

République Algérienne Démocratique et Populaire
الجمهورية الجزائرية الديمقراطية الشعبية
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
وزارة التعليم العالي و البحث العلمي
École nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département électronique

Mémoire de projet de fin d'études
Pour l'obtention du diplôme d'Ingénieur d'État en Électronique

Conception d'une architecture ANN optimale pour détecter et localiser les dommages dans les structures en forme de plaque

Mohamed AISSAOUI

Sous la direction de Mr. El Yamine DRIS MRB. CRTI, Alger

Présenté et soutenu publiquement le 22/06/2023 auprès des membres du jury :

Président	Mme. Aicha	MOUSSAOUI	MAA.	ENP, Alger
Promoteur	M. El Yamine	DRIS	MRB.	CRTI, Alger
Co-Promoteur	M. Cherif	LARBES	Prof.	ENP, Alger
Examineur	Mme. Nour El-houda	BENALIA	MCB.	ENP, Alger

ENP 2023

10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie.
www.enp.edu.dz

République Algérienne Démocratique et Populaire
الجمهورية الجزائرية الديمقراطية الشعبية
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
وزارة التعليم العالي و البحث العلمي
École nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département électronique

Mémoire de projet de fin d'études
Pour l'obtention du diplôme d'Ingénieur d'État en Électronique

Conception d'une architecture ANN optimale pour détecter et localiser les dommages dans les structures en forme de plaque

Mohamed AISSAOUI

Sous la direction de Mr. El Yamine DRIS MRB. CRTI, Alger

Présenté et soutenu publiquement le 22/06/2023 auprès des membres du jury :

Président	Mme. Aicha	MOUSSAOUI	MAA.	ENP, Alger
Promoteur	M. El Yamine	DRIS	MRB.	CRTI, Alger
Co-Promoteur	M. Cherif	LARBES	Prof.	ENP, Alger
Examineur	Mme. Nour El-houda	BENALIA	MCB.	ENP, Alger

ENP 2023

10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie.
www.enp.edu.dz

ملخص

يُتيح الاختبار غير المتلف باستخدام الانبعاث الصوتي اكتشاف إنشاء العيوب و / أو توطيئها و / أو تطورها. يعتمد على استخدام واحد أو أكثر من أجهزة الاستشعار التي يمكن تثبيتها بشكل دائم لمراقبة الأحداث التي تحدث داخل الهياكل ذات الأبعاد الصغيرة أو الكبيرة. ومع ذلك ، فإن دقة أدوات التعريب تعتمد بشكل كبير على الطرق المستخدمة لتحليل إشارات الانبعاث الصوتي المسجلة. في هذه الرسالة ، نقترح خوارزمية تجمع بين طريقتين محسنتين من شبكة اعصاب صناعية باستخدام الفارق الزمني المقدر للوصول وسرعة المجموعة بناءً على التحويل المويجي المستمر كمدخلات. الثاني شبكة عصبية تلافيفية أحادية الأبعاد ينفذ ميزة استخراج مباشرة من الإشارات الأولية لتوطين الإشارات الصوتية. أخيرًا ، تم إجراء مقارنة بين أداء الطرق المقترحة.

كلمات مفتاحية : انبعاث صوتي ، شبكة عصبية تلافيفية أحادية الأبعاد ، شبكة اعصاب صناعية

Abstract

Non-destructive testing (NDT) using acoustic emission (AE) enables the detection of the creation, localization, and/or evolution of defects. It relies on the use of one or more sensors that can be permanently installed to monitor events occurring within structures of small or large dimensions. However, the accuracy of localization tools heavily depends on the methods used to analyze the recorded AE signals. In this thesis, we propose an algorithm that combines two optimized ANN approaches (ANN_322 and ANN_966) by using estimated Time Difference of Arrival (TDOA) and group velocity based on CWT as inputs. The second 1D-CNN performs feature extraction directly from the raw signals for AE signal localization. Finally, a comparison of the performance of the proposed methods is conducted.

Keywords : 1D-CNN, ANN, AE

Résumé

Le contrôle non-destructif (CND) par émission acoustique (EA) permet la détection de la création, de la localisation et / ou de l'évolution de défauts. Il repose sur l'utilisation d'un ou plusieurs capteurs pouvant être installés de façon permanente à l'écoute d'événements pouvant se dérouler au sein de structures de petites ou de grandes dimensions. Cependant, la précision des outils de localisation est fortement dépendante des méthodes d'analyse des signaux d'EA enregistrés. Dans ce mémoire nous proposons un algorithme qui combine deux approches de ANN optimisé (ANN_322 et ANN_966) en utilisant comme entrée les TDOA et la vitesse de groupe estimées à base de la CWT, et le second CNN-1D effectue l'extraction des caractéristiques directement à partir des signaux EA pour la localisation des événements acoustiques. Enfin, une comparaison des performances des méthodes proposées est réalisée.

Mots clés : CNN-1D, ANN, EA

Dédicace

“

*À ma chère Maman, à mon père, à ma famille et à mes
amis.*

À tous ceux qui me sont chers, à vous tous

Merci.

”

- Mohamed

Remerciements

Je tiens à exprimer ma sincère gratitude à mon promoteur, Dr. El Yamine DRIS, qui m'a soutenu tout au long de ce travail. Je le remercie pour sa patience, sa motivation, sa disponibilité et son dévouement sans pareil. Je n'aurais pas pu espérer un meilleur superviseur et mentor. De plus, je souhaite remercier chaleureusement le Pr. Cherif LARBES qui m'a aussi soutenu tout au long de ce travail. Ils ont toujours été disponibles lorsque j'avais besoin d'eux.

