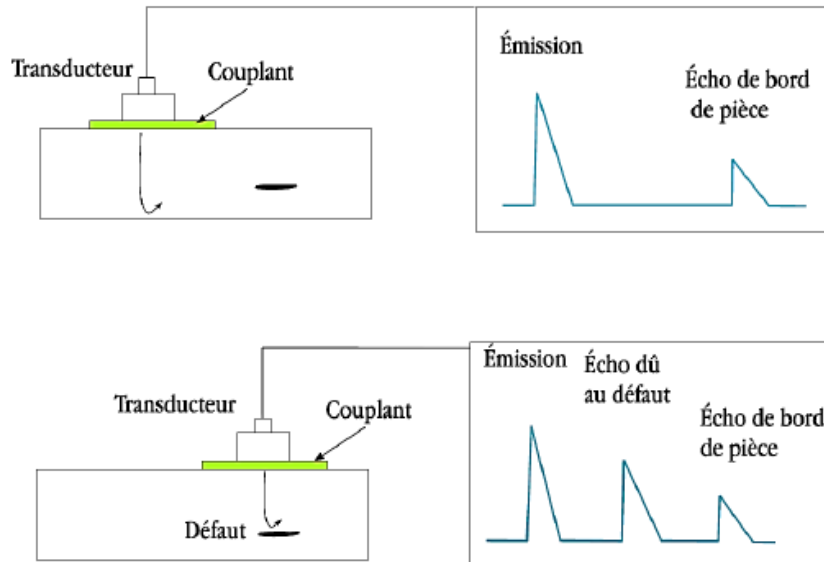


Figure 1.5 - Principe du contrôle par Ultrasons

4-2. Propagation des ondes

Le contrôle par ultrasons est basé sur la transmission et la réflexion d'onde de type ultrasons à l'intérieur d'un matériau. Une onde ultrasons est émise par un palpeur placé sur la surface du matériau à contrôler et se propage dans le matériau. Lorsque ces ultrasons rencontrent une interface délimitant deux milieux ayant des impédances acoustiques différentes, il y a réflexion. Les ultrasons réfléchis sont captés par un palpeur (qui peut être le même que l'émetteur). Il y a création d'un « écho ». Dans le cas d'une pièce comportant deux surfaces, la détection de défaut se fait en comparant le temps mis pour faire un aller-retour dans l'épaisseur de la pièce et le temps mis pour la réflexion sur un défaut. D'un point de vue pratique, on utilise un écran d'oscilloscope. Les échos sont représentés par des pics sur l'écran. [3]

4-3. Production des ondes ultrasonores

Les ondes ultrasonores se produisent par un transducteur appelé palpeur. Il joue le rôle d'un convertisseur. Lors de l'émission, il convertit l'énergie électrique qu'on lui envoie en énergie acoustique et lors de la réception, il convertit l'énergie acoustique reçue par la pièce en énergie électrique. [5]

Il existe des différents types de transducteurs on peut citer :

- Transducteurs électromagnétiques

- Transducteurs électroacoustiques
- Transducteurs piézoélectrique

Nous allons s'intéressé par Les transducteurs piézoélectriques à cause de leurs capacité de couvrir tout le spectre ultrasonores et son utilisation dans notre contrôle

4-4. Palpeurs piézoélectriques

De façon générale, un palpeur ultrasonore comporte, outre la pastille céramique dont les faces sont métallisées et raccordées à un connecteur électrique, une face avant de protection et de couplage et un bloc amortisseur arrière pour, à la fois, dissiper l'énergie rayonnant vers l'arrière et moduler le spectre ultrasonore par amortissement de la résonance mécanique de la pastille traductrice. Une bobine électrique d'accord ou un transformateur adaptateur d'impédance peut être inclus dans le boîtier, constituant l'ensemble du palpeur qui est généralement utilisé en émetteur-récepteur (figure 1.6). [4]




Figure 1.6 - Structure d'un palpeur ultrasonore

Il existe plusieurs familles de palpeurs piézoélectriques adaptées aux différents modes d'utilisation : contrôle par contact ou en immersion, nature du produit à sonder, des défauts, etc. Les 4 types de palpeurs les plus utilisés dans l'industrie sont les suivants: palpeur droit cylindrique, palpeur d'angle à sabot, palpeur droit focalisé, palpeur droit double avec émission et réception séparées. Certaines applications particulières font appel à des palpeurs spéciaux tels que les palpeurs droits rectangulaires, les palpeurs à

focalisation cylindrique et les barrettes multi-palpeurs, nées dans le domaine médical et dont l'emploi se développe dans l'industrie.

On caractérise un palpeur ultrasonore par les 2 paramètres à la base des lois de propagation rappelées précédemment : sa fréquence d'oscillation et son diamètre. On ajoutera la distance focale (dans l'eau) pour un palpeur focalisé, et l'angle de réfraction (dans l'acier) pour les palpeurs d'angle. Les caractéristiques électriques devront être connues pour adapter le matériel électronique et le câble de liaison. On se contente souvent de caractériser le spectre de fréquence par un classement qualitatif : large bande (palpeur amorti), bande étroite. La tendance est toutefois de mieux caractériser le matériel en relevant le spectre réel et surtout la cartographie du faisceau ultrasonore (dans l'eau) en régime impulsionnel. [4]

4-5. Différents types d'ondes des ultrasons

Les ondes ultrasonores, vibrations élastiques de la matière, ont des propriétés liées aux caractéristiques élastiques du support matériel. Ainsi, dans les liquides et les gaz, qui sont des milieux n'offrant aucune résistance au cisaillement, les ondes ultrasonores sont essentiellement des vibrations longitudinales, les particules matérielles se déplaçant, par rapport à leur position d'équilibre, parallèlement à la direction de propagation de l'onde, engendrant des fronts de compression-décompression, eux-mêmes perpendiculaires à cette direction. Ce type d'onde se retrouve dans les solides et est d'ailleurs le plus utilisé en pratique. Toutefois, un autre mode, utilisant le cisaillement, peut exister : mode d'onde transversale pour lequel les vibrations des particules s'exercent perpendiculairement à la direction de propagation.

Ces deux types d'ondes, les plus couramment rencontrés en contrôle non destructif, sont des ondes de volume ; il est possible aussi de générer d'autres types d'ondes dont l'existence dépend en particulier de la configuration du support de propagation. Il y a tout d'abord les ondes de surface, ondes composites constituées à la fois par des déplacements longitudinaux et transversaux, et dont les plus connues et utilisées sont les ondes de Rayleigh ; d'autres modes sont possibles et connus : ondes rampantes de Love, ondes de Bleustein – Gulyaev. Lorsque le support a des dimensions du même ordre de grandeur que la longueur d'onde, cela génère des modes vibratoires particuliers : ondes de Lamb dans les tôles, il s'agit d'ondes dispersives avec mode de vibration symétrique ou antisymétrique ; ondes guidées dans les tiges et barres. Les ondes de Lamb sont utilisées

industriellement pour le contrôle des tôles minces métalliques et de certains composites. [6] [7] (voir figure 1.7)




Figure 1.7- Types d'ondes et modes de propagation des ultrasons

4-6. Vitesse, directivité, atténuation

On démontre par la théorie des milieux élastiques que les vitesses de propagation des ondes ultrasonores longitudinales (V_L) transversales (V_T) et de Rayleigh (V_R), en m/s , sont liées aux caractéristiques du matériau par les relations suivantes :

$$V_L = \sqrt{\frac{E(1-\sigma)}{\rho(1+\sigma)(1-2\sigma)}}$$

$$V_T = \sqrt{\frac{E}{2\rho(1+\sigma)}}$$

$$V_R \approx 0.9V_T$$

Avec : E (Pa) module d'Young, σ (sans dimension) coefficient de Poisson, ρ (kg/m^3) masse volumique

Le tableau 1.2 donne quelques exemples de vitesses moyennes V_L et V_T pour les matériaux couramment utilisés en CND. Il s'agit de valeurs moyennes, car les paramètres élastiques des matériaux dépendent de l'état physique et chimique précis de ceux-ci (analyse et microstructure pour les métaux, par exemple). Les ondes de Lamb sont des ondes dispersives ; leur vitesse dépend de la fréquence et, de plus, la vitesse de propagation du front d'onde (vitesse de phase) est différente de la vitesse de propagation de l'impulsion énergétique donnée par l'émetteur (vitesse de groupe). Des diagrammes donnent ces valeurs en fonction du mode de vibration et du produit fréquence \times épaisseur de la tôle. [8]

Chapitre I : Généralités sur le contrôle non destructif CND (Les ultrasons)

La longueur d'onde λ d'un train d'onde ultrasonore se déduit de la vitesse de propagation

par la relation simple suivante :
$$\lambda = \frac{V}{f}$$

Où f est la fréquence de la vibration.

Tableau 1.2 – la vitesse et l'impédance des ondes ultrasonores

Matériaux	Masse Volumique (10^3 Kg/m^3)	Vitesse des ondes longitudinales m/s	Vitesse des ondes transversales m/s	Impédance acoustique ($10^3 \text{ Kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$)
Aciers	7.8	5900		46
Fonte	7.2	4600	3250	33
Aluminium	2.7	6300	2150	17
Cuivre	8.9	4700	3100	42
Laiton	8.5	4500	2250	38
Béton	2.5	4500	2100	11
Muscle	1.0	1600		1.6
Araldite	1.2	2500		3
Plexiagls	1.2	2700	1050	3.2
Verre	2.5	5650	1100	14
Huile	0.8	1500	3400	1.2
Glycérine	1.3	1900		2.5
Eau	1.0	1480		1.5
Mercure	13.6	1450		20
Quartz	2.7	5750		15
Titanate	5.7	4400		35
Air	$1.3 \cdot 10^{-3}$	330		$4 \cdot 10^{-4}$

Cette longueur d'onde λ est à prendre en considération dans la propagation des ondes, en particulier vis-à-vis de l'étalement du faisceau ultrasonore (directivité) et de l'atténuation de l'onde par le milieu. Nous avons vu que les ultrasons utilisés en CND se situent dans la gamme des fréquences 1 à 10 MHz, ce qui correspond, dans l'acier par exemple, à des longueurs d'onde de 0,6 à 6 mm en mode longitudinal.

À ces courtes longueurs d'onde, les ultrasons se propagent essentiellement en ligne droite selon un faisceau plus ou moins étalé, constitué d'un lobe principal dans lequel la plus grande partie de l'énergie est concentrée (figure 1.8).

C'est cette propriété qui les rend utiles pour localiser les défauts. Près de la source ultrasonore, on peut démontrer que le faisceau est l'objet d'interactions vibratoires assez complexes donnant lieu à des maximums et des minimums d'énergie sur l'axe de propagation (figures 1.9 et 1.10) [8] ; il s'agit du champ proche ou zone de Fresnel dont la longueur L est donnée par la relation :

$$L = \frac{D^2}{4\lambda}$$

D étant le diamètre de la source. Ensuite, l'énergie devient monotone et le faisceau diverge selon un angle d'étalement 2θ tel que :

$$\theta \approx 1.22\lambda/D$$




Figure 1.8 – Divergence du faisceau d'ultrasons




Figure 1.9 – Intensité acoustique sur l'axe du faisceau




Figure 1.10 – Distribution de l'amplitude perpendiculairement à l'axe

Il s'agit du champ éloigné ou zone de Fraunhofer, située en pratique à quelques centimètres du transducteur et donnant lieu à un étalement en général inférieur à quelques dizaines de degrés d'angle.

L'énergie dans l'axe décroît régulièrement à cause de l'étalement du faisceau, mais aussi à cause de l'atténuation de l'onde par le milieu.

L'atténuation ultrasonore suit assez bien la loi exponentielle de la forme :

$$I = I_0 \exp(-\alpha x)$$

Avec α coefficient d'atténuation

x épaisseur traversée.

On peut considérer cette atténuation, en particulier dans les métaux, comme faible eu égard aux puissances et aux sensibilités de détection utilisables ; cela explique les grandes possibilités pratiques du contrôle par ultrasons. α varie de 1 dB/m pour l'eau à 5 à 200 pour les métaux et 500 pour le plexiglass (à 2 MHz).

L'atténuation résulte de plusieurs effets :

L'absorption ultrasonore par le milieu proportionnel à la fréquence et qui correspond à la dissipation thermique par frottement.

La diffusion ultrasonore par le milieu, liée à sa structure, à son anisotropie, à son caractère parfois diphasique ; la longueur d'onde, donc la fréquence, est à prendre en compte pour définir les domaines et les lois d'atténuation par diffusion ; on montre ainsi que l'atténuation dans un solide poly cristallin simple, de diamètre de grain homogène d , est de la forme :

$$\alpha = \alpha_1 f + \alpha_2 d^3 f^4$$

Si $\lambda \gg d$ (diffusion de Rayleigh).

On voit ici l'importance que jouent, à la fois, la fréquence des ultrasons et la nature du matériau sur l'atténuation et donc sur la possibilité de mettre en œuvre le contrôle ultrasonore d'une pièce. [4]

4-7. Changement de milieu : réflexion, transmission

Lorsqu'un faisceau acoustique arrive en incidence normale sur l'interface entre deux milieux de natures différentes, tout comme en optique, une partie de l'onde incidente est transmise dans le second milieu, alors que l'autre partie est réfléchiée en sens inverse dans le premier milieu. Ces phénomènes de réflexion/transmission sont régis par un concept d'impédance acoustique

$Z = \rho V$, produit de la masse volumique ρ du matériau par la vitesse V des ultrasons dans ce milieu considéré (noter que l'impédance acoustique utilisée dans le domaine sonore est définie différemment). Les intensités acoustiques réfléchies (I_R) et transmises (I_T), relativement à l'intensité initiale (I_0), sont données par les relations suivantes :

$$\frac{I_R}{I_0} = \left(\frac{Z_1 - Z_2}{Z_1 + Z_2} \right)^2$$

$$\frac{I_T}{I_0} = \frac{4Z_1 Z_2}{(Z_1 + Z_2)^2}$$

Avec Z_1 et Z_2 impédances acoustiques des milieux 1 et 2, l'onde se propageant du milieu 1 vers le milieu 2.

Il est facile d'en déduire qu'une onde sera transmise intégralement si $Z_1 = Z_2$ c'est-à-dire si l'on a réalisé une parfaite adaptation d'impédance, condition bien connue en électronique des circuits. En fait, les couplages acoustiques en CND par ultrasons mettent souvent en jeu des matériaux à impédances acoustiques éloignées comme l'eau, l'acier, le plexiglas, on doit donc tolérer en pratique une perte importante d'énergie aux interfaces, perte qui devra être compensée par une grande sensibilité à la réception de l'onde en retour. Dans des cas particuliers, comme la microscopie acoustique, on devra choisir un couplant liquide mieux adapté, à forte impédance, comme le mercure par exemple. Ces relations montrent, par ailleurs, et cette fois-ci de façon favorable, que la sensibilité de la détection ultrasonore par échos sur un défaut est très grande, puisqu'en général le rapport $\frac{Z_1}{Z_2}$ de l'impédance du matériau solide testé (métal par exemple, avec $Z_1 > 15 \times 10^6 \text{Kg.m}^{-2}.\text{s}^{-1}$) à celle du défaut (porosité ou fissure remplies d'air avec $Z_2 = 10^{-3} \times 10^6 \text{Kg.m}^{-2}.\text{s}^{-1}$) sera très grande correspondant à une réflexion totale de l'énergie ultrasonore. De plus, l'expérience montre que cette réflexion reste totale même lorsque l'épaisseur de la fissure est infime et bien inférieure à la longueur d'onde λ . [4]

4-8. Réfraction

Lorsqu'un faisceau acoustique arrive avec une incidence non nulle α_1 sur une interface plane (sur la largeur utile du faisceau) entre deux milieux, on retrouve, comme ci-dessus, une décomposition de l'énergie en énergie réfléchiée et énergie réfractée. Cependant, un second phénomène peut prendre naissance, c'est la création de plusieurs ondes réfractées (ou réfléchies) de modes différents (figure 1.11).