Je remercie tout particulièrement les membres du jury qui ont accepté de consacrer leur temps à examiner ce travail : Madame Nour El-houda BENALIA, Docteur à l'Ecole Nationale Polytechnique et Madame Aicha MOUSSAOUI, Maître-assistante à l'Ecole Nationale Polytechnique.

Je tiens à adresser mes remerciements et ma gratitude à tous mes professeurs de l'Ecole Nationale Polytechnique, qui m'ont guidé tout au long de mes cinq années d'études.

J'aimerais également remercier ma promotion 'ELN MATCH' pour leur soutien tout au long de mon parcours, Je suis reconnaissant d'avoir eu la chance d'être parmi vous. Je remercie tout mes amis qui m'ont aidé et soutenu, en particulier Idir, Walid, Massyia, Ahmed, pour leurs supports, conseils et remarques sur mon travail.

Table des matières

Liste des tableaux

Table des figures

Liste des abréviations

Introduction générale	12
1 Émission acoustique	14
1.1 Introduction	15
1.2 Définition Et Principe	15
1.3 Historique de l'émission acoustique	16
1.4 Principales caractéristiques de l'émission acoustique	17
1.5 Description et traitement des signaux d'EA	18
1.6 Paramètres des signaux d'émission acoustique	19
1.7 Mécanismes sources d'émission acoustique	20
1.8 Propagation des ondes de Lamb dans une plaque	21
1.8.1 Équations de dispersion	22
1.9 Paramétrage du logiciel d'acquisition	24
1.10 Formation des événements acoustiques	25
1.11 Conclusion	26
2 Méthode de détermination de temps d'arrivée des ondes d'EA	27
2.1 Introduction	28
2.2 Seuil fixe	28
2.3 Analyse temps-fréquence à l'aide des ondelettes	29
2.3.1 Rappels sur la transformée de fourier et ses limitations	30
2.3.2 Principe d'incertitude d'heisenberg	30
2.3.3 Transformée de fourier à court terme (STFT)	31
2.3.4 Transformée en ondelette	33
2.3.5 Comparaison entre la CWT et STFT	40
2.3.6 Utilisation de la CWT pour la détermination du temps d'arrivée TOA des ondes	41
2.4 Conclusion	44
3 ANN et CNN	45
3.1 Introduction	46
3.2 Intelligence artificielle	46

3.3	Histoire des réseaux de neurones	46
3.4	Perceptron	48
3.5	Perceptron multicouches (MLP)	49
3.6	Les Éléments de l'architecture d'un réseau neuronal MLP	50
3.7	Entraînement des réseaux de neurones	50
3.8	Paramètres des réseaux de neurones artificiels	51
3.8.1	Taux d'apprentissage (Learning rate) :	51
3.8.2	Nombre de couches cachées	52
3.8.3	Nombre de neurones cachées	52
3.8.4	Nombre d'itérations	53
3.8.5	Choix de fonction d'activation	53
3.9	Introduction sur les CNN	57
3.10	Présentation des réseaux de neurones convolutifs	57
3.11	Réseaux de neurones convolutionnels 2D	57
3.11.1	Bloc des couches d'extraction des caractéristiques	58
3.11.2	Bloc des couches entièrement connectées	60
3.11.3	Paramètres d'un CNN	61
3.12	1D convolutional neural networks	63
3.12.1	Architecture	63
3.12.2	La propagation et la rétropropagation dans les CNN1D :	65
3.13	Conclusion	66
4	Validations expérimentales	67
4.1	Introduction	68
4.2	Dispositif expérimental	68
4.2.1	Matériau utilisé dans le problème de localisation	68
4.2.2	Caractéristiques de l'Aluminium	68
4.2.3	Géométrie de l'éprouvette	69
4.2.4	Acquisition des signaux d'EA	70
4.3	Sources d'EA Artificielles Utilisées	71
4.4	Paramètres d'évaluation	72
4.4.1	L'erreur absolue moyenne MAE	72
4.4.2	La racine de l'erreur quadratique moyenne (Root Mean Squared Error, RMSE)	72
4.5	Résultats expérimentaux	73
4.5.1	Représentation temporelle des signaux d'EA	73
4.5.2	Analyse temps-fréquence des signaux d'EA	74
4.5.3	Représentation de la CWT	75
4.5.4	Calcul du temps d'arrivée (TOA)	76
4.6	Localisation des sources d'EA	80
4.6.1	Méthodologie	80
4.6.2	Répartition des données	81
4.6.3	Localisation Par un réseau de neurone artificiel optimisé ANN	82
4.6.4	Localisation Par un réseau de neurones convolutifs 1D CNN-1D	86
4.6.5	Performances atteintes	87
4.6.6	Récapitulatif des résultats et Comparaison	96