Les orientations des faisceaux d'ondes réfléchies et réfractées sont définies par les lois de Descartes (ou de Snell), bien connues en optique, et où l'indice optique est ici remplacé par la vitesse V des ondes acoustiques considérées. On a les relations entre angles de réfraction et vitesse de l'onde :

$$\frac{\sin \alpha_1}{V_1} = \frac{\sin \alpha_{2L}}{V_{2L}} = \frac{\sin \alpha_{2T}}{V_{2T}}$$

On en déduit qu'il est possible, à partir d'une onde longitudinale dans le milieu 1, de créer dans le milieu 2 à la fois des ondes longitudinales et des ondes transversales ayant des directions de propagation différenciées. Le calcul de la condition sur les sinus montre qu'il

peut exister des angles d'incidence critiques au-delà desquels les ondes réfractées ne peuvent exister. [4]

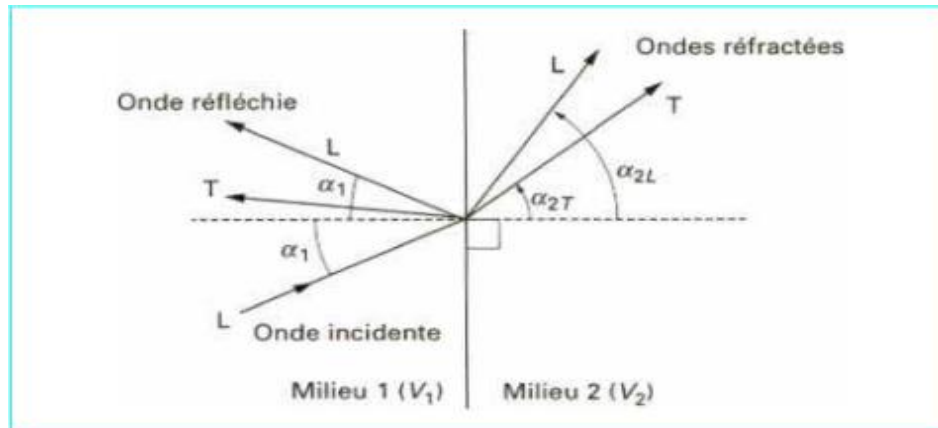


Figure 1.11 – Réflexion et réfraction des ondes ultrasonores

4-9. Méthodes de contrôle ultrasonore

4-9-1. Échographie ultrasonore

Connue désormais de tout un chacun par son utilisation médicale, l'échographie est aussi la méthode de loin la plus employée dans le contrôle non destructif industriel. Son principe, très simple, est celui du radar : on envoie, dans la zone à inspecter, de brèves impulsions ultrasonores et l'on recueille en retour des échos renvoyés par les diverses hétérogénéités susceptibles de créer des ruptures d'impédance acoustique. On obtient ainsi un échogramme comme cela est illustré dans un cas simple par la (figure 1.12) La distance entre échos correspond à des temps de propagation aller et retour de l'onde et permet donc de localiser les défauts en profondeur dans la pièce examinée.

L'amplitude relative des échos d'émission, de défauts et de fond permet d'avoir une estimation de l'importance du défaut. Il faut toutefois ici être prudent, même lorsque l'on applique des calculs de correction d'atténuation de propagation. Le parcours mis en œuvre pour essayer d'obtenir des échos de défaut peut être complexe et comporter des réflexions multiples, comme dans le cas du contrôle des soudures avec palpeur d'angle et ondes transversales par exemple (figure 1.13). [4]

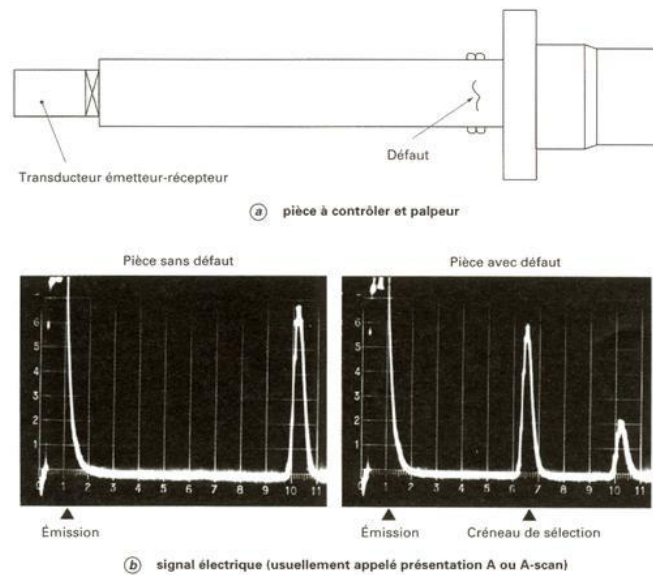


Figure 1.12 - Contrôle ultrasonore par échographie (ondes longitudinales)

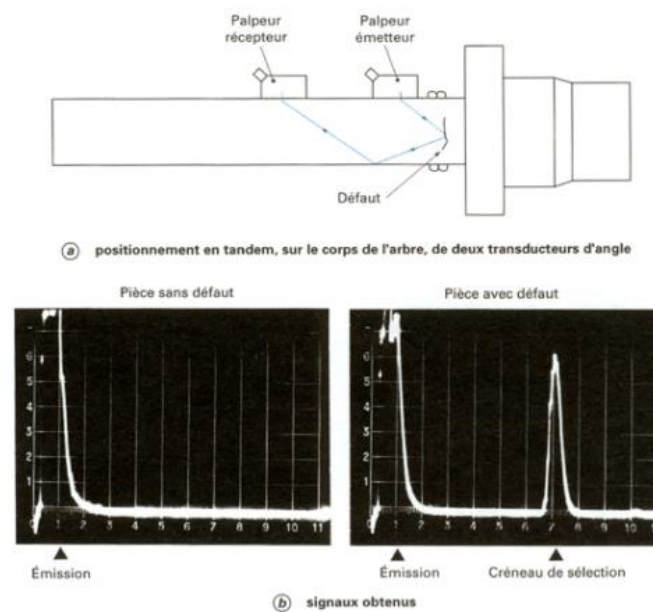


Figure 1.13 – Contrôle des soudures par la méthode tandem (ondes transversales)

4-9-2. Méthode par transmission

Elle met en œuvre un faisceau ultrasonore reliant deux palpeurs disposés de part et d'autre de la pièce sondée. Bien que décrite dans tous les manuels, son emploi a pratiquement disparu, sauf dans quelques cas particuliers où l'atténuation ultrasonore est extrêmement forte et interdit l'utilisation de la méthode par échos. Son inconvénient majeur est en effet le risque qu'il y a à attribuer l'atténuation du signal à la présence d'un

défaut alors que la cause peut être tout autre : rupture du couplage entre les palpeurs et la pièce, mauvais alignement, etc. [4]




Figure 1.14 – Différents modes de présentation

4-10. Mode de contrôle par ultrasons

Plusieurs méthodes sont utilisées selon la nature du contrôle par ultrason

a. Le contrôle en cuve d'immersion

Remplie en général d'eau additionnée d'un agent mouillant, permet d'assurer un couplage satisfaisant entre les palpeurs et la pièce à contrôler, tout en assurant une mobilité 3D à ces palpeurs, d'où des possibilités d'examen de pièces complexes grâce à un bras manipulateur programmé et aussi la facilité d'utiliser des palpeurs focalisés.

b. En contrôle manuel

Le contact direct à sec du palpeur sur la pièce n'est pas suffisant pour transmettre les ultrasons, il faut utiliser un agent de couplage généralement plus visqueux que l'eau, tel que graisse, colle, etc. [9]

Le palpeur doit être adapté à la nature du contrôle et aux conditions de couplage : en contrôle par immersion on surveillera son étanchéité, en contrôle par contact on s'assurera des performances anti-usure de la face avant. Le câble de liaison avec l'équipement électronique doit absolument être adapté à son emploi car, en cas contraire, des pertes de sensibilité et des distorsions spectrales peuvent rendre le sondage aléatoire. [4]

4-11. Appareillage d'émission-réception des ondes

Dans un appareil à ultrasons classique, en général portable par ailleurs, on peut distinguer quatre modules principaux :

— un émetteur d'impulsions électriques brèves, aptes à exciter le palpeur piézoélectrique avec une énergie notable ; les tensions appliquées sont ainsi de plusieurs centaines de volts sous 50Ω avec des temps de montée souvent inférieurs à 30 ns ; la fréquence de répétition des impulsions est de quelques centaines de hertz.

— un système d'amplification des signaux piézoélectriques dus aux échos de retour du sondage ; ces signaux sont faibles (quelques millivolts), aussi doit-on disposer d'un amplificateur performant : faible bruit, large bande (réglable), bonne linéarité sur au moins 100 dB.

— un démodulateur et un écran de visualisation qui permet de présenter l'échogramme en fonction du parcours des ultrasons dans la pièce sondée.

L'oscilloscope comportera donc une base de temps synchronisée par l'émetteur et réglable et programmable par affichage de la vitesse des ultrasons selon la matière auscultée et le mode de propagation choisi :

— un moniteur, fenêtre électronique de sélection d'une zone particulière dans l'échogramme, dans laquelle il est possible de placer un seuil d'alarme au-delà duquel les échos (de défauts) déclenchent un signal lumineux ou sonore.

L'essor de la micro-informatique a favorisé l'éclosion de nouvelles générations d'appareillages à ultrasons (figure 1.15). [4]

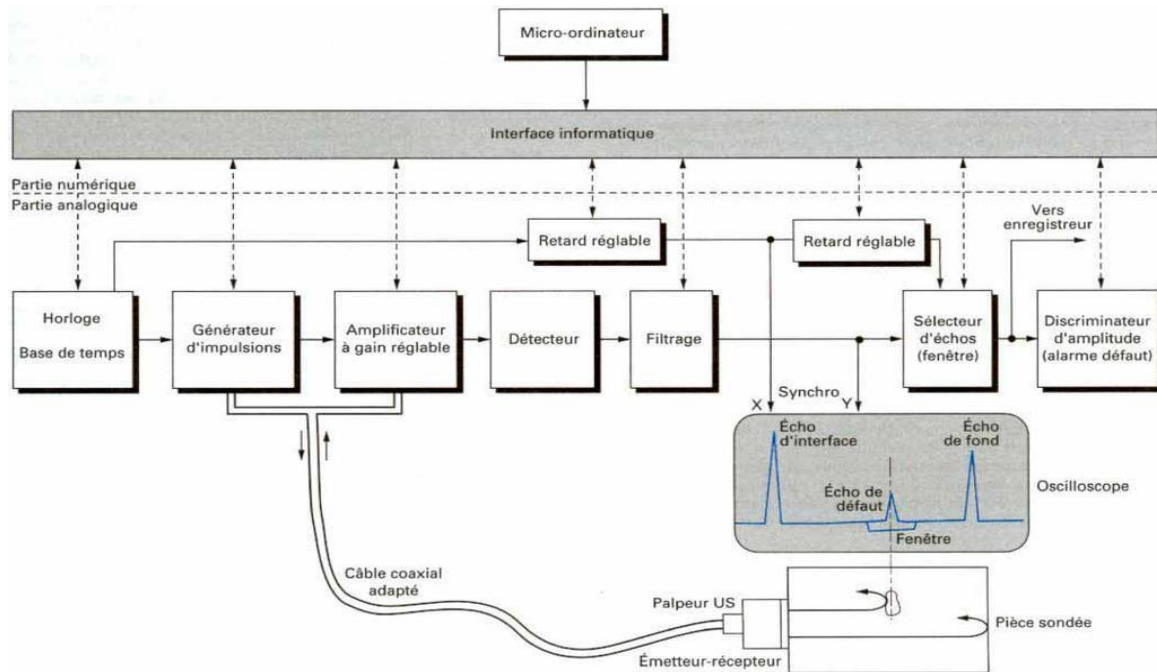


Figure 1.15 - Schéma de principe d'un appareil classique de contrôle par ultrasons

D'abord, des appareillages mariant un système classique analogique d'émission réception à un micro-ordinateur recevant les signaux en vue de les traiter, de les stocker ou de les éditer. Ensuite, une gamme d'appareils de contrôle ultrasonore (portables) bâtis autour d'un microprocesseur et ainsi aptes à assurer intrinsèquement des fonctions d'étalonnage, de réglage, de traitement telles que les compensations d'atténuation d'amplitude-distance (dites courbes AVG) qu'il était difficile de réaliser avec les appareils totalement analogiques. [4]

4-12. Étalonnage

L'étalonnage de l'ensemble appareillage et palpeur ultrasonore présente une grande importance, dans la mesure où l'on cherche à fournir des résultats de contrôle pertinents. On pourra, dans un premier temps, déterminer les caractéristiques de l'électronique et du palpeur : cela ne dispensera pas toutefois d'effectuer un tarage de l'ensemble, selon les procédures normalisées adaptées aux types de contrôles et d'industries concernés.

Soit on utilisera un bloc étalon comme la cale AFNOR NF A 09.310 qui permet en particulier de vérifier aisément les caractéristiques des palpeurs, soit on fera appel à des pièces de référence du type de celles à contrôler et possédant des défauts connus, naturels ou artificiellement créés. [4]

4-13. Principe de contrôle par ultrasons

La vibration mécanique engendrée par l'élément piézo-électrique du traducteur se propage dans la section de la pièce en se réfléchissant sur les faces. Une partie du faisceau acoustique est interceptée par le défaut et renvoyée vers le traducteur qui convertit la vibration en signal électrique. (Voir figure 1.16)

L'œil observe sur l'écran de visualisation un écho caractéristique apparaissant à une distance donnée sur la base de temps.

Il est alors possible de détecter la présence du défaut, d'évaluer sa position et son étendu. L'amplitude de l'écho reçue dépend de l'étendu et de l'orientation de la surface réfléchissante. On peut distinguer deux types de méthodes par Ultrasons :

1. Les Ultrasons dit « classiques » permettant de déceler des indications au cœur de la matière en utilisant des traducteurs de type Ondes longitudinales ou à Ondes inclinées.
2. Les mesures d'épaisseurs qui permettent de vérifier l'épaisseur restante d'un matériel (on peut établir une cartographie des zones examinées et étudier son évolution dans le temps). [11]




Figure 1.16 - Principe de contrôle par ultrasons

4-14. Champ d'application du contrôle ultrasonore

a. Détection des défauts internes

La détection de défauts internes par ultrasons est très pratiquée en contrôle de fabrication, en contrôle de recette, en surveillance de structure en service, en maintenance. La remarquable sensibilité de l'échographie ultrasonore à la moindre discontinuité ou hétérogénéité interne dans les matériaux, en particulier métalliques, en fait une méthode de choix, concurrente ou parfois complémentaire de la radiographie. Toutefois, en échographie ultrasonore, le choix des paramètres de sondage et l'interprétation des signaux recueillis ne sont pas toujours aisés et requièrent l'intervention d'un personnel spécialement qualifié. [4]

b. Localisation des défauts en profondeur

La localisation de défauts en profondeur est aisée lorsqu'on travaille en échographie. Il existe toutefois une zone sous la surface de couplage pour laquelle l'écho de défaut peut être noyé dans l'écho d'émission ou d'interface, ce qui peut rendre à la fois la détection et la localisation aléatoires. La localisation en plan se fera en relation avec le relevé manuel de la position du palpeur. Des équipements d'aide au sondage manuel par recopie du déplacement du palpeur permettent désormais l'utilisation des présentations B et C et favorise le dépouillement et la présentation des résultats. [4]

c. Dimensionnement des défauts

Le dimensionnement des défauts détectés est une préoccupation légitime du contrôleur en vue de les relier à des critères de nocivité technologique faisant en général l'objet d'une procédure normalisée ou spécifique. C'est un problème délicat auquel on peut toutefois donner des solutions pratiques simples. Deux cas se présentent en théorie, selon que le champ du palpeur est censé être supérieur ou inférieur à la dimension moyenne du défaut. Dans le premier cas, tout le défaut est éclairé par le faisceau et l'on peut relier l'amplitude de l'écho de retour à la dimension du défaut à l'aide de diagrammes qui prennent en compte l'ensemble des paramètres ultrasonores du sondage. Cette méthode, souvent appelée méthode AVG, est intéressante mais délicate d'emploi, surtout lorsque le défaut à dimensionner présente une orientation et une morphologie très éloignées des cas théoriques (généralement matérialisés par des réflecteurs constitués par des trous à fond plat forés dans les blocs d'étalonnage). Lorsque le défaut est plus grand que le faisceau,

ce que l'on peut parfois volontairement obtenir en utilisant l'étroit champ d'un palpeur focalisé, on trace son contour apparent, soit en repérant et en quantifiant le basculement entre écho de fond et écho de défaut (normes de contrôle de tôles fortes par exemple), soit en utilisant la règle « des – 6 dB » qui prend en compte un rapport 1/2 entre l'amplitude maximale de l'écho de défaut et celle obtenue lorsque les bords du défaut occultent environ à moitié la section du faisceau ultrasonore.[4]

4-15. La nature des pièces et des défauts détectés par les ultrasons

Les pièces inspectées sont de forme et d'épaisseur variables, les zones à risque sont celles soumises à des contraintes physiques importantes. Deux types sont principalement contrôlés :

- Les soudures, arasées ou non arasées.
- Les pièces moulées, telles que les coudes.

Les défauts, pouvant intervenir dans les pièces, sont répertoriés par des normes officielles, ils sont divisés en deux grandes catégories : les défauts volumiques et les défauts plans. Un défaut est considéré comme plan si sa largeur est inférieure à trois fois sa longueur, tous les autres défauts sont considérés comme des défauts volumiques. [12]

a. Défauts plans

Ce sont des défauts plus ou moins rectilignes. Ils représentent soit un manque de liaison inter-matières ou une rupture du métal. Ces défauts sont les plus nocifs. On peut citer les fissures, les manques de fusion et les manques de pénétration.

b. Défauts volumiques

Les défauts volumiques se définissent par la présence de corps étrangers occupant un volume de forme quelconque dans le matériau. On peut citer les inclusions et les cavités gazeuses (soufflures). [11]

4-16. Évolution du contrôle ultrasonore

L'évolution du contrôle ultrasonore va vers un plus grand recours à l'automatisation des opérations, avec l'objectif de simplifier, de fiabiliser les procédures, d'accroître la reproductibilité et la productivité des essais. Cela est rendu possible grâce aux progrès du matériel et des moyens de traitement de l'information. Il n'en reste pas moins que la qualification du contrôleur reste primordial pour les raisons exprimées plus haut.

Notons enfin le développement de l'utilisation en laboratoire d'un nouvel outil d'investigation et d'étude de la microstructure des matériaux : le microscope acoustique utilisant de très hautes fréquences ultrasonores, ce qui conduit à un fort pouvoir de résolution (quelques micromètres) accompagné malheureusement d'une faible pénétration des ondes dans la matière (quelques dixièmes de millimètre). [10]

5-17. Avantages et inconvénients du contrôle non destructif par ultrasons

Le contrôle par ultrasons peut être facilement mis en œuvre sur le site de production.

Les avantages du contrôle par ultrasons sont :

- Il est rapide - Les résultats sont immédiats.
- Il est utilisable sur la plus part des matériaux.
- Il n'est pas nécessaire d'avoir accès aux deux côtés de la pièce.

Et ses inconvénients sont :

- Un produit de couplage est exigé.
- Les défauts parallèles aux ondes ultrasonores sont difficiles à déceler.
- L'opérateur doit suivre une formation pour interpréter l'affichage de manière précise.
- Le matériel doit être étalonné de façon régulière pour chaque épaisseur et chaque type de matériau.

5-18. Problématique des ultrasons

Les problèmes major lors du contrôle non destructif par ultrasons sont le bruit et la difficulté de détection des défauts multiples

Tout d'abord Il existe 3 types de bruit :

- 1- **Le bruit électronique** présent dans les systèmes ultrasoniques. Ce bruit est dû au fait que toute résistance produit un bruit thermique à une température non nulle. Cette augmentation de la température mobilise les charges (électrons) à l'intérieur de la résistance, dont la somme qui peut être mesurée comme une tension aux bornes de la résistance. Ensuite, en raison du théorème central limite, la tension agrégée peut être modélisée comme un bruit
- 2- **Le bruit de structure** ou « herbe » est l'énergie ultrasonore diffusée par la structure revenant au transducteur lors du contrôle. Il est toutes fois reconnu que le bruit de structure est très important dans le cas d'hétérogénéité grande devant la longueur d'onde. Par déplacement du capteur, la composante du bruit de structure est aléatoire et peut être ainsi séparée du signal de propagation direct qui lui, est déterministe
- 3- **Le bruit de quantification** résultant de la conversion des données analogiques en données numériques. [5]

Les défauts multiples causent un problème major lors du contrôle non destructif par ultrasons.

La forme géométrique complexe des défauts multiple présents dans des différentes régions de la pièce peut compliquer l'inspection et la détection.

Lors du contrôle par ultrasons l'endroit, l'orientation, la forme géométrique complexe, la taille, la profondeur et le nombre des défauts peuvent affecter la caractérisation spectrale et temporelle des signaux ultrasonores.

Plusieurs techniques ont été utilisées pour résoudre ce problème comme la technique « split Spectrum processing » qui utilise des opérations non-linéaires pour améliorer la visibilité des défauts multiples. Mais la gamme spectrale de cette technique peut ne pas être suffisamment sensible aux variations des caractéristiques spectrales et temporelles des défauts pour les détecter. [5]

C'est pour ça, dans le prochain chapitre nous allons proposer une technique du Deep Learning appelé « convolution des réseaux de neurones » inspiré de l'intelligence artificielle qui utilise des architectures basées sur des réseaux de neurones artificielles pour la classification des défauts multiples.

6- Conclusion

Dans ce chapitre, nous nous sommes intéressés au contrôle non destructif par ultrasons que nous allons utiliser pour faire une simulation. Nous avons présenté tout d'abord les différentes méthodes du contrôle non destructif. Nous avons décrit ensuite le fonctionnement du contrôle en détaillant les différents défauts qu'on peut détecter. Enfin, nous avons présenté l'évolution, les avantages et les inconvénients du contrôle par ultrasons.

Chapitre II :

**Généralité sur Les réseaux de neurones
(Les réseaux de neurones convolutifs CNN)**

1- Introduction

L'intelligence artificielle est une discipline scientifique recherchant des méthodes de solution de problèmes à forte complexité logique ou algorithmique. L'apprentissage automatique champ d'étude de l'intelligence artificielle. Par conséquent, L'apprentissage profond (en anglais deep Learning, deep structured Learning, hierarchical Learning) est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

Dans ce chapitre nous allons mettre l'accent sur les réseaux de neurones qui constituent une partie de l'apprentissage profond. Ces derniers forment des sous-ensembles de l'intelligence artificielle

2- L'intelligence artificielle (IA)

L'intelligence artificielle (IA, ou AI en anglais pour Artificiel Intelligence) consiste à mettre en œuvre un certain nombre de techniques visant à permettre aux machines d'imiter une forme d'intelligence réelle.

L'IA se retrouve implémentée dans un nombre grandissant de domaines d'application. La notion voit le jour dans les années 1950 grâce au mathématicien Alan Turing. Dans son livre Computing Machinery and Intelligence, ce dernier soulève la question d'apporter aux machines une forme d'intelligence. Il décrit alors un test aujourd'hui connu sous le nom « Test de Turing » dans lequel un sujet interagit à l'aveugle avec un autre humain, puis avec une machine programmée pour formuler des réponses sensées. Si le sujet n'est pas capable de faire la différence, alors la machine a réussi le test et, Selon l'auteur, peut véritablement considéré comme « intelligente »

De Google à Microsoft en passant par Apple, IBM ou Facebook, toutes les grandes entreprises dans le monde de l'informatique planchent aujourd'hui sur les problématiques de l'intelligence artificielle en tentant de l'appliquer à quelques domaines précis. Chacun a ainsi mis en place des réseaux de neurones artificiels constitués de serveurs et permettant de traiter de lourds calculs au sein de gigantesques bases de données.




Figure 2.1 la Différence entre AI, Machine Learning et le deep Learning

2-1. Les origines de l'intelligence artificielle

Depuis au moins le premier siècle avant notre ère, l'Homme s'est penché sur la création de machines capables d'imiter le raisonnement humain. Le terme « intelligence artificielle » a été créé plus récemment, en 1955 par John McCarthy. En 1956, John McCarthy et ses collaborateurs ont organisé une conférence intitulée « Dartmouth Summer Research Project on Artificial Intelligence » qui a donné naissance au machine Learning, au deep learning, aux analyses prédictives et, depuis peu, aux analyses prescriptives. Un nouveau domaine d'étude est également apparu : la science des données.

2-2. L'importance de l'intelligence artificielle

De nos jours, êtres humains et machines génèrent des données plus vite qu'il n'est humainement possible de les absorber et de les interpréter pour prendre des décisions complexes. L'intelligence artificielle est la base de tout apprentissage par un ordinateur et représente l'avenir des processus décisionnels complexes. Par exemple, la plupart des êtres humains peuvent apprendre à ne pas perdre à une simple partie de morpion, alors qu'il existe 255 168 actions possibles, dont 46 080 mènent à un match nul. En revanche, les champions du jeu de dames sont plus rares, étant donné qu'il existe plus de 500×10^{18} (500 trillions) de coups possibles. Les ordinateurs sont capables de calculer ces combinaisons et les meilleures permutations possibles très efficacement, afin de prendre la bonne décision. L'IA (avec son évolution logique, le machine learning) et le deep learning représentent l'avenir de la prise de décisions.

2-3. Les applications de l'IA

Voici quelques exemples d'utilisation de l'IA au quotidien:

2-3-1. Achats en ligne et publicité

L'intelligence artificielle est fréquemment utilisée lorsqu'on fournit des recommandations personnalisées aux utilisateurs, basé (par exemple) sur leur historique de recherche ou d'achat ou encore sur leur comportement en ligne. L'IA est d'une très grande importance dans le monde du commerce - elle permet d'améliorer les produits, mieux gérer l'inventaire et la logistique, etc.

2-3-2. Recherche en ligne

Les moteurs de recherche évoluent alors qu'ils engrangent un flot massif de données fournit par les utilisateurs, afin de leur procurer des résultats plus pertinents.

Assistants numériques personnels

Les smartphones emploient l'IA pour proposer un produit aussi pertinent et adapté que possible. Les assistants virtuels (désormais partout présents) répondent aux questions, fournissent des recommandations et aide à gérer les tâches quotidiennes.

2-3-3. Traduction automatique

Les logiciels de traduction, basés sur la langue écrite ou parlée, repose sur l'intelligence artificielle pour fournir des traductions sans cesse améliorées. Cette approche s'applique également lors de la génération automatique de sous-titres.

2-3-4. Smart city

C'est l'utilisation des différents capteurs intelligents de collecte de données pour fournir des informations permettant de gérer efficacement les ressources et les actifs. Cela comprend les données collectées auprès des citoyens, des dispositifs mécaniques, des actifs, traitées et analysées pour surveiller et gérer les systèmes de circulation et de transport, les centrales électriques, les réseaux d'approvisionnement en eau, la gestion des déchets, les systèmes d'information, les écoles, les bibliothèques et les hôpitaux.

Le concept de ville intelligente intègre les TIC et divers dispositifs physiques connectés au réseau, constituant l'Internet des objets et l'intelligence artificielle, pour optimiser l'efficacité des opérations et des services urbains et se connecter aux citoyens.

2-3-5. Voitures

Alors que les véhicules autonomes ne sont pas encore devenus la norme, nos voitures utilisent déjà des fonctions de sécurité basées sur l'IA. L'UE a par exemple soutenu le financement de

VI-DAS, des capteurs automatiques qui détectent les situations potentiellement dangereuses et les accidents.

Le fonctionnement des systèmes de navigation repose fortement sur l'IA.

2-3-6. Cybersécurité

Les systèmes dotés de l'IA peuvent aider à détecter et combattre les cyberattaques et autres menaces, en utilisant le flot continu de données pour déceler des figures et remonter à la source des attaques.

2-3-7. L'IA contre la Covid-19

L'IA permet de lutter contre la Covid-19, en l'employant dans les aéroports lors de la production d'imageries thermiques ainsi que dans d'autres cas de figure. Dans le domaine médical, l'IA permet de détecter l'infection par lorsque les poumons de patients sont soumis à une tomographie par ordinateur. Elle a aussi permis de recueillir des données afin de suivre l'évolution des infections.

2-3-8. La lutte contre les fausses informations

L'IA permet de détecter les fausses informations et les cas de désinformation en parcourant le contenu des réseaux sociaux pour repérer des mots clés ou des termes alarmistes, en identifiant les sources peuvent être considérées comme étant fiables.

Apprenez-en plus sur la façon dont les députés souhaitent façonner la législation sur les données pour stimuler l'innovation et garantir la sécurité.

2-3-9. Santé

Les chercheurs étudient comment employer l'IA pour analyser un très grand nombre de données liées à la santé pour repérer des motifs récurrents qui mèneraient à de nouvelles découvertes et des moyens d'améliorer les diagnostics individuels.

Ils ont développé un programme d'IA qui répond aux appels d'urgence qui devrait détecter les cas d'arrêts cardiaques durant l'appel plus rapidement et fréquemment qu'un répartiteur médical. On trouve un autre exemple dans le projet cofinancé par l'UE, KConnect, qui développe des services de recherche et de texte multilingues qui aident les personnes à trouver les renseignements médicaux les mieux adaptés à leurs besoins.

2-3-10. Transport

L'IA pourrait aider à améliorer la sécurité, la rapidité et l'efficacité du transport ferroviaire en réduisant le frottement des roues, augmentant la vitesse des trajets et en favorisant la conduite autonome.

2-3-11. Fabrication

L'IA peut aider les fabricants européens à améliorer leur efficacité et réinstaller des usines en Europe en employant des robots lors du processus de fabrication ou en prédisant avec précision l'entretien et les pannes dans les usines connectées.