4.7 Conclusion	97
Conclusion et perspectives	98
Bibliographie	99

Liste des tableaux

4.1	Propriétés du matériau d'aluminium	68
4.2	Coordonnées des capteurs sur la plaque en aluminium.	69
4.3	Données des TDOA calculés par CWT 'maximum d'énergie'	78
4.4	Données des TDOA calculés par CWT 'Entropie des ondelettes'	80
4.5	répartition des différents ensembles : entraînement, validation et test Pour le modèle ANN_322	81
4.6	répartition des différents ensembles : entraînement, validation et test Pour le modèle ANN après l'augmentation des données	81
4.7	répartition des différents ensembles : entraînement, validation et test Pour le modèle CNN-1D	82
4.8	Les paramètres utilisées pour l'acquisition de TOA pour le modèle ANN_322	82
4.9	Les paramètres utilisées pour l'acquisition de TOA pour le modèle ANN_966	83
4.10	Architectures ANN	85
4.11	Architecture utilisée	85
4.12	Les paramètres utilisées pour le modèle CNN-1D	87
4.13	la prédiction des sources d'EA sur l'ensemble d'entraînement	88
4.14	la prédiction des sources d'EA sur l'ensemble de test	88
4.15	Les erreurs dans l'ensemble de 322 échantillons	89
4.16	la prédiction des sources d'EA sur l'ensemble d'entraînement	91
4.17	la prédiction des sources d'EA sur l'ensemble de test	91
4.18	Les erreurs dans l'ensemble de 966 échantillons	92
4.19	la prédiction des sources d'EA sur l'ensemble d'entraînement	93
4.20	la prédiction des sources d'EA sur l'ensemble de test	94
4.21	Les erreurs pour le modèle de CNN-1D	94

Table des figures

1.1	Représentation d'une chaîne d'émission acoustique	16
1.2	Montage typique d'acquisition d'émission acoustique	18
1.3	Signaux type d'une émission continue (à gauche) et d'une émission discrète (à droite).	19
1.4	Paramètres du signal d'émission acoustique	20
1.5	Déformée de la plaque pour les modes symétriques (a) et antisymétriques (b).	22
1.6	Nombres d'onde des ondes de Lamb pour une plaque d'aluminium	23
1.7	Vitesse de phase des ondes de Lamb dans une plaque d'aluminium.	23
1.8	Vitesse de groupe des ondes de Lamb dans une plaque d'aluminium.	24
1.9	Paramètres d'acquisition des salves d'EA : PDT (Peak Definition Time), HDT (Hit Definition Time) et HLT (Hit Lockout Time)	25
1.10	Méthode de formation des événements en fonction de la chronologie d'arrivée des salves sur chacun des capteurs.	26
2.1	Représentation schématique du seuil fixe	29
2.2	Principe de la transformée de Fourier à court terme, découpage de signal en fenêtres d'analyse de même taille	32
2.3	Région étudiée dans le plan temps-fréquence par (a) la transformée de Fourier et (b) l'analyse temps-fréquence.	32
2.4	représentation du signal EA en utilisant la STFT	33
2.5	Analyse multi-résolution	33
2.6	Etapes de calcul des Coefficients d'ondelette.	37
2.7	Ondelette de Morlet complexe	39
2.8	CWT	41
2.9	Représentation STFT d'un signal EA de capteur N°1	41
3.1	Neurone biologique	47
3.2	Un neurone McCulloch-Pitts	47
3.3	Architecture d'un Perceptron	49
3.4	Réseaux de neurones MLP	50
3.5	Illustration du taux d'apprentissage	52
3.6	Fonction d'activation linear	53
3.7	Fonction d'activation sigmoïde	54
3.8	Fonction d'activation tanh	55
3.9	Fonction d'activation Relu	55
3.10	Fonction d'activation Leaky relu	56

3.11	L'illustration d'un exemple de CNN avec 2 couches de convolution et une couche entièrement connectée.	58
3.12	L'illustration d'un exemple d'opération de convolution	59
3.13	L'illustration d'un exemple d'opération de pooling	60
3.14	Opération de concaténation du vecteur de caractéristiques	60
3.15	Cartes de caractéristiques	61
3.16	principe de stride	61
3.17	Principe du drop-out durant l'entraînement d'un modèle	62
3.18	configuration 1dcnn	64
3.19	Trois couches CNN cachées consécutives	65
4.1	Plaque d'aluminium utilisé et sa photographie.	70
4.2	Représentation schématique du protocole expérimental utilisé pour valider les signaux simulés	71
4.3	Formes d'onde des signaux d'EA générés sur la plaque de d'aluminium	73
4.4	Représentation de mode symétrique et antisymétrique	74
4.5	Incertitude dans la résolution en temps et en fréquence de l'ondelette de Morlet Complexe	75
4.6	Représentation temps-fréquence issue d'une CWT des signaux EA générer par la rupture de mine	76
4.7	Représentation 3D de la CWT des signaux EA générer par la rupture de mine sur une plaque d'aluminium	76
4.8	Extraction de la vitesse de propagation à partir de la courbe de dispersion	77
4.9	l'entropie des ondelettes	78
4.10	Comparaisons des courbes d'entropie des ondelettes	79
4.11	Courbe indique l'énergie des coefficients d'ondelettes voisin qui correspond a l'échelle d'entropie minimale en fonction de temps	79
4.12	Courbe indique l'énergie des coefficients d'ondelettes voisin qui correspond a l'échelle d'entropie minimale en fonction de temps	80
4.13	Méthodes adoptées pour la localisation des signaux EA	81
4.14	méthode de localisation des sources basé sur les ANN	83
4.15	Procedure d'architecture CNN	87
4.16	Comparaison entre les positions réelle et les positions prédites	89
4.17	Estimation des emplacements des sources d'EA en utilisant ANN_322	90
4.18	Comparaison entre les positions réelles et les positions prédites	92
4.19	Estimation des emplacements des sources d'EA en utilisant ANN_996	92
4.20	Comparaison entre les positions réelles et les positions prédites	94
4.21	Estimation des emplacements des sources d'EA en utilisant CNN-1D	95
4.22	Les erreurs relatives des modèles sur la prédiction des coordonnées des sources d'EA en mm	96