Le projet SatisFactory, cofinancé par l'UE, utilise des systèmes collaboratifs et de réalité augmentée pour accroître le bien-être au travail dans les usines connectées.

3- Le Machine Learning**3-1. Définition du Machine Learning**

Il s'agit d'une science moderne permettant de découvrir des patterns et d'effectuer des prédictions à partir des données en se basant sur des statistiques, sur du forage de données, sur la reconnaissance de patterns et sur les analyses prédictives. Les premiers algorithmes sont créés à la fin des années 1950. Le plus connu d'entre eux n'est autre que le Perceptron.

C'est une technologie d'intelligence artificielle permettant aux ordinateurs d'apprendre sans avoir été programmés explicitement à cet effet. Pour apprendre et se développer, les ordinateurs ont toutefois besoin de données à analyser et sur lesquelles s'entraîner. De fait, le Big Data est l'essence du Machine Learning et c'est la technologie qui permet d'exploiter pleinement le potentiel du Big Data.

Le Machine Learning est très efficace dans les situations où les insights doivent être découvertes à partir de larges ensembles de données diverses et changeantes, c'est à dire : le Big Data.

Pour l'analyse de telles données, il se révèle nettement plus efficace que les méthodes traditionnelles en termes de précision et de vitesse.

Par exemple, pour en se basant sur les informations associées à une transaction comme le montant et la localisation, et sur les données historiques et sociales, le Machine Learning permet de détecter une fraude potentielle en une milliseconde. Ainsi, cette méthode est nettement plus efficace que les méthodes traditionnelles pour l'analyse de données transactionnelles, de données issues des réseaux sociaux ou de plateformes CRM.

Le Machine Learning peut être défini comme une branche de l'intelligence artificielle englobant de nombreuses méthodes permettant de créer automatiquement des modèles à partir des données. Ces méthodes sont en fait des algorithmes.

Un programme informatique traditionnel effectue une tâche en suivant des instructions précises, et donc systématiquement de la même façon. Au contraire, un système Machine Learning ne suit pas d'instructions, mais apprend à partir de l'expérience. Par conséquent, ses performances s'améliorent au fil de son " entraînement " à mesure que l'algorithme est exposé à davantage de données. [13]

3-2. Fonctionnement du Machine Learning

Le Machine Learning est idéal pour exploiter les opportunités cachées du Big Data. Cette technologie permet d'extraire de la valeur en provenance de sources de données massives et variées sans avoir besoin de compter sur un humain. Elle est dirigée par les données, et convient à la complexité des immenses sources de données. Contrairement aux outils analytiques traditionnels, il peut également être appliqué aux ensembles de

données croissants. Plus les données injectées à un système Machine Learning sont nombreuses, plus ce système peut apprendre et appliquer les résultats à des insights de qualité supérieure. Le Machine Learning permet ainsi de découvrir les patterns enfouies dans les données avec plus d'efficacité que l'intelligence humaine. [13]

3-3. Les différents types d'algorithmes de Machine Learning

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

3-3-1. L'apprentissage supervisé

Les données utilisées pour l'entraînement sont déjà " étiquetées ". Par conséquent, le modèle de Machine Learning sait déjà ce qu'elle doit chercher (motif, élément...) dans ces données. À la fin de l'apprentissage, le modèle ainsi entraîné sera capable de retrouver les mêmes éléments sur des données non étiquetées. Parmi les algorithmes supervisés, on distingue les algorithmes de classification (prédictions non-numériques) et les algorithmes de régression (prédictions numérique). En fonction du problème à résoudre, on utilisera l'un de ces deux archétypes.

La classification et la régression sont deux problèmes de prédiction majeurs qui sont généralement traités dans l'exploration de données. La modélisation prédictive est la technique de développement d'un modèle ou d'une fonction utilisant les données historiques pour prédire les nouvelles données. La différence significative entre Classification et Régression réside dans le fait que la classification mappe l'objet de données d'entrée à certaines étiquettes discrètes. D'autre part, la régression mappe l'objet de données d'entrée aux valeurs réelles continues. [13]




Figure 2.2 La différence entre la classification et la régression

3-3-2. L'apprentissage non supervisé

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

Parmi les modèles non-supervisés, on distingue les algorithmes de clustering (pour trouver des groupes d'objets similaires), d'association (pour trouver des liens entre des objets) et de réduction dimensionnelle (pour choisir ou extraire des caractéristiques).

Une troisième approche est celle de l'apprentissage par renforcement. [13]

3-3-3. L'apprentissage renforcé

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

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

À chaque tentative, l'IA reçoit une récompense ou une punition en fonction des actions effectuées. Elle est programmée pour maximiser sa récompense, et tentera donc de trouver la méthode le lui permettant. [13]

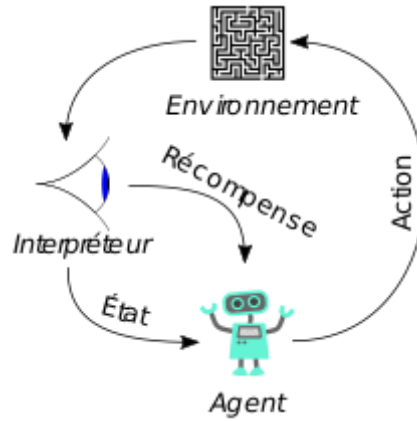


Figure 2.3 Le principe de l'apprentissage renforcé

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

3-3-3. - La différence entre l'apprentissage supervisé et non-supervisé

Types d'apprentissage

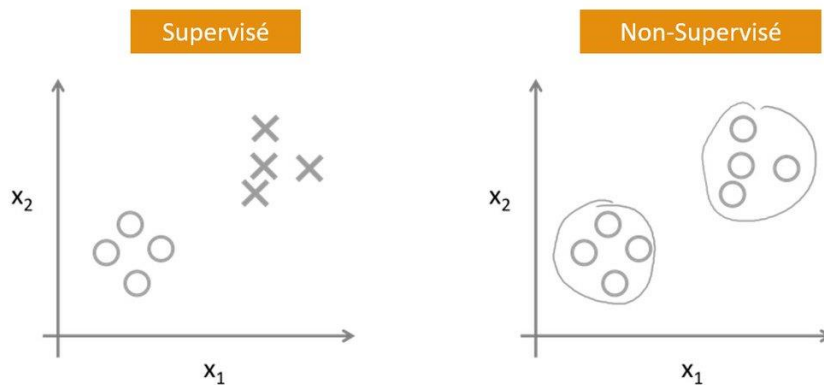


Figure 2.4 - La différence entre l'apprentissage supervisé et non-supervisé

3-4. L'utilité du Machine Learning

Le Machine Learning alimente de nombreux services modernes très populaires les moteurs de recherche web comme Google ou Baidu.

Les fils d'actualité des réseaux sociaux tels que Facebook et Twitter reposent sur le Machine Learning, au même titre que les assistants vocaux tels que Siri (Apple) et Alexa (Samsung).

Toutes ces plateformes collectent des données sur les utilisateurs, afin de mieux les comprendre et d'améliorer leurs performances. Les algorithmes ont besoin de savoir ce que regarde le spectateur, sur quoi clique l'internaute, et à quelles publications il réagit sur les réseaux. De cette manière, ils sont ensuite en mesure de proposer de meilleures recommandations, réponses ou résultats de recherche.

Un autre exemple est celui des voitures autonomes. Le fonctionnement de ces véhicules révolutionnaires repose sur le Machine Learning. Pour l'heure, toutefois, les performances de l'IA restent limitées dans ce domaine. Si elle parvient à se garer ou à suivre une voie sur l'autoroute, le contrôle complet d'un véhicule en agglomération est une tâche plus complexe ayant provoqué plusieurs accidents tragiques.

On utilise aussi le Machine Learning pour la traduction linguistique automatique, et pour la conversion du discours oral à l'écran (speech-to-text). Un autre cas d'usage est l'analyse de sentiment sur les réseaux sociaux, reposant également sur le traitement naturel du langage (NLP).

Le Machine Learning est aussi utilisé pour l'analyse et la classification automatique des images de radiographies médicales.

L'IA se révèle très performante dans ce domaine, parfois même plus que les experts humains pour détecter des anomalies ou des maladies. Toutefois, elle ne peut pas encore remplacer totalement les spécialistes compte tenu des enjeux. [13]

4- Deep Learning

4-1. Définition du Deep Learning

L'apprentissage profond « deep Learning » est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence artificielle dans les dernières années. Dans l'apprentissage automatique, un programme analyse un ensemble de données afin de tirer des règles qui permettront de tirer des conclusions sur de nouvelles données. L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités (les neurones) qui effectuent chacune de petites opérations simples.

Les résultats d'une première couche de « neurones » servent d'entrée aux calculs d'une deuxième couche et ainsi de suite. Par exemple, pour la reconnaissance visuelle, des premières couches d'unités identifient des lignes, des courbes, des angles... des couches supérieures identifient des formes, des combinaisons de formes, des objets, des contextes... Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« Big data »). [14]

4-2. Domaine d'application

- ✓ L'apprentissage profond s'applique à divers secteurs des NTIC, notamment :
- ✓ La reconnaissance visuelle — par exemple, d'un panneau de signalisation par un robot ou une voiture autonome — et vocale.
- ✓ La robotique.
- ✓ La bio-informatique, p. ex., pour l'étude de l'ADN et des segments non codants du génome, ou encore la Cryométrie.
- ✓ La reconnaissance ou la comparaison de formes.
- ✓ La sécurité.
- ✓ La santé.
- ✓ La pédagogie assistée par l'informatique.
- ✓ L'art.
- ✓ L'intelligence artificielle en général.
- ✓ La traduction.
- ✓ La méthode du Deep Learning est aujourd'hui utilisée pour l'élaboration des moteurs de traduction automatique.

L'apprentissage profond peut, par exemple, aider à :

- ✓ Mieux reconnaître des objets hautement déformables;
- ✓ Analyser les émotions révélées par un visage photographié ou filmé ;
- ✓ Analyser les mouvements et position des doigts d'une main, ce qui peut être utile pour traduire les langues signées.

- ✓ Poser, dans certains cas, un diagnostic médical (ex. : reconnaissance automatique d'un cancer en imagerie médicale, ou détection automatique de la maladie de Parkinson) [14]

5- Les Réseaux de neurones

Tout d'abord, le réseau de neurones est un concept. Ce n'est pas physique. Le concept de réseaux de neurones artificiels (Artificial Neural Networks ANN) (figure 2.5) a été inspiré par les neurones biologiques (figure 2.6).

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

Il s'agit là d'une variété de technologie Deep Learning (apprentissage profond), qui fait elle-même partie de la sous-catégorie d'intelligence artificielle du Machine Learning (apprentissage automatique). [15]




Figure 2.5 - Représentation du réseau de neurones humain




Figure 2.6 - Représentation du réseau de neurones artificiel

5-1. Principe de Fonctionnement des réseaux de neurones

En règle générale, un réseau de neurones repose sur un grand nombre de processeurs opérant en parallèle et organisés en tiers. Le premier tiers reçoit les entrées d'informations brutes, un peu comme les nerfs optiques de l'être humain lorsqu'il traite des signaux visuels.

Par la suite, chaque tiers reçoit les sorties d'informations du tiers précédent. On retrouve le même processus chez l'Homme, lorsque les neurones reçoivent des signaux en provenance des neurones proches du nerf optique. Le dernier tiers, quant à lui, produit les résultats du système.

Les réseaux de neurones apprennent Par le biais d'un algorithme, le réseau de neurones artificiels permet à l'ordinateur d'apprendre à partir de nouvelles données. L'ordinateur doté du réseau de neurones apprend à effectuer une tâche en analysant des exemples pour s'entraîner. Ces exemples ont préalablement été étiquetés afin que le réseau puisse savoir ce dont il s'agit.

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

Contrairement à d'autres types d'algorithmes, les réseaux de neurones ne peuvent pas être programmés directement pour effectuer une tâche. A la manière du cerveau en développement d'un enfant, la seule instruction qu'ils ont est d'apprendre.

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

Dans le cas de l'apprentissage non-supervisé, les données ne sont pas étiquetées. Le réseau de neurones analyse l'ensemble de données, et une fonction-coût lui indique dans quelle mesure il est éloigné du résultat souhaité. Le réseau s'adapte alors pour augmenter la précision de l'algorithme.

Enfin, avec la méthode de l'apprentissage renforcé, le réseau de neurones est renforcé pour les résultats positifs et sanctionné pour les résultats négatifs. C'est ce qui lui permet d'apprendre au fil du temps, de la même manière qu'un humain apprend progressivement de ses erreurs. [16]

5-2. Les principaux composants du réseau de neurones

Le réseau de neurones est composé des composants principaux suivants :

5-2-1. Neurones : ensemble de fonctions

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

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

Dans un réseau de neurones à plus de 3 couches (voir schéma ci-dessus), les neurones de la dernière couche cachée (hidden layer) transmettent les données de sortie en entrée des neurones de la couche de sortie (output layer). A partir de cela les neurones de la couche de sortie produisent les données de sortie finales. [17]

5-2-2. Couches : groupement de neurones

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

Il est tout à fait possible d'avoir un (très) grand nombre de couches dans un réseau de neurones complexe. Plus il y aura de couches, plus le réseau sera profond (deep learning). Les couches, autres que les couches d'entrée et de sortie, sont appelées les couches cachées (ou hidden layers). [17]

5-2-3. Poids et biais : valeurs numériques

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

Les réseaux de neurones mettent à jour ces poids de manière continue. Il existe donc une boucle de rétro-action mise en œuvre dans la plupart des réseaux de neurones. Les biais sont également des valeurs numériques qui sont ajoutées une fois que les poids sont appliqués aux valeurs d'entrée. Les poids et les biais sont donc en quelque sorte des valeurs d'auto-apprentissage de nos réseaux de neurones. [17]

5-2-4. Fonction d'activation : algorithmes mathématiques appliqués aux valeurs de sortie

Les fonctions d'activation lissent ou normalisent la donnée de sortie avant qu'elle ne soit transmise aux neurones suivants. Ces fonctions aident les réseaux de neurones à apprendre et à s'améliorer. [17]

5-3. Le perceptron

Un Perceptron est un neurone artificiel est une unité de réseau de neurones. Il effectue des calculs pour détecter des caractéristiques ou des tendances dans les données d'entrée.

Il s'agit d'un algorithme pour l'apprentissage supervisé de classificateurs binaires. C'est cet algorithme qui permet aux neurones artificiels d'apprendre et de traiter les éléments d'un ensemble de données.

Le Perceptron joue un rôle essentiel dans les projets de Machine Learning. Il est massivement utilisé pour classifier les données, ou en guise d'algorithme permettant de simplifier ou de superviser les capacités d'apprentissage de classificateurs binaires.

Rappelons que l'apprentissage supervisé consiste à apprendre à un algorithme à réaliser des prédictions. Pour y parvenir, on nourrit l'algorithme à l'aide de données déjà étiquetées correctement. [18]

5-3-1. L'apprentissage du Perceptron

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

Le Perceptron reçoit de multiples signaux d'entrée. Si la somme des signaux excèdent un certain seuil, un signal est produit ou au contraire aucun résultat n'est émis. (Voir figure 2.7)

Dans le cadre de la méthode d'apprentissage supervisé de Machine Learning, c'est ce qui permet de prédire la catégorie d'un échantillon de données. Il s'agit donc d'un élément essentiel. [18]




Figure 2.7 - Représentation d'un simple réseau de neurones perceptron

5-3-2. Le fonctionnement du Perceptron

En réalité, le Perceptron est une fonction mathématique. Les données d'entrée (x) sont multipliées par les coefficients de poids (w). Le résultat produit est une valeur.

Cette valeur peut être positive ou négative. Le neurone artificiel s'active si la valeur est positive. Il ne s'active donc que si le poids calculé des données d'entrée dépasse un certain seuil.

Le résultat prédit est comparé avec le résultat connu. En cas de différence, l'erreur est rétro propagée afin de permettre d'ajuster les poids. [18]

5-3-3. Perceptron à couche unique vs multicouches

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

- Un Perceptron à couche unique peut apprendre uniquement des fonctions linéaires séparables.
- Un Perceptron à couches multiples, aussi appelé "réseau neuronal" feed-forward, permet de surmonter cette limite et offre une puissance de calcul supérieure. Il est aussi possible de combiner plusieurs Perceptron pour créer un puissant mécanisme.

5-3-4. Perceptron et réseaux de neurones

En résumé, un réseau de neurones est un ensemble de Perceptrons interconnectés. Son fonctionnement repose sur des opérations de multiplication entre deux composants importants : les entrées de données (input) et le poids.

La somme de cette multiplication est transmise à une fonction d'activation, déterminant une valeur binaire de 0 ou 1. C'est ce qui permet de classifier les données.

[18]

5-4. Les différents types de réseaux de neurones

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

5-4-1. Réseau de neurones récurrent – Recurrent Neural Network (RNN):

Ce sont des réseaux de neurones spécialisés qui utilisent le contexte des entrées lors du calcul de la sortie. La sortie dépend des entrées et des sorties calculées précédemment. Ainsi, les RNN conviennent aux applications où les informations historiques sont importantes. Ces réseaux nous aident à prévoir les séries chronologiques dans les applications commerciales et à prévoir les mots dans les applications de type chatbot. Ils peuvent fonctionner avec différentes longueurs d'entrée et de sortie et nécessitent une grande quantité de données. [17]

5-4-2. Réseau de neurones convolutif – Convolution Neural Network (CNN):

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

Comparés à d'autres algorithmes de classification, les réseaux de neurones convolutifs utilisent relativement peu de pré-traitement. Cela signifie que le réseau est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision), ce qui n'est pas le cas d'autres algorithmes plus traditionnels. L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN. [17]

Dans l'optique de trouver une architecture de réseau robuste et indépendante des techniques d'extraction de caractéristiques tout en donnant des performances

satisfaisantes pour les signaux bruyants dans la classification, Nauman Munir« ingénieur en Département de Mécanique à l'université Sungkyunkwan et chercheur à l'Institut nucléaire à la Corée a fait une comparaison dans son article [12] entre la convolution des réseaux de neurones CNN et d'autres architectures dans la classification des défauts de soudures. L'ingénieur a conclu que la CNN a donné de meilleurs résultats dans des conditions bruyantes.

Ce qui nous a conduit à choisir ce type de réseaux de neurones CNN dans notre application

6- Convolution Neural Network (CNN)

Les réseaux de neurones convolutifs (CNN ou ConvNet - Convolutional Neural Network) sont un type particulier de réseaux de neurones multi-couches feed forwards souvent utilisés en traitement d'images, introduits initialement par Fukushima en 1980 pour une tâche de reconnaissance de forme dont l'architecture du réseau est inspirée du cortex visuel des animaux et popularisés pour la tâche de la reconnaissance de caractères.

Aujourd'hui, les CNNs sont devenus populaires dans plusieurs applications d'intelligence Artificielle en traitement automatique des langues : classification de texte, classification de musique et d'environnements sonores et traitement de signal. [19]

6-1 Le principe de la CNN

Le réseau neuronal convolutif est un type de réseau neuronal profond qui possède des couches convolutives ainsi que des couches entièrement connectées.

La convolution est une fonction mathématique largement appliquée dans le domaine du traitement du signal. Dans le réseau neuronal convolutif, les couches convolutives utilisent en fait la technique de corrélation croisée qui est techniquement très similaire à la convolution.

Il existe deux couches importantes dans les réseaux neuronaux convolutifs, à savoir les couches d'extraction de caractéristiques et les couches de classification.

La couche convolutionnelle et les couches de mise en commun sont couches d'extraction de caractéristiques, tandis que les couches de classification sont entièrement connectées. Les couches convolutionnelles, contrairement aux couches pleinement connectées, ne sont pas connectées à tous les nœuds de la couche d'entrée, mais à des régions locales spécifiques basées sur les filtres/ noyaux convolutifs définis. Cette architecture permet au réseau de se concentrer sur les caractéristiques de bas niveau, qui sont ensuite assemblées en caractéristiques de haut niveau. Le CNN est également capable d'apprendre des motifs [19]

Nous allons utiliser la CNN pour la classification des défauts détectés par le contrôle non destructif par ultrason

6-2. Les dimensions de la CNN

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

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

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

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

6-3. Les principaux composants du CNN

Trois types de couches (en anglais Layers) composent le CNN : convolutional layers, pooling layers and fully-connected layers (FC). Lorsque ces couches sont empilées, une architecture CNN est formée. En plus de ces trois couches, il y a trois paramètres plus importants qui sont dropout layers, the activation function et loss function qui sont définis ci-dessous. [20]

6-3-1. 1D Convolutional layers

Cette couche est la première couche qui est utilisée pour extraire les différentes caractéristiques du Data d'entrée. Dans cette couche, l'opération mathématique de convolution est effectuée entre le Data d'entrée et un filtre d'une taille particulière $M \times M$. En faisant glisser le filtre sur le Data, le produit scalaire est pris entre le filtre et les parties du Data d'entrée par rapport à la taille du filtre ($M \times M$). (Voir figure 2.8) [20]




Figure 2.8 - exemple d'un filtre de convolution 1D

Pour chaque couche de convolution il existe une fonction d'activation L'un des paramètres les plus importants du modèle CNN. Elles sont utilisées pour apprendre et approximer tout type de relation continue et complexe entre les variables du réseau. En d'autres termes, elle décide quelles informations du modèle doivent être tirées dans la direction avant et lesquelles ne doivent pas l'être à la fin du réseau. Elle ajoute une non-linéarité au réseau. Il existe plusieurs fonctions d'activation couramment utilisées, telles que les fonctions ReLU, Softmax, Linear, TanH et Sigmoid (figure 2.9). [20]

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

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




Figure 2.9 - Les fonctions D'activation

6-3-2. Pooling layers

Dans la plupart des cas, une couche convolutive est suivie d'une couche de mise en commun. L'objectif principal de cette couche est de diminuer la taille de la carte de caractéristiques convolutionnelle afin de réduire les coûts de calcul. Ceci est réalisé en diminuant les connexions entre les couches et en opérant indépendamment sur chaque carte de caractéristiques. Selon la méthode utilisée, il existe plusieurs types d'opérations de pooling. [20]

Dans le cas du Maxpooling (figure 2.10), l'élément le plus grand est extrait de la carte de caractéristiques. Le pooling moyen calcule la moyenne des éléments dans une section d'image de taille prédéfinie. La somme totale des éléments dans la section prédéfinie est calculée dans Sum Pooling. La couche pooling sert généralement de pont entre la couche de convolution et la couche FC. [20]




Figure 2.10- Exemple sur le Maxpooling

6-3-3. Fully-connected layers(FC)

La couche entièrement connectée (FC) se compose des poids et des biais avec les neurones et est utilisée pour connecter les neurones entre deux couches différentes. Ces couches sont généralement placées avant la couche de sortie et forment les dernières couches d'une architecture CNN. (Voir figure 2.11)

Dans cette couche, le Data des couches précédentes est aplati et transmise à la couche FC. Le vecteur aplati passe ensuite par quelques couches FC supplémentaires où les opérations de fonctions mathématiques ont généralement lieu. A ce stade, le processus de classification commence à avoir lieu. [20]




Figure 2.11 - Représentation des fully-connected Layers

6-3-4. Dropout layers

Habituellement, lorsque toutes les caractéristiques sont connectées à la couche FC, cela peut entraîner un surajustement dans l'ensemble de données d'apprentissage. Le surajustement se produit lorsqu'un modèle particulier fonctionne si bien sur les données

d'apprentissage qu'il a un impact négatif sur les performances du modèle lorsqu'il est utilisé sur de nouvelles données. [20]

Pour surmonter ce problème, on utilise une couche d'exclusion dans laquelle quelques neurones sont éliminés du réseau neuronal pendant le processus de formation, ce qui réduit la taille du modèle. Lorsque la couche d'exclusion est égale à 0,3, 30 % des nœuds sont éliminés de manière aléatoire du réseau neuronal. (Voir figure 2.12)




Figure 2.12- exemple sur le fonctionnement des Dropout Layers

6-3-5. Loss function

La couche de perte est la dernière couche du réseau. Elle calcule l'erreur entre la prévision du réseau et la valeur réelle. Lors d'une tâche de classification, la variable aléatoire est discrète, car elle peut prendre uniquement la valeur 0 ou 1, représentant l'appartenance (1) ou non (0) à une classe. C'est pourquoi la fonction de perte la plus courante et la plus adaptée est la fonction d'entropie croisée (en anglais cross-entropy). [20]

7- Conclusion

Dans ce chapitre, nous nous sommes intéressés aux réseaux de neurones convolutifs que nous allons utiliser pour proposer une nouvelle approche de classification des défauts détectés par le contrôle non destructif par ultrasons. Nous avons présenté tout d'abord l'intelligence artificielle et le machine Learning. Nous avons présenté ensuite les réseaux de neurones et ses différents types ainsi que les choix de l'architecture et le fonctionnement de base d'un réseau de neurones convolutif simple en détaillant les différents blocs de construction : l'entrée du réseau, l'opération de convolution, l'opération de pooling ainsi que la fonction d'activation et la fonction Loss permettant d'adapter la sortie du réseau en fonction de la tâche visée.

Chapitre III :

Expérimentation et résultats

1- Introduction

Dans ce chapitre, nous allons implémenter une méthode basée sur les réseaux de neurones convolutifs pour la classification des défauts multiples. La première phase est de construire l'architecture du modèle et l'entraînement de ce dernier. Dans cette phase nous avons utilisé une base de données simulée par le logiciel Matlab qui présentera des trois types de classes à savoir un défaut, deux défauts et aucun défaut. Finalement, la deuxième phase sera consacrée à la validation du modèle pour la classification des défauts multiples sera validée en utilisant une autre base de données avec des signaux réels acquis à l'aide d'une chaîne ultrasonores (multiéléments).

2- La phase d'apprentissage

2-1 Base de données d'apprentissage

Dans notre approche, comme il y avait très peu d'exemples dans la base de données des signaux réels pour entraîner notre réseau et augmenter sa fiabilité pour la classification des défauts multiples. Nous avons utilisé une base de données simulés des signaux ultrasonores bruités (bruit de structure) avec le modèle mathématique suivant :

$$Y(t) = s(t) * h(t) + br(t)$$

Avec :

$h(t)$: la réponse impulsionnelle du système ultrasonores.

$s(t)$: l'écho du défaut.

$br(t)$: bruit de structure.

Les détails de la simulation son mentionner dans [5].

2-2. Création de classe

Comme la CNN est un type d'apprentissage supervisé, les données utilisées pour l'entraînement sont déjà " étiquetées ". La classe représente chaque type de défaut.

- La classe 0 pour les signaux qui n'ont pas de défaut.
- La classe 1 pour les signaux d'un seul défaut.
- La classe 2 pour les signaux de 2 défauts.

Tout d'abord, nous avons séparé la base de données en ensembles. Chaque défaut a son propre ensemble et nous avons rajouté une classe à chaque ensemble par exemple :

Le numéro 0 est la classe de l'ensemble de 0 défaut

	B	C	D	E	F	G	H	I	J	K	L	M	
1	0	0,01524972	-0,03084952	-0,08342762	-0,06855807	-0,04033064	0,02067228	0,03342845	0,05490511	0,02497023	0,00184961	-0,01908418	-0,00334324
2	0	-0,06548707	-0,08879413	-0,064234	-0,01578512	0,04976884	0,07323174	0,06905533	0,01765793	-0,014111	-0,0558932	-0,04890668	-0,00314404
3	0	0,12543057	0,09461459	-0,00275383	-0,05642552	-0,13069216	-0,10698523	-0,04117429	0,06267673	0,10608048	0,10055171	0,06435221	-0,02058712
4	0	-0,03145131	-0,03460072	-0,02712894	0,00879772	0,04262811	0,07455263	0,04700996	-0,00193547	-0,06097974	-0,09869545	-0,05752003	-0,02632784
5	0	-0,02975244	-0,01502652	0,00581331	0,02524252	0,05048905	0,02387292	0,04888427	0,00357845	-0,02056472	-0,02834577	-0,03514785	-0,02572083
6	0	0,01053582	0,05743516	0,07168603	0,04861372	0,00290451	-0,06157093	-0,09163342	-0,08102432	-0,08834235	0,03543002	0,09294509	0,11321959
7	0	0,02986831	0,04292492	0,01189416	-0,00053113	0,00540098	-0,02369102	-0,01520594	-0,00956756	-0,02569044	-0,03510481	0,01897389	0,01094279
8	0	0,00699404	-0,01919402	-0,02467155	-0,02928078	0,00464137	0,04051544	0,06581547	0,05402776	0,03047854	-0,02272112	-0,08331044	-0,07671086
9	0	-0,06729656	-0,01585869	0,04315133	0,11067217	0,10037012	0,05730462	-0,06896505	-0,08957453	-0,09302302	-0,05486608	0,02948542	0,07239709
10	0	-0,11572833	-0,10388182	-0,03232974	0,05448471	0,12048739	0,11707939	0,06921596	-0,04572981	-0,13608082	-0,12774122	-0,08459479	0,01151871
11	0	-0,0486053	-0,17364361	-0,19266594	-0,13964237	0,00458576	0,12463718	0,15699953	0,11370337	0,01902861	-0,05253524	-0,10939991	-0,10216773
12	0	0,03168913	0,01085975	-0,0405375	-0,05015387	-0,03815385	-0,01563737	0,0385731	0,07340723	0,06029143	0,0032202	-0,07236729	-0,08218039
13	0	0,02826544	0,00285241	-0,03598208	-0,02573008	0,01351041	0,00817553	0,0424245	-0,00531803	-0,02594226	-0,0333541	-0,02930537	0,00510346
14	0	0,03524517	0,04389242	0,03380096	0,00082528	-0,01644152	0,03890881	0,0075635	0,0266281	-0,02078548	-0,00716447	-0,03095777	-0,02006389
15	0	0,03600131	-0,00579025	-0,03906296	-0,03847403	-0,05677268	-0,01359413	0,06354709	0,06467792	0,07021303	0,00427867	-0,04926691	-0,08950204
16	0	0,0085954	0,0363981	0,0569015	0,02048063	0,02001408	-0,03631616	-0,04310309	-0,04559937	-0,04370202	0,03314072	0,02625658	0,06130746
17	0	0,00575086	0,06504272	0,06732173	0,06815523	-0,03033602	-0,08668981	-0,10774964	-0,0462656	0,01809369	0,09437364	0,12616664	0,0707627
18	0	0,0209688	0,02881139	-0,01668346	-0,03153362	-0,06224697	-0,05219503	-0,02148925	0,01971819	0,03383306	0,02827564	0,0370528	0,00845727
19	0	-0,00380084	0,04041524	0,05170009	0,06982379	0,03604868	-0,03979242	-0,06302321	-0,08711138	-0,06682006	0,02948568	0,07855412	0,10876391
20	0	0,07976009	0,09923681	0,04710486	0,00422065	-0,05589382	-0,05800769	-0,03099854	-0,02026679	0,02847522	0,00480163	0,00332087	0,00478878
21	0	0,0519594	0,10364537	0,09269094	0,0653711	-0,0208306	-0,08029272	-0,08823016	-0,06033221	-0,00141931	0,08142674	0,0868371	0,05365808
22	0	0,05168469	-0,02374269	-0,0868316	-0,10422026	-0,06713525	0,01109821	0,04390111	0,06141459	0,0693286	0,01354082	-0,02493867	-0,05452297
23	0	0,05165488	0,12586357	0,10534935	0,0374186	-0,01567556	-0,10664453	-0,14518392	-0,06192616	0,00585055	0,07696357	0,09945431	0,04984437