Liste des abréviations

EA *Emission acoustique.*

SHM *Structural Health Monitoring.*

PDT *Peak Definition Time.*

HDT *Hit Definition Time.*

HLT *Hit Lockout Time.*

STFT *Short Time Fourier Transform.*

CWT *Continuous Wavelet Transform.*

TOA *Time Of Arrival.*

DTOA *Difference Time Of Arrival.*

IA *Intelligence artificielle.*

CNN1D *Convolutional neural network one dimension.*

ANN *Artifiel neural network.*

MLP *Multi Layer Perceptron.*

Adam *Adaptive Moment Estimation.*

FB *Forward propagation.*

BP *Backward propagation.*

MSE *Mean Squared Error.*

RMSE *Root Mean Square Error.*

MAE *Mean Absolute Error.*

Introduction générale

De nombreuses structures en service souffrent de problèmes de dommages cumulatifs résultant des contraintes mécaniques et / ou thermiques (surcharges, fissures de fatigue liées à l'âge [1] .ect). Afin d'établir le diagnostic, détecter les inhomogénéités et de réduire les coûts de maintenance, il est évident qu'il est nécessaire de disposer d'un système de surveillance fiable et rigoureux.

Les méthodes de contrôle non destructif (CND) permettent de tester une structure sans provoquer de modification irréversible. Elles représentent donc un enjeu industriel important du point de vue économique puisque les pièces testées peuvent être de nouveau utilisées lorsqu'aucun défaut n'a été révélé. L'émission acoustique (EA) désigne la manifestation d'une onde acoustique générée par une source située au sein d'un matériau subissant des modifications structurales. Elle est aussi une technique de contrôle non destructif (CND) consistant à mesurer et interpréter la signature acoustique des sources d'endommagements. L'utilisation de la technique EA offre la possibilité d'une surveillance en temps réel et une détection précoce des dommages dans une structure. L'une des caractéristiques les plus essentielles de la technique EA est sa capacité à localiser les dommages/fissures en se basant sur les événements EA. L'identification de l'emplacement de la source peut permettre une investigation globale précise d'une structure et une compréhension préalable de la zone spécifique potentiellement endommagée/fissurée [2]. Elle a l'avantage d'être totalement passive et donc de n'avoir aucune influence sur les dommages observés.

En effet, lors d'un essai, le signal généré par la source d'endommagement et qui se propage au sein du matériau, est mesuré par un capteur piézoélectrique, puis enregistré et exploité par le système d'acquisition. Ainsi, entre sa création et sa visualisation par l'utilisateur, le signal subit de nombreuses transformations. De même, le type de capteur utilisé et son positionnement à la surface du matériau modifient la forme du signal mesuré. Toutes ces transformations rendent délicate la localisation et l'identification des sources d'EA.

Le contexte de ce mémoire de fin d'étude porte sur la proposition et l'évaluation des outils de traitement et d'analyse des signaux non-stationnaires pour l'estimation de l'emplacement des sources d'émission acoustique (EA) au sein d'un matériau sous forme de plaque, tout en considérant les incertitudes liés à la modélisation et à la mesure. Les techniques d'intelligence artificielle sont, depuis quelques années, de plus en plus utilisées dans le domaine de la surveillance de la santé structurelle (SHM) [3]. on peut cité par exemple les ANN, le régresseur Random Forest [4] et la régression généralisée [5]. Plus précisément, un ANN bien entraîné pourrait être utilisé pour prédire les résultats sans

une bonne connaissance des fonctions analytiques explicites. Au cours de l'apprentissage du réseau, les caractéristiques inhérentes au système peuvent être reproduites par une relation de fonction symbolique établie entre les données d'entrée et les données de sortie.

Les ondes d'EA reçues par un réseau de capteurs piézoélectriques collés en surface du matériau contiennent des informations caractéristiques sur les dommages sources d'EA. La première partie de ce travail portera sur le développement de nouvelles techniques d'extraction de temps d'arrivée (TOA) à partir des signaux d'EA reçus. Pour augmenter la précision des mesures des TOA des ondes acoustiques, une variété de méthodes ont été développées, on peut citer la transformée de Fourier à court temps (TFCT) [6], la distribution de Wigner-Ville (WVD) [7], la transformée en ondelette continue (CWT) [8], etc. Dans ce travail, Nous avons proposé une analyse temps-fréquence basée sur la CWT. Cette dernière a été choisie pour sa bonne résolution à la fois dans le domaine temporel et fréquentiel et pour sa propriété multi-résolution. La deuxième partie de ce travail traitera du problème de localisation des sources d'EA à partir des différences de temps d'arrivée (TDOA). Nous proposerons dans cette deuxième partie un algorithme qui combine deux approches de ANN optimisé (ANN_322 et ANN_966) en utilisant comme entrée les TDOA et la vitesse de groupe. La vérification expérimentale des performances de la méthode proposée est réalisée en utilisant des expériences réelles sur une structure en forme de plaque d'aluminium. Des ruptures de mine de crayon ont été utilisées pour simuler plusieurs scénarios de dommages, fournissant une base de données pour l'entraînement des ANN et CNN1D. Les ANN utilisent en entrée les DTOA et la vitesse de propagation estimées à base de la CWT, et le second CNN1D effectue l'extraction des caractéristiques directement à partir des données brutes. En fin, une comparaison des performances des méthodes proposées est réalisée.

Ce mémoire est divisé en quatre chapitres qui sont structurés comme suit :

Le premier chapitre a pour objet de présenter un aperçu général des notions fondamentales de l'émission acoustique et des différents modes de propagation de ces ondes dans les matériaux.

Le deuxième chapitre est dédié pour présenter les principales techniques d'extraction de temps d'arrivée des signaux d'EA. L'analyse temps-fréquence issue de la CWT a été choisie pour sa bonne résolution à la fois dans le domaine temporel et fréquentiel.

Le troisième chapitre décrit les méthodes proposées à base des réseaux de neurones artificiels et les réseaux de neurones convolutifs pour la localisation des sources d'émission acoustique.

Le quatrième chapitre s'intéresse à la validation expérimentale des méthodes d'estimation proposées et à analyser les performances des différents systèmes mis en place pour identifier et localiser les sources d'émission acoustique.

Enfin, ce mémoire se termine par une conclusion générale et quelques perspectives pour un travail futur.

Chapitre 1

Émission acoustique

1.1 Introduction

Une étude bibliographique du contrôle par émission acoustique (EA) des phénomènes impliqués dans l'évolution des endommagements des matériaux et des structures est proposée. L'émission acoustique (EA) est mise en œuvre en tant que méthode d'investigation non destructive passive, basée sur l'exploitation de signaux engendrés par un phénomène d'émission spontanée d'ondes ultrasonores par un matériau soumis à une sollicitation ou à une transformation interne. Cette technique est très utilisée au sein de nombreux domaines d'application : les infrastructures de transport (secteurs automobiles, ferroviaire, aérien) et d'habitat, les matériaux aéronautiques, pour ne citer que les principaux.

Ce chapitre a pour but de présenter la technique d'émission acoustique (EA) ainsi que les problématiques liées à la complexité et à la richesse des signaux d'émission acoustique. Il constitue une étape essentielle pour notre projet de fin d'études, en nous permettant d'acquérir les connaissances nécessaires pour développer une méthodologie fiable et efficace de localisation des défauts sur des structures métalliques en formes de plaque.

1.2 Définition Et Principe

L'émission acoustique est le phénomène de libération d'énergie sous forme d'ondes élastiques transitoires résultant des micro-déplacements locaux internes au sein d'un matériau (fissures, inclusions, corrosion, délaminage, etc.) sous l'effet d'une sollicitation d'origine mécanique, thermique ou chimique. Les ondes générées se propagent dans toutes les directions jusqu'à la frontière de la structure où elles sont détectées par des capteurs spécifiques qui permettent leur conversion en signaux électriques. Ces signaux sont ensuite enregistrés et ils contiennent beaucoup d'informations. Le traitement et l'analyse de ces informations collectées se fera en fonction du but recherché. Toutes les fréquences des ondes concernées sont dans la gamme ultrasonores plus de 20 kHz à quelques centaines de MHz.

L'émission acoustique (AE) est reconnue aussi comme une technique passive qui permet la surveillance en temps réel des matériaux et des structures, fournissant des informations utiles non seulement sur la présence de défauts mais aussi sur leur criticité [9]. Toutefois, il convient de noter que, pour identifier une fracture, il est nécessaire que celle-ci soit déjà présente dans le matériau [10]. L'EA fait donc référence à la fois au phénomène de libération d'énergie dans un matériau et à la technique qui permet de mesurer ce phénomène.

La détection est assurée généralement par des capteurs piézo-électriques permettant la conversion de l'onde acoustique en un signal électrique. Le signal d'émission acoustique est ensuite conditionné par un préamplificateur qui assure l'adaptation de l'impédance électrique, l'amplification et le filtrage. Le signal d'émission acoustique est ensuite transmis au système de mesure qui permet la numérisation, l'enregistrement des formes d'ondes en temps réel et/ou l'extraction d'un certain nombre de paramètres relatifs aux signaux.




FIG. 1.1 : Représentation d'une chaîne d'émission acoustique

1.3 Historique de l'émission acoustique

L'identification des anomalies structurelles par le son des émissions sonores est une méthodologie appliquée avec succès depuis longtemps. Les ouvriers potiers, jusqu'à plusieurs millénaires avant J.-C., écoutaient les sons audibles pendant la phase de refroidissement afin d'identifier un éventuel défaut structurel. De même, quelques millénaires plus tard, cette procédure a été appliquée au travail des métaux [11]. Les artefacts étaient battus pour écouter le bruit qu'ils émettaient afin d'identifier d'éventuelles fractures. Dans certaines productions artisanales, ces procédures sont encore appliquées aujourd'hui.

Les bases de cette technique remontent toutefois au début des années 1950, lorsque J. Kaiser a utilisé une instrumentation électronique pour détecter les émissions sonores émises par les métaux lors de leur déformation [12]. Kaiser a constaté que tous les métaux étudiés présentaient une activité acoustique et que cette activité était irréversible, en ce sens qu'elle disparaissait au cours d'un processus de rechargement du matériau jusqu'à ce que le niveau de contrainte dépasse sa valeur précédente. Ce phénomène est aujourd'hui connu sous le nom d'effet Kaiser et s'est avéré très utile dans les études sur l'EA [13]. Schofield [14] et Tatro [15] ont commencé leurs recherches au milieu des années 1950, contribuant de manière significative à l'amélioration de l'équipement instrumental et à la clarification de la genèse de l'EA. Ils ont été les premiers à observer que l'émission dans les métaux était principalement due au mouvement des dislocations qui accompagne la déformation plastique, plutôt que d'être entièrement due au glissement réciproque des grains, comme l'avait initialement proposé Kaiser. Au cours des années 1960, de nombreux chercheurs se sont intéressés à l'EA en utilisant cette technique pour l'étude des matériaux, la caractérisation et l'évaluation de la qualité, les essais non destructifs et les vérifications structurelles [16].