Figure 3.1 - la base de données des signaux qui contiennent 0 défauts

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	1	0,18123453	0,2382808	0,1171199	0,04808033	-0,17234739	-0,13576694	-0,36570271	-0,06866778	-0,04127308	-0,01482278	0,01866908	0,12232496
2	1	0,11563123	0,03002512	-0,02901837	0,08562148	0,02578806	0,07474982	0,04010574	0,04060116	-0,07256345	-0,15399981	-0,03609936	0,13237589
3	1	-0,06165212	-0,05450221	-0,32294878	-0,25004179	0,07204548	-0,02198013	0,32422741	0,47919055	0,19618564	-0,06169426	-0,31085384	-0,66560015
4	1	0,28141527	-0,09030377	-0,18537539	-0,32591651	-0,12302954	-0,07634308	0,14267726	0,34404778	0,18906663	0,03076973	-0,10720543	-0,1661777
5	1	-0,01525692	-0,10602767	-0,01767665	0,06966778	0,13077718	0,1685948	0,01118598	0,11429295	-0,02070193	-0,17769064	-0,10128507	0,00312437
6	1	0,06101827	0,11659366	0,42029854	0,00043709	0,12651006	-0,06224484	-0,23286925	-0,05553782	-0,00318481	0,24912931	0,06986819	0,11182548
7	1	-0,07542328	-0,09732242	-0,03728303	-0,17061629	0,00850682	-0,09037246	0,08749885	0,08410523	0,14398529	-0,09892192	-0,1039098	-0,11417578
8	1	-0,05483663	0,08758644	-0,05719893	0,12625298	0,15101358	0,02689805	-0,09436496	-0,08461511	-0,06820046	0,1915579	0,187481	0,29830626
9	1	0,05128739	0,23203842	0,09181638	0,02599119	-0,10786972	-0,24328847	-0,27168424	-0,06510099	0,07754435	0,27959232	0,28611862	0,07941846
10	1	-0,07689893	0,041095045	0,3355588	0,38003218	0,11641459	-0,43573592	-0,62888601	-0,41515796	-0,1257337	0,24755399	0,41669408	0,39649053
11	1	0,01489276	-0,1339435	-0,07140907	-0,15125283	-0,15063634	-0,1508804	0,10315188	0,15987298	0,29867633	0,21770559	-0,07292095	-0,30622551
12	1	0,0002353	-0,13908402	0,14015716	0,09728408	-0,0942219	-0,07983838	0,07939562	-0,01115071	-0,11420856	0,07688149	0,27090961	0,32031773
13	1	0,03830125	0,06848325	0,0328805	0,07107627	0,03998985	-0,0876924	-0,209073	-0,04555112	-0,05623218	-0,03733216	0,09150075	0,15096833
14	1	0,13191136	0,02560614	-0,10138432	-0,04891218	-0,22959684	-0,06962445	0,15861709	0,10968453	0,23763532	0,1606338	0,06691951	-0,18057584
15	1	0,35260729	0,11027774	0,03957747	-0,31910905	-0,44380615	-0,1192485	0,00668764	0,17908308	0,32079374	0,23764581	0,0727385	-0,1718007
16	1	0,13313222	0,00410514	0,12853085	-0,07440179	-0,07411616	-0,26232336	0,00410653	-0,37567294	-0,01254644	0,07369497	0,20670806	0,34121842
17	1	-0,11694893	-0,00055625	0,11838739	0,27428503	0,12389099	-0,03889755	-0,12473604	-0,09153128	-0,12082803	0,14996767	0,04002963	-0,00753136
18	1	-0,23595551	-0,23408251	-0,2384131	-0,0852298	0,03958628	0,30643369	0,32681447	0,20863067	0,02417716	-0,18225445	-0,41750474	-0,10535193
19	1	0,08990955	-0,02437045	-0,01148302	0,1459712	0,07596875	0,17451137	-0,07697179	-0,17419042	-0,18951278	-0,05130319	0,25837457	0,27884767
20	1	-0,03101778	0,01420211	-0,07563585	-0,00887863	0,05190807	0,08446777	0,03300567	-0,10435642	-0,0371281	-0,11494086	-0,21494677	-0,01662282
21	1	-0,02581294	0,12495035	0,12118577	0,04174857	-0,18787012	-0,10421984	-0,05593088	-0,16419504	0,24678963	0,07270284	0,20169262	0,20326158
22	1	0,0788993	-0,03596471	-0,02750669	-0,03476309	-0,09270779	0,0787366	0,17215194	0,16395043	0,1095905	-0,11190986	-0,1523606	-0,22382136
23	1	0,06171451	0,13591476	0,11882093	-0,02490266	-0,13073501	-0,11628349	-0,09601213	0,05903666	-0,05826025	0,22865832	0,08092245	0,10144291

Figure 3.2 - la base de données des signaux qui contiennent 1 défaut

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	2	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10	3,0084E-10	5,7275E-10	9,834E-10	1,5236E-09	2,0865E-09
2	2	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11	2,0851E-10	4,2081E-10	7,5989E-10	1,2408E-09	1,8152E-09
3	2	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10	3,0084E-10	5,7275E-10	9,834E-10	1,5236E-09
4	2	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11	2,0851E-10	4,2081E-10	7,5989E-10	1,2408E-09
5	2	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10	3,0084E-10	5,7275E-10	9,834E-10
6	2	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11	2,0851E-10	4,2081E-10	7,5989E-10
7	2	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10	3,0084E-10	5,7275E-10
8	2	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11	2,0851E-10	4,2081E-10
9	2	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10	3,0084E-10
10	2	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11	2,0851E-10
11	2	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11	1,3926E-10
12	2	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11	8,8664E-11
13	2	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11	5,2725E-11
14	2	-7,8001E-14	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12	2,801E-11
15	2	-4,4887E-14	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12	1,1665E-11
16	2	-2,3404E-14	-7,8001E-14	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12	1,396E-12
17	2	-9,9742E-15	-4,4887E-14	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12	-4,5908E-12
18	2	-1,9908E-15	-2,3404E-14	-7,8001E-14	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12	-7,6595E-12
19	2	2,4073E-15	-9,9742E-15	-4,4887E-14	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12	-8,8209E-12
20	2	4,5222E-15	-1,9908E-15	-2,3404E-14	-7,8001E-14	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12	-8,8029E-12
21	2	5,2445E-15	2,4073E-15	-9,9742E-15	-4,4887E-14	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12	-8,1142E-12
22	2	5,168E-15	4,5222E-15	-1,9908E-15	-2,3404E-14	-7,8001E-14	-1,9991E-13	-4,4786E-13	-9,1401E-13	-1,7256E-12	-3,0226E-12	-4,8781E-12	-7,0977E-12
23	2	4,677E-15	5,2445E-15	2,4073E-15	-9,9742E-15	-4,4887E-14	-1,2676E-13	-3,0323E-13	-6,4645E-13	-1,2676E-12	-2,3057E-12	-3,8829E-12	-5,9743E-12

Figure 3.3 - représente la base de données des signaux qui contiennent 2 défauts

2-3. La normalisation des données

La normalisation est une méthode de prétraitement des données qui permet de réduire la complexité des modèles. C'est également un préalable à l'application de certains algorithmes.

La normalisation permet de simplifier le problème d'apprentissage. Pour effectuer cette normalisation

$$V_{normalisé} = \frac{V - V_{min}}{V_{max} - V_{min}}$$

V Une valeur dans le data.

V_{min} La valeur minimal du data.

V_{max} La valeur maximal du data.

2-4. L'Entraînements et le test de l'architecture

L'entraînement d'un réseau neuronal sur un ensemble de données et la validation de performance sur le même ensemble de données est méthodologiquement erronée car il peut atteindre une grande précision sur les exemples vus, mais peut échouer à prédire les exemples non vus.

Afin d'étudier les performances réelles du réseau neuronal, il est courant de diviser les données en ensembles de données d'entraînement et de test. Le réseau est formé sur

l'ensemble de données d'entraînement, tandis que sa précision est vérifiée sur l'ensemble de données de test. Cependant, il faut équilibrer les données de la base de données pour chaque défaut « sauf si vous voulez que l'architecture améliore sa capacité de détection pour une classe déterminée » c'est-à-dire toutes les classes ont le même nombre de signaux. 80% des signaux pour l'entraînement et 20% pour le test. Le tableau montre le nombre de signaux pour chaque défaut dans la base de données.

Tableau 3.1 – le nombre des signaux d'entraînement et de test

Les classes de défauts	Les niveaux de bruits SNR5dB, SNR15dB	
	Nombre des signaux d'entraînements	Nombre des signaux de test
0 Défaut	328	82
1 Défaut	329	83
2 Défauts	421	105
Total	1078	270

Notre réseau de neurones convolutifs adopté dans cette étude a également été conçu à l'aide de Tensorflow (logiciel open source de Google pour l'apprentissage profond) et Google Colaboratory qui permet d'écrire et d'exécuter l'algorithme Python dans le navigateur.

Le langage Python est un langage de programmation qui peut s'utiliser dans de nombreux contextes et s'adapter à tout type d'utilisation grâce à des bibliothèques spécialisées. Il est cependant particulièrement utilisé comme langage de script pour automatiser des tâches simples mais fastidieuses, comme il est utilisé dans le développement du machine Learning et le deep Learning. On l'utilise également comme langage de développement de prototype lorsqu'on a besoin d'une application fonctionnelle avant de l'optimiser avec un langage de plus bas niveau. Il est particulièrement répandu dans le monde scientifique, et possède de nombreuses bibliothèques optimisées destinées au calcul numérique.

Note : Le programme a été développé sur Google Colaboratory qui permet d'écrire et d'exécuter du code Python dans le navigateur.

2-5. Le choix des paramètres :

2-5-1. Les bibliothèques utilisées

```
[2] import pandas as pd
import os
import numpy as np
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers, models
from matplotlib import pyplot as plt
```

Figure 3.4 - les bibliothèques utilisées dans l'architecture

- Bibliothèque Pandas pour la lecture des fichiers Excel
- Bibliothèque numpy pour effectuer des calculs numériques avec Python. Elle introduit une gestion facilitée des tableaux de nombres.
- Bibliothèque keras permet d'interagir avec les algorithmes de réseaux de neurones profonds et d'apprentissage automatique. Conçue pour permettre une expérimentation rapide avec les réseaux de neurones profonds.
- Bibliothèque matplotlib c'est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques.

Le nombre de nœuds dans la couche d'entrée était égal aux points d'échantillonnage des signaux ultrasoniques (320 échantillons)

2-5-2. Architecture du modèle de CNN

Notre architecture a été décidée après plusieurs essais et nous avons choisi l'architecture qui donnait les meilleurs résultats. Cette architecture permet au réseau de se concentrer sur les caractéristiques de bas niveau, qui sont ensuite assemblées en caractéristiques de haut niveau. Le CNN est également capable d'apprendre un modèle à un endroit et de le déterminer à un autre endroit. Ceci, en fait, est possible grâce au même partage des paramètres dans les filtres. Maxpooling dans le réseau neuronal est utilisée pour sous-échantillonner l'entrée, ce qui permet de réduire la charge de calcul, améliorer la qualité du réseau et d'éviter le surajustement. Cependant, cela augmente la complexité

2-5-3. Les couches utilisées :

2 couches convolutionnelles, une couche de Maxpooling et une couche entièrement connectée et une couche de sortie

La taille du filtre dans la première couche a été maintenue à un niveau élevé (8 × 1) en raison de sa bonne performance dans des conditions bruyantes

Afin de garder le réseau simple réseau, il n'y a pas eu de couche de mise en commun entre la première et la seconde couche de convolution.

La couche de convolution et son effet a été approximé par un pas plus grand (2 × 1) dans la deuxième couche de convolution. Car elle ne réduit pas les performances, Cependant, cela réduit le nombre de couches.

La fonction d'activation utilisé dans les deux couches de convolutions été la fonction Rectified Linear Unit (ReLU)

$$\text{Fonction_ReLU}(x) = \max(x, 0)$$

Cette fonction permet d'effectuer un filtre sur nos données. Elle laisse passer les valeurs positives ($x > 0$) dans les couches suivantes du réseau de neurones.

Une couche de Maxpooling a été appliquée avec une taille de filtre 2 × 1 et une taille de pas 2 × 1 pour réduire la charge de calcul

Une couche de dropout de 0,25 a été placée après le Maxpooling pour réduire le surajustement dans les réseaux de neurones. La technique évite des co-adaptations complexes sur les données de l'échantillon d'entraînement.

Après la couche de dropout, une couche entièrement connectée avec 1200 nœuds et une couche de sortie avec 3 nœuds. la fonction utilisé dans la couche de sortie c'est la fonction Softmax, cette fonction a été utilisée pour convertir un score en probabilité dans un contexte de classification multi-classe. Le nombre de nœuds dans la couche entièrement connectée a également été décidé après plusieurs essais. il a été décidé après plusieurs essais et nous avons choisi le nombre de nœuds qui donnait de bonnes performances.