Les techniques modernes basées sur les émissions acoustiques ont recherché des éventuelles signatures spectrales permettant d'identifier les défauts structurels dans le spectre ultrasonique. Le terme ultrason définit des ondes élastiques dont la fréquence est supérieure à la limite d'audition de l'oreille humaine et dont la bande de fréquence varie donc entre 20 kHz à 1 GHz. Généralement, dans les matériaux où se produisent des processus dynamiques, tels que des déformations, des fractures ou des transitions de phase, il y a une libération d'énergie élastique sous forme d'ondes élastiques impulsives, dont le spectre de fréquence se situe entre 1 kHz et 10 GHz [17]. Les processus dynamiques à l'origine des émissions acoustiques sont bien mis en évidence, par exemple, par les phénomènes acoustiques macroscopiques liés à la rupture ou à la déformation d'un matériau

solide. L'intérêt physique de ces phénomènes concerne cependant des signaux éloignés des limites du spectre audible, tant en intensité qu'en fréquence, déterminés dans les matériaux solides par le mouvement des déplacements, la croissance des microfractures et le mouvement du fil du grain, processus que nous appellerons sources d'émission acoustiques [18].

1.4 Principales caractéristiques de l'émission acoustique

L'émission acoustique (EA) se distingue des techniques ultrasonores classiques par plusieurs caractéristiques. Contrairement aux ultrasons contrôlés par l'opérateur, l'EA est générée par des phénomènes physiques et des mécanismes d'endommagement évolutifs dans le temps. L'EA est déclenchée en fonction des sollicitations subies par le matériau, ce qui entraîne son développement. Les principales caractéristiques de l'EA sont les suivantes :

Non-destructif : L'émission acoustique est une technique de contrôle non destructive, ce qui signifie qu'elle n'endommage pas le matériau ou la structure inspectée. Elle permet d'identifier les défauts ou les anomalies sans altérer leur intégrité.

Sensibilité aux micro-déformations : L'émission acoustique est sensible aux micro-déformations et aux événements dynamiques à l'intérieur de l'objet ou de la structure. Elle peut détecter les signaux acoustiques générés par des fissures, des fractures, des déformations ou des mouvements minimes.

Localisation précise des sources : L'émission acoustique permet de localiser avec précision les sources des signaux acoustiques. En utilisant des capteurs placés à des emplacements spécifiques, il est possible de déterminer la position des défauts ou des anomalies.

Surveillance en temps réel : L'émission acoustique peut être utilisée pour surveiller en temps réel les objets ou les structures. Cependant, l'EA ne détecte que des mécanismes évolutifs dans le temps (par exemple, l'apparition ou la propagation d'une fissure) et ignore les défauts non évolutifs.

Sensibilité à distance : Les capteurs acoustiques de l'émission acoustique peuvent être placés à distance de l'objet ou de la structure inspectée, ce qui facilite l'accès aux zones difficiles à atteindre.

Ces caractéristiques [19, 20] font de l'émission acoustique une technique précise, sensible et non destructive pour la détection, la localisation et la surveillance des défauts ou des anomalies dans les matériaux et les structures.

1.5 Description et traitement des signaux d'EA

Une source d'EA peut donner naissance à des ondes longitudinales, à des ondes transversales, à des ondes de surface, dites de Rayleigh, ainsi qu'à des ondes de plaque, dites de Lamb. La détection de ces ondes est assurée par un capteur transformant l'énergie mécanique en signal électrique, généralement de très faible amplitude du fait de la très faible amplitude des ondes émises. Le conditionnement du signal est assuré par un pré-amplificateur placé à proximité immédiate du capteur permettant d'acheminer le signal sur de longues distances. (Figure 1.2)

Un signal d'EA est modélisé comme le résultat du produit de convolution de fonctions de transfert :

$$Z(t) = S(t) * G(t) * R(t) * H(t) \quad (1.1)$$

tel que : Z est le signal EA résultant, S le signal de la source, G la réponse impulsionnelle du matériau, R la fonction du capteur, H la fonction du système d'acquisition (filtrage, amplificateurs, échantillonnage, ...etc.).

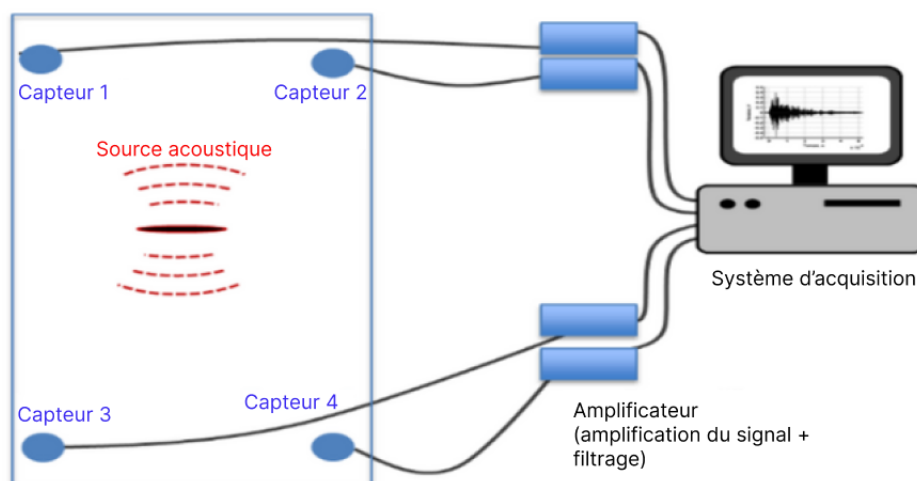


FIG. 1.2 : Montage typique d'acquisition d'émission acoustique

On peut distinguer deux types de signaux d'émission acoustique (Figure 1.3) :

l'Émission continue qui est constituée d'un grand nombre de signaux aléatoires de très petite amplitude qui se superposent les uns les autres et qui s'ajoutent au bruit de fond ;

l'Émission discrète qui est constituée de signaux transitoires, aléatoires, bien séparés les uns des autres ou ondes sinusoïdales amorties, cas de fissures conduisant à la rupture.




FIG. 1.3 : Signaux type d'une émission continue (à gauche) et d'une émission discrète (à droite).

Généralement, les capteurs utilisés pour l'EA sont de type piézoélectriques, et ils ont la propriété de convertir les ondes mécaniques qui les excitent en ondes électriques. Selon la plage de fréquences ultrasonores souhaitée, les capteurs d'émission acoustique utilisés sont de deux types ::

- **large bande** : ils possèdent une bande passante régulière pour une étendue fréquentielle assez large pouvant aller jusqu'au MHz. Ils ont l'avantage de modifier peu la forme réelle du signal mais ils ont une faible sensibilité.

- **résonnants** : ils ont une bande passante moins large et un pic aux alentours d'une certaine fréquence. Ce pic de réponse entraîne une modification de l'allure des signaux et de leur contenu fréquentiel. Ces capteurs sont cependant les plus utilisés car ils présentent une meilleure sensibilité et permettent de détecter des signaux de plus faible amplitude.

1.6 Paramètres des signaux d'émission acoustique

Les signaux successifs enregistrés lors des différentes expériences sont appelés salves (Figure 1.4). Pour être enregistrée, une salve doit dépasser un seuil de déclenchement défini par l'opérateur permettant de s'affranchir le plus possible du bruit de fond tout en conservant le maximum d'information provenant du système étudié.

Temps de montée : c'est le temps entre la première salve qui dépasse le seuil et l'amplitude maximale

Durée : La durée d'un signal correspond à la période de temps entre son premier et son dernier échantillon.

Nombre de coups : Le nombre de coups d'un signal correspond au nombre de fois où le signal traverse son axe horizontal (c'est-à-dire la ligne zéro) en passant de valeurs positives à négatives ou de valeurs négatives à positives.

Energie : L'énergie d'un signal continu est définie comme l'intégrale du carré de l'amplitude du signal sur l'ensemble de temps, tandis que pour un signal discret, l'énergie est définie comme la somme du carré de l'amplitude du signal sur l'ensemble des échantillons de temps.

Signal continu :

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dt \quad (1.2)$$

Signal discret :

$$E = \sum_{n=-\infty}^{+\infty} |x[n]|^2 \quad (1.3)$$

En pratique, on utilise souvent l'approximation de l'énergie par la puissance moyenne sur une durée T

Fréquence moyenne : rapport du nombre de coups sur la durée du signal

Amplitude maximale (Amax) : c'est l'amplitude maximale du signal sur toute la durée d'une salve.




FIG. 1.4 : Paramètres du signal d'émission acoustique

1.7 Mécanismes sources d'émission acoustique

Les mécanismes d'endommagement sources d'émission acoustique sont divers et dépendent des caractéristiques spécifiques du matériau ou de la structure étudiée. Lorsqu'un matériau est soumis à des contraintes mécaniques, telles que la traction, la compression ou la flexion, des déformations plastiques peuvent se produire, entraînant la génération d'ondes acoustiques. De nombreux phénomènes physiques et mécanismes d'endommagement des matériaux sont susceptibles d'être à l'origine de l'EA. Toutefois, nous pouvons distinguer trois grandes catégories [21] [22] :

Sources d'origines mécaniques L'émission acoustique d'origine mécanique est générée par les mécanismes d'endommagement liée principalement aux contraintes mécaniques appliquées sur les matériaux et structures. Ces mécanismes diffèrent d'un matériau à l'autre. Les mécanismes à l'origine de l'EA comprennent les mouvements coopératifs de dislocation, la création et la propagation des fissures, les fissurations matricielles, la décohésion et les transformations de phase, etc... Les déformations plastiques génèrent des ondes acoustiques à partir des micro-déplacements atomiques ou moléculaires, tandis que la propagation des fissures et des micro-fractures entraîne des frottements, des séparations ou des fermetures brusques des surfaces, produisant ainsi des signaux acoustiques caractéristiques. L'activité de dislocation, qui correspond au mouvement des défauts cristallins sous contraintes, peut également générer des ondes acoustiques. La détection et l'analyse de ces sources d'origine mécanique permettent d'évaluer l'intégrité structurale et la progression des défauts.

Sources artificielles Les sources artificielles d'émissions acoustiques sont largement utilisées en raison de leur facilité de mise en œuvre et de leur reproductibilité. Elles jouent un rôle important dans la calibration des capteurs acoustiques et la vérification des montages expérimentaux lors d'expérimentations en laboratoire. Parmi les sources artificielles on trouve la rupture d'une mine de crayon *PencilLeadBreak* (PLB)[23] qui est la plus utilisée au laboratoire.