Nous avons choisir la fonction « sparse_categorical_crossentropy » comme fonction Loss à cause de son Utilisation comme fonction de perte pour les modèles de

classification multi-classes où il y a deux ou plusieurs étiquettes de sortie. L'étiquette de sortie se voit attribuer une valeur d'encodage de catégorie à un coup sous la forme de 0 et de 1. L'étiquette de sortie, si elle est présente sous forme d'entier, l'étiquette est convertie en encodage catégorique à l'aide de keras.

```
[8] from keras.optimizers import Adam
input = keras.layers.Input(shape=(320,1))
y = keras.layers.Conv1D(32,8, strides=8, activation="relu")(input)
y = keras.layers.Conv1D(64,16, strides=8, activation="relu")(y)
y = keras.layers.MaxPool1D(2, strides=2)(y)
y = keras.layers.Dropout(0.25)(y)
y = keras.layers.Flatten()(y)
y = keras.layers.Dense(1200, activation="relu")(y)
y = keras.layers.Dropout(0.75)(y)
y = keras.layers.Dense(3, activation="softmax")(y)
model_2 = keras.models.Model(
    inputs=[input], outputs=[y], name="model2"
)
model_2.summary()
#optimisation parameters
opt = Adam(lr = 0.00001)
model_2.compile(optimizer=opt, loss='sparse_categorical_crossentropy', metrics = ['accuracy'])
history = model_2.fit(x_train,y_train,epochs=1200, validation_data=(x_test, y_test),batch_size=32, verbose=1)
```

Figure 3.5 - l'algorithmme de notre architecture

Model: "model2"

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 320, 1)]	0
conv1d_2 (Conv1D)	(None, 40, 32)	288
conv1d_3 (Conv1D)	(None, 4, 64)	32832
max_pooling1d_1 (MaxPooling1D)	(None, 2, 64)	0
dropout_2 (Dropout)	(None, 2, 64)	0
flatten_1 (Flatten)	(None, 128)	0
dense_2 (Dense)	(None, 1200)	154800
dropout_3 (Dropout)	(None, 1200)	0
dense_3 (Dense)	(None, 3)	3603
=====		
Total params: 191,523		
Trainable params: 191,523		
Non-trainable params: 0		

Figure 3.6 - les paramètres entraînés dans le modèle

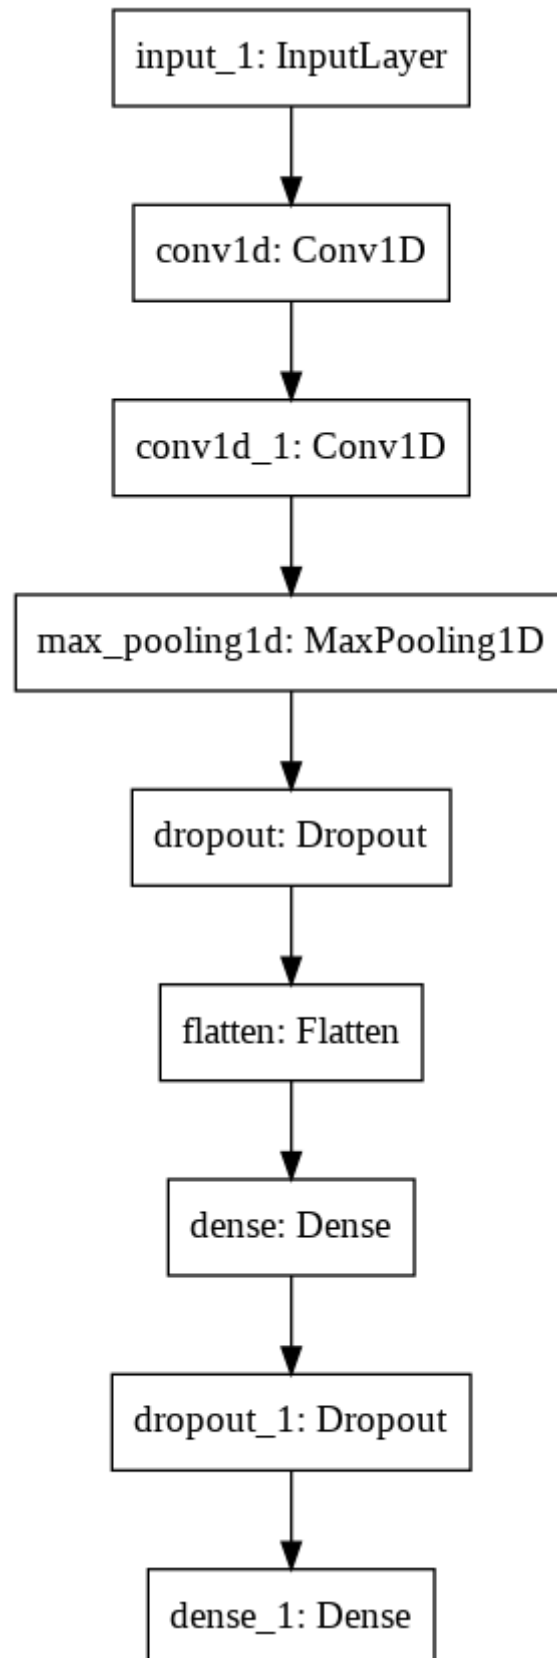


Figure 3.7 - l'architecture du modèle CNN

2-5-4. La Configuration d'apprentissage

Le batch size est le nombre de signaux d'entraînement utilisés dans une itération (Batch-size= 64)

Epoch indique le nombre de passages de l'ensemble des données d'apprentissage que l'algorithme d'apprentissage automatique a effectués (Epoch = 1200)

Optimazer : « Adam » c'est une extension de la descente de gradient stochastique et peut être utilisée à la place de la descente de gradient stochastique classique pour mettre à jour les poids du réseau plus efficacement.

Learning Rate est un hyper paramètre configurable utilisé dans l'apprentissage des réseaux neuronaux qui a une petite valeur positive, souvent comprise entre 0,0 et 1,0.

Le taux d'apprentissage contrôle la vitesse d'adaptation du modèle au problème.

2-6. Résultats d'apprentissage

a. Learning Rate = 0.001, epoch = 100




Figure 3.8 - la courbe de l'accuracy de l'architecture (Learning Rate = 0.001, epoch = 100)




Figure 3.9 - la courbe du Loss de l'architecture(Learning Rate = 0.001, epoch = 100)

On remarque que dans le premier cas (Learning rate = 0.001, epoch = 100) le Learning rate était trop élevé, ce qui a causé une convergence très rapide du modèle vers des solutions sous-optimal.

b. Learning rate = 0.00001, epoch = 1200, FC = 600




Figure 3.10 - la courbe de l'accuracy de l'architecture(Learning Rate = 0.00001, epoch = 1200, FC = 600)




Figure 3.11 - la courbe du Loss de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 600)

```

Evaluation

[ ] model_2.evaluate(x_test, y_test, batch_size=64, verbose=1)

5/5 [=====] - 0s 3ms/step - loss: 0.0228 - accuracy: 0.9926
[0.022786691784858704, 0.9925925731658936]
    
```

Figure 3.12 - l'évaluation de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 600)

Dans le deuxième cas, on remarque qu'avec un Learning rate inférieur de celui du premier cas et un nombre de nœuds égal à 600 dans la couche fully-connected, l'architecture a montré une bonne performance avec un Loss de 0.0228 et une accuracy de 0.9926

c. Learning Rate = 0.00001, epoch = 1200, FC = 1200.




Figure 3.13 - la courbe de l'accuracy de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)




Figure 3.14 - la courbe du Loss de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)

```

Evaluation
▶ model_2.evaluate(x_test, y_test, batch_size=64, verbose=1)
5/5 [=====] - 0s 4ms/step - loss: 0.0094 - accuracy: 0.9963
[0.009413488209247589, 0.9962962865829468]
    
```

Figure 3.15 - l'évaluation de l'architecture (Learning Rate = 0.00001, epoch = 1200, FC = 1200)

Dans le troisième cas, on remarque qu'après l'augmentation du nombre de nœuds dans la couche fully-connected, l'architecture a amélioré sa performance par rapport au deuxième cas, avec un Loss inférieur 0.0094 et une accuracy plus élevée 0.9963

Remarque

La performance du CNN a été évaluée pour la base de données simulée en formant le réseau sur celle des données d'entraînement, et en testant les performances du CNN sur la base de données de test.

3- La phase de validation

3-1. Génération d'une base de données réelle

3-1-1. Présentation des pièces à contrôler :




Figure 3.16 - Une pièce en Aluminium avec les dimensions (25,8cm x 3,3cm x 2,6cm)



Figure 3.17 - Une pièce en Aluminium avec les dimensions (32,5cm x 7,7cm x 2,1cm)



Figure 3.18 - Une pièce en Acier avec les dimensions (19,8cm x 17,8cm x 3cm)



Figure 3.19 - Une pièce en Acier avec les dimensions (25,5cm x 9,9cm x 2,4cm)

Les 4 pièces représentent différents nombres de défauts (0 défaut, 1 défaut, 2 défauts). Nous allons nous concentrer sur les Défauts Multiples à cause de leurs difficultés de prédiction.

3-1-2. Matériel utilisé

a. Appareil à ultrasons multiéléments de type OmniScan MX

L'OmniScan MX est l'appareil à ultrasons multiéléments modulaire et portable d'Olympus le plus apprécié à ce jour, comme en témoignent les milliers d'appareils utilisés partout dans le monde. Il est le fruit de plus de dix années d'expérience et de leadership.



Figure 3.20 - L'interface de l'OmniScan MX

L'OmniScan MX est un outil d'inspection et de contrôle de défaut avec une grande efficacité d'inspection. En effet, la grande rapidité des configurations, des cycles d'inspection et de la génération de rapport garantit une performance exceptionnelle lors

d'applications automatisées, en plus de s'adapter parfaitement à plus de dix modules à ultrasons multiéléments et conventionnels. Cette plateforme évolutive, offre une vraie performance de nouvelle génération.

Sans compter que cet appareil portable et modulaire réunit une fréquence d'acquisition élevée.

C'est un appareil de recherche de défauts avec des puissantes capacités d'inspection pour les applications manuelles et automatisées

Les utilités de l'OmniScan MX :

- La recherche et la détection des défauts présents dans les pièces
- Inspection des soudures d'équipements sous pression.
- L'inspection des pièces en matériau composite stratifié.
- Inspection des soudures de tubes de petit diamètre.
- Cartographie de la corrosion manuelle et semi-automatisée.

b. Le palpeur




Figure 3.21 –Palpeur A11 (Sonde 5 Mhz-32 éléments)

Le palpeur Olympus A11 fait partie des sondes à Ultrasons multiéléments classiques qui ont des fréquences allant de 1 MHz à 17 MHz et sont équipées de 10 à 128 éléments.

Le A11 utilise la technologie piézocomposite pour tous les types d'inspections

Les applications du palpeur A11 :

- Inspection automatisée ou manuelle de soudures d'une épaisseur de 6,35 mm à 38mm.
- Recherche et dimensionnement de défauts.
- Inspection des fissures et des défauts de soudure dans les pièces moulées, les pièces forgées, les tuyaux, les tubes et les composants structurels usinés.

3-1-3. Mode opératoire**a. L'étalonnage**

L'étalonnage de l'ensemble appareillage et palpeur ultrasonore présente une grande importance, dans la mesure où l'on cherche à fournir des résultats de contrôle pertinents.

b. La configuration de L'OmniScan Mx

Dans la configuration il faut sélectionner

- La nature de la pièce à contrôlée (Aluminium, Acier).
- L'épaisseur de la pièce.
- Le type du palpeur utilisé (A11).
- Le nombre d'échantillons (640 points).
- Le nombre d'éléments excités dans le palpeur.

c. Le contrôle

Tout d'abord nous avons mis un peu de gel sur la pièce pour assurer la bonne transmission des ondes ultrasonores. Ensuite nous avons placé le palpeur au-dessus de la partie qui contient des défauts et on a enregistré les échos apparents sur l'écran de l'OmniScan dans une clé USB afin de le traiter avec le logiciel TomoView




Figure 3.22–le déroulement du contrôle




Figure 3.23 - le contrôle ultrasonore d'une pièce a l'aide d'une unité d'inspection ultrasonores multiéléments (L'OmniScan MX)

Logiciel Tomoview

Tomoview est un logiciel de conception, d'acquisition et de visualisation des signaux ultrasonores exploitable sur PC. La flexibilité de configuration des paramètres ultrasons permet d'afficher différents types de vues. Vous pouvez donc l'utiliser pour une grande variété d'applications, aussi bien dans le domaine industriel que scientifique.

TomoView est conçu pour être compatible avec un grand nombre d'appareils à ultrasons conventionnels ou multiéléments, de sorte qu'on peut sélectionner la configuration d'acquisition de données qui convient le mieux à notre application.

De plus, ce logiciel nous permet de convertir la base de données acquise en un type de données qu'on peut exploiter avec n'importe quel logiciel de traitement.

Echo d'un défaut à l'intérieur d'une pièce

Le positionnement du défaut

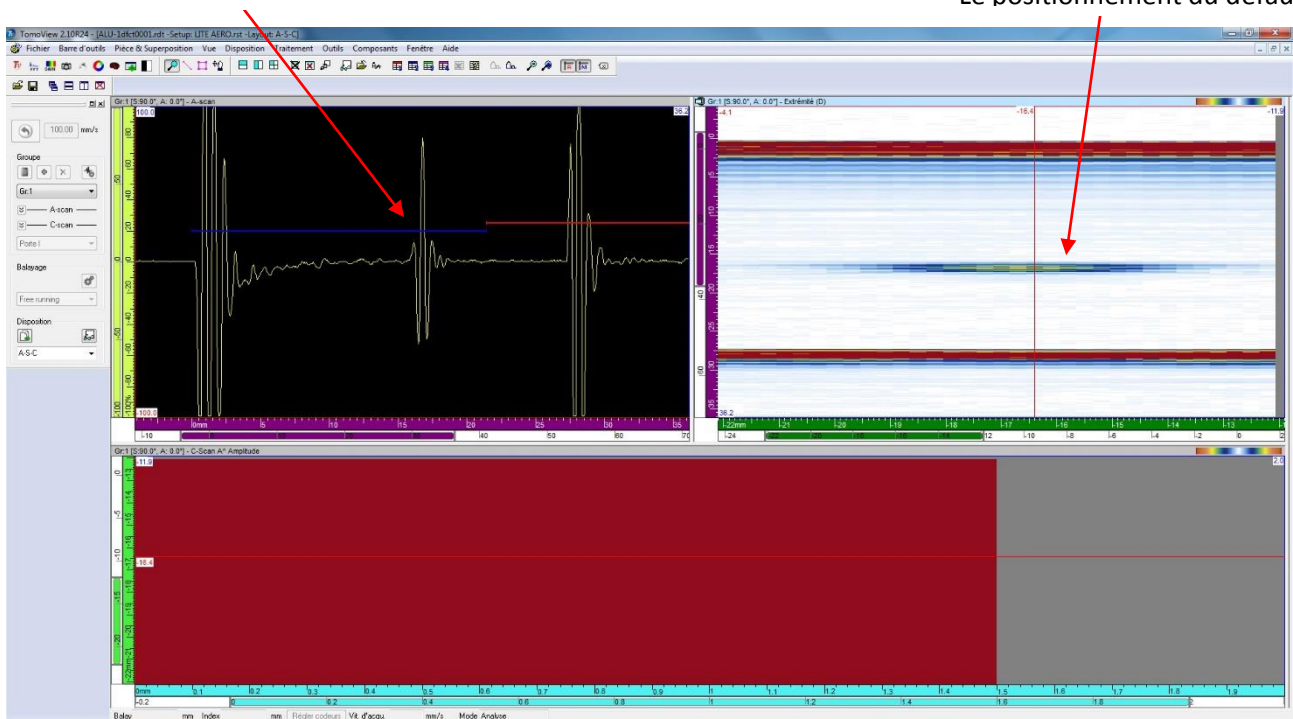


Figure 3.24- l'interface du logiciel TomoView

La base de données récupérée de TomoView a été traitée par le logiciel matlab pour focaliser la zone des défauts et sélectionner le nombre d'échantillons (320 échantillons) que nous allons utiliser pour valider notre architecture




Figure 3.25 - l'écho d'un signal sans défaut sur 640 points




Figure 3.26 - l'écho d'un signal sans défaut sur 320 points

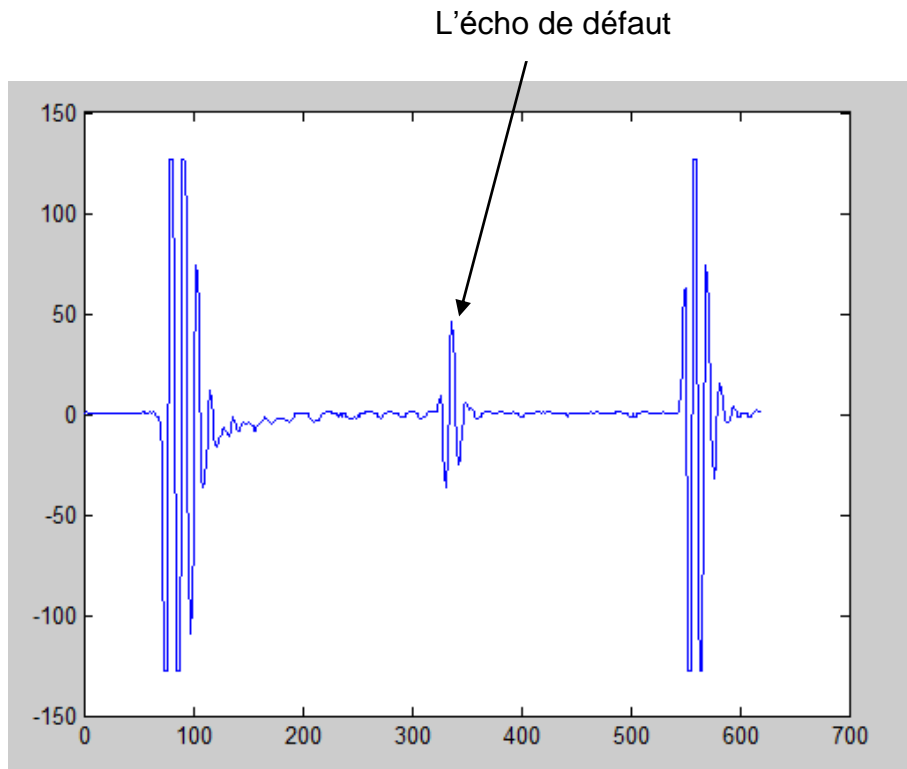


Figure 3.27 - l'écho d'un signal avec 1 défaut sur 640 points




Figure 3.28 – l'écho d'un signal avec 1 défaut sur 320 points

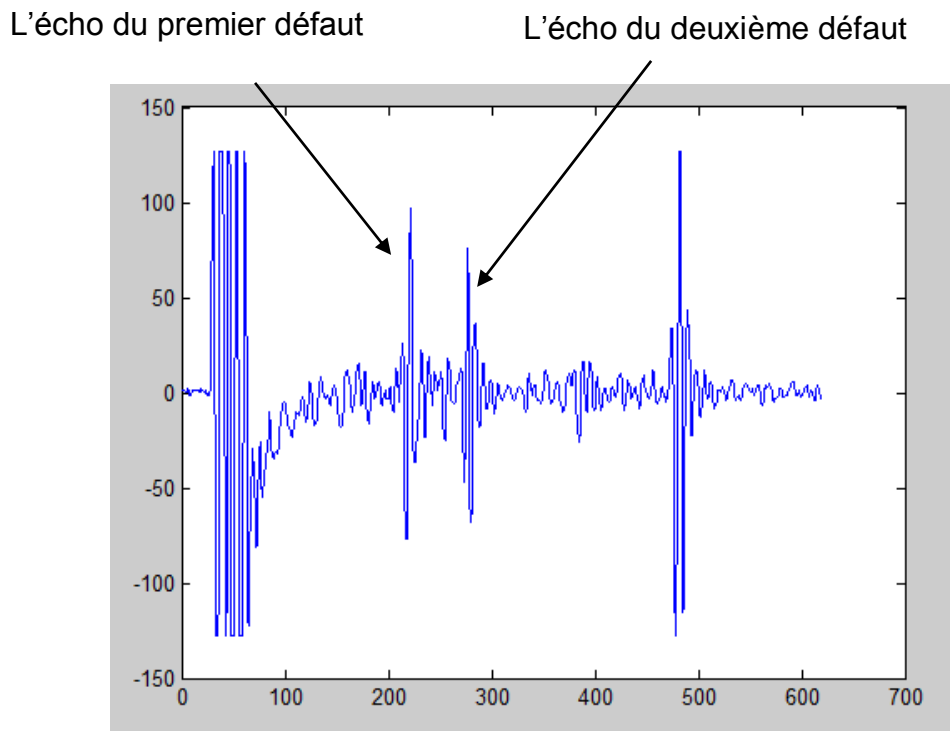


Figure 3.29 – l'écho d'un signal avec 2 défauts sur 640 points




Figure 3.30 - l'écho d'un signal avec 2 défauts sur 320 points

3-2. Validation de l'architecture

Pour valider notre architecture, nous avons créé un code qui sert à prédire la classe des signaux acquis à partir du contrôle non destructif ultrasonore.

```
[13] model_2 = keras.models.load_model('/content/drive/MyDrive/model/')
      output = model_2.predict(frame, batch_size=32, verbose=1)
      out = np.argmax(output)
      print(out)

1/1 [=====] - 0s 105ms/step
2
```

Figure 3.31 - le code de prédiction de classe

Remarque :

L'objectif de cette fonction (prédiction) est de voir si le modèle est capable de prédire la classe des signaux acquis par le contrôle et faire la différence entre les défauts simples et les défauts multiples.

Il ressort de ce code que le modèle a pu prédire la classe des signaux acquis avec un pourcentage de 93%. Néanmoins, il reste toujours un pourcentage de 7% imputé à une erreur de prédiction à cause de la différence entre la base de données réelle et la base de données simulé

Le plus grand avantage de cette technique est l'économie du temps. Par ex, le temps d'apprentissage de notre architecture était de 1200 secondes pendant que d'autres techniques prennent des heures de traitement. Sachant que l'environnement de développement de cette technique est Open Source

3-3. Résumé d'algorithme

- Génération d'une base de données simulée avec Matlab.
- Importation des bibliothèques utilisées par l'architecture.
- Importation de la base de données simulée.
- Normalisation des données de la base
- Construction d'une architecture performante
- Entraîner et tester l'architecture avec la base de données simulée.

- Valider l'architecture avec une base de données réelle (faire la prédiction de la classe).

4- Conclusion

Dans ce chapitre nous avons proposé une nouvelle technique de classification des défauts multiples avec les réseaux de neurone convolutifs. Tout d'abord, nous avons simulé une base de données contenant des signaux ultrasonores bruités (bruit de structure), qui représentent trois classes de défauts (0 défaut, 1 défaut, 2 défaut). Cette base de données sera utilisée dans l'entraînement et le test du modèle que nous allons créer. Ensuite, nous avons construit une architecture de réseau de neurones convolutif, celle-ci se repartie en plusieurs types de couches avec différents paramètres. Afin d'aboutir à un taux d'apprentissage élevé, des changements de paramètres ont été effectués jusqu'à ce que nous soyons arrivés à un $\text{test_accuracy} = 0.9963$ et un $\text{test_loss} = 0.0094$. Lorsque nous avons atteint ces valeurs, nous avons conclu que notre modèle a reçu un meilleur apprentissage. Enfin pour valider notre technique nous avons effectué un contrôle ultrasonore sur diverses pièces de différents matériaux et avons utilisé la base de données acquise par le contrôle dans la prédiction du taux de réussite de notre modèle dans la classification des défauts multiples. Les résultats obtenus à la fin ont montré l'efficacité de cette technique en classification, en temps d'apprentissage et en environnement de développement.

Conclusion générale

Conclusion générale

Le souci de tout le milieu industriel est le bon fonctionnement de ses machines en service et d'évitement tout type d'accident. Pour cela la détection et la classification des défauts sont importantes.

L'atteinte de ce but qui est l'objectif des grands laboratoires de recherche et de développement en matière de CND présente différentes difficultés dont la plus importante est la classification des défauts multiples. La solution trouvée permet de se doter d'un moyen plus robuste et plus efficace dans la classification des défauts détectés par les ultrasons

Pour répondre à cet objectif, nous avons développé un algorithme basé sur les réseaux de neurones convolutif et d'autres méthodes intelligentes capable de détecter, de classifier les défauts présents dans un écho et de faire la différence entre les défauts simples et les défauts multiples.

Tout d'abord nous avons présenté d'une façon générale le contrôle non destructif et ses différentes méthodes en mettant l'accent sur les ultrasons

Ensuite nous avons expliqué l'intelligence artificielle et ses différents domaines, le machine Learning et ses utilités et le deep Learning, en se basant sur les réseaux de neurones convolutif, ses différents composants, son principe de fonctionnement et sur les différents paramètres utilisés dans notre architecture

Puis comme notre architecture a besoin d'une grande quantité d'informations, nous avons généré une base de données simulé avec Matlab contenant des signaux ultrasonores bruités (bruit de structure), qui représentent trois classes de défauts (0 défaut, 1 défaut, 2 défaut) pour l'apprentissage de notre modèle. La démarche suivie s'est faite en trois étapes. La première étape c'était de normaliser les données et d'associer une classe à chaque type de défaut. Dans la deuxième étape, nous avons entraîné, testé notre architecture et avons vu les résultats obtenus. La troisième étape consistait à varier les paramètres jusqu'à ce que nous ayons obtenu un $\text{test_accuracy} = 0.9963$ et un $\text{test_Loss} = 0.0094$. Enfin pour valider notre technique nous avons effectué un contrôle ultrasonore sur diverses pièces de différents matériaux et avons utilisé la base de données acquise par le contrôle dans la prédiction du taux de réussite de notre modèle dans la classification des défauts multiples.

Conclusion générale

Les résultats obtenus à la fin ont montré l'efficacité de cette technique en temps d'apprentissage et en environnement de développement.

Notre travail n'est que dans sa version initiale, on peut dire que ce travail reste ouvert pour des travaux de comparaison et/ou d'hybridation avec d'autres méthodes de classification.

Références

Références bibliographiques :

- [1] ALI RIAD contrôle non destructif ressuage, magnétoscopie, radiographie, courants de Foucault et ultrasons par 2017 - 2018.
- [2] CHOUA Yahya Application de la méthode des éléments finis pour la modélisation de configurations de contrôle non destructif par courants de Foucault 01 octobre 2009.
- [3] technique d'ultrasons.
- [4] Contrôle non destructif (CND) Jacques Dumont-Fillon, Techniques de l'Ingénieur, Traité Mesure et Contrôle.
- [5] BENAMMAR Abdeslam - étude et implémentation d'outil de traitement de signal dans la détection des imperfections multiples noyées dans le bruit. A application au contrôle ultrasonore des matériaux » 2004.
- [6] ADLER (L.) ET NAGDY (P.B.). – Improved discontinuity detection in composites by ultrasonic leaky lamb waves. Bulletin 9010 EWI Research brief, Edison Welding Institut, Columbus (Ohio), déc. 1990.
- [7] ALBERT (J.C.) et CASSIER (O). – Contrôle en ondes de Lamb de tôles d'acier inoxydable à l'aide d'un générateur de trains d'onde. 6e Colloque international sur les méthodes de contrôle non destructif, Strasbourg, oct. 1986.
- [8] COLETTE (G.). – Considération sur la propagation des ondes de Lamb. Métaux Corrosion Industrie no 454, 455, 456, 457 (1963).
- [9] DUMONT-FILLON (J.). – Les ultrasons dans la sidérurgie. Annales des Mines, p. 165/172, déc. 1978.
- [10] RABHI Mouldi COUR DE CONTROLE NON DESTRUCTIF CND 2016 - 2017
- [11] BELABAS Badr eddin – etude et implementation des techniques de traitement des signaux phased arrays en vue de détecter des défauts multiples
- [12] Numan Munir - convolutional neural network for ultrasonic weldment flaw classification in noisy conditions
- [13] Bastien L, article sur Machine Learning : Définition, fonctionnement, utilisations 18 novembre 2020

Références

- [14] Lu Hongtao; Zhang Qinchuan Applications of Deep Convolutional Neural Network in Computer Vision Department of Computer Science and Engineering, Shanghai Jiao Tong University
- [15] <https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-les-reseaux-de-neurones-artificiels>
- [16] <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>
- [17] <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>
- [18] Margot P article sur le Perceptron : qu'est-ce que c'est et à quoi ça sert ? 7 avril 2021
- [19] <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [20] Découvrez les différentes couches d'un CNN, NEDJAH Kimia ingénieure en Machine Learning et vision par l'ordinateur le 05 mai 2021

ملخص

هذا العمل هو جزء من تصنيف العيوب المتعددة التي تم الكشف عنها عن طريق اختبار الموجات فوق الصوتية غير المدمرة باستخدام الشبكات العصبية الملتوية. هذه التقنية تستخدم طبقات مع معلمات مختلفة مثل عدد من الطبقات المخفية التي تتوافق مع القدرة على التعامل مع المشاكل غير الخطية، وعدد من الخلايا العصبية لكل طبقة خفية. الحد الأقصى لعدد التكرارات، الحد الأقصى المسموح به للخطأ، معدل التعلم لمعالجة المعلومات. تم إجراء تدريب واختبار هذه العمارة مع قاعدة بيانات محاكاة. والتحقق من صحة مع النتائج المكتسبة من التحكم بالموجات فوق الصوتية التي أجريت

وأظهرت النتائج التي تم الحصول عليها فعالية هذه التقنية في تصنيف عيوب متعددة (نجاح الاختبار = 0,9963،

خسارة الاختبار = 0,0094، نسبة التنبؤ = 93%)

كلمات مفتاحية: الموجات فوق الصوتية، التحكم، التحقيق، العيوب الانتشار، الشبكات العصبية، الالتفاف

Abstract

This work is part of the classification of multiple defects detected by ultrasonic non-destructive testing using convolutional neural networks. This technique uses layers with different parameters such as the number of hidden layers which corresponds to an ability to handle non-linearity problems, the number of neurons per hidden layer. The maximum number of iterations, the maximum tolerated error, the learning rate to process the information. The training and the test of this architecture was carried out with a simulated database and the validation with the acquired results of the ultrasonic control carried out.

The results obtained from this architecture showed the effectiveness of this technique in the classification of multiple defects with (test_accuracy = 0.9963, test_loss = 0.0094 and a percentage of 93% of successful prediction).

Keyword: ultrasound, control, probe, defects, propagation, neural networks, CNN, convolution.

Résumé

Ce travail s'inscrit dans le cadre de la classification des défauts multiples détectés par le contrôle non destructif ultrasonores en utilisant les réseaux de neurones convolutifs. Cette technique utilise des couches avec différents paramètres comme le nombre de couches cachées qui correspond à une aptitude à traiter des problèmes de non-linéarité, le nombre de neurones par couche cachée, le nombre maximum d'itérations, l'erreur maximum tolérée, Le taux d'apprentissage pour traiter les informations. L'entraînement et le test de cette architecture a été effectué avec une base de données simulée et la validation avec les résultats acquis du contrôle ultrasonores effectué.

Les résultats obtenus de cette architecture ont montré l'efficacité de cette technique dans la classification des défauts multiples avec (test_accuracy = 0.9963, test_loss = 0.0094 et un pourcentage de 93% de réussite de prédiction)

Mot clé : ultrasons, contrôle, palpeur, défauts, propagation, réseaux de neurones, CNN, convolution.

Résumé