Sources dues à des processus physico-chimiques Certains processus physico-chimiques, tels que la corrosion, la cavitation ou les réactions chimiques, peuvent générer des signaux acoustiques.

1.8 Propagation des ondes de Lamb dans une plaque

Les signaux d'émission acoustique sont des ondes sonores générées par des sources vibratoires. Les ondes de Lamb sont un type particulier d'ondes élastiques qui se propagent le long de la surface d'une structure solide, comme une plaque ou une coque.

La relation entre les signaux d'émission acoustique et les ondes de Lamb réside dans le fait que les signaux d'émission acoustique peuvent contenir des composantes correspondant aux ondes de Lamb. Cela signifie que lorsqu'une structure solide est soumise à des vibrations ou à des impacts, des ondes de Lamb peuvent être générées et se propager à travers la structure. Ces ondes de Lamb peuvent être détectées et enregistrées à l'aide de capteurs d'émission acoustique. L'analyse des signaux d'émission acoustique peut permettre d'identifier et de caractériser les ondes de Lamb présentes dans une structure, ce qui peut être utile pour diagnostiquer d'éventuels défauts ou dommages. Les ondes de Lamb peuvent fournir des informations sur la localisation, la taille, la nature et l'évolution des défauts dans une structure, ce qui en fait une technique précieuse pour la surveillance non destructive des matériaux et des structures.

Dans un solide élastique infini, il est possible de distinguer deux types d'ondes : une onde longitudinale ou de compression qui se propage dans la même direction que les

particules, et une onde transversale ou de cisaillement dont les particules vibrent perpendiculairement à la direction de propagation. Les ondes de Lamb, également appelées ondes de plaque, sont des ondes qui se propagent le long des parois d'une structure. Elles résultent de la combinaison d'une onde longitudinale et d'une onde transversale à des fréquences particulières appelées fréquences de résonance. Ainsi, l'énergie reste localisée dans la plaque et une onde guidée se propage le long des surfaces du guide plan.

Les ondes de Lamb ont été découvertes par Sir H. Lamb en 1889 [24], [25]. Elles sont des ondes qui se propagent dans une plaque plane d'épaisseur finie et peuvent se propager sur des distances pouvant atteindre plusieurs dizaines de longueurs d'onde, selon la nature des matériaux et la fréquence. Il existe deux types d'ondes de Lamb : symétriques et antisymétriques, en fonction de la façon dont les surfaces vibrent par rapport au plan médian. La Figure 1.5 montre une représentation de la déformation de la surface de la plaque pour les modes symétriques et antisymétrique.




FIG. 1.5 : Déformée de la plaque pour les modes symétriques (a) et antisymétriques (b).

1.8.1 Équations de dispersion

Les équations de dispersion permettent de calculer le nombre d'onde noté k des différents modes de Lamb. Ces équations sont assez répandues dans la littérature [26, 27, 28] et sont rappelées ici dans les équations (1.4) et (1.5) :

Pour les modes symétriques :

$$\frac{\tan\left(\frac{q \cdot e}{2}\right)}{\tan\left(\frac{p \cdot e}{2}\right)} + \frac{4k^2 p \cdot q}{(q^2 - k^2)^2} = 0 \quad (1.4)$$

Pour les modes antisymétriques :

$$\frac{\tan\left(\frac{p \cdot e}{2}\right)}{\tan\left(\frac{q \cdot e}{2}\right)} + \frac{4k^2 p \cdot q}{(q^2 - k^2)^2} = 0 \quad (1.5)$$

avec e l'épaisseur de la plaque $p^2 = k_L^2 - k^2$ et $q^2 = k_T^2 - k^2$, $k_L = \frac{2\pi f}{c_L}$ et $k_T = \frac{2\pi f}{c_T}$ les nombres d'onde respectifs des ondes longitudinales et transverses dans la plaque, f

la fréquence considérée, C_T et C_L les vitesses respectives des ondes longitudinales et transverses dans le matériau qui compose la plaque.

Ces équations sont invariantes pour le produit fréquence-épaisseur. Les résultats seront donc affichés en fonction du produit $f.e$ en $\text{KHz} \cdot \text{mm}$, ce qui permet d'utiliser les mêmes courbes même si l'épaisseur de la plaque change. La figure 1.6 montre les nombres d'onde des différents modes de Lamb calculés pour une plaque en aluminium $C_L = 6380 \text{ m/s}$ et $C_T = 3100 \text{ m/s}$.

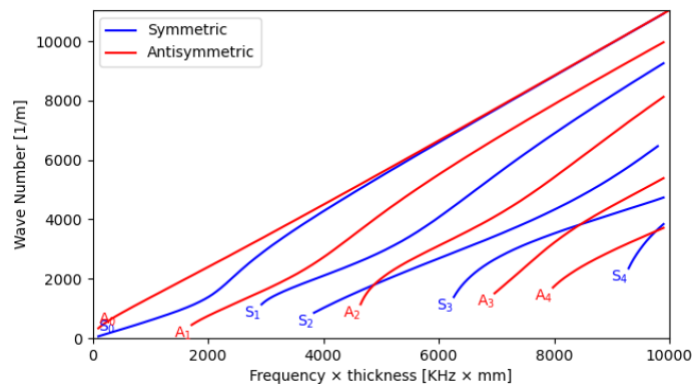


FIG. 1.6 : Nombres d'onde des ondes de Lamb pour une plaque d'aluminium

La figure 1.6 présente les courbes de dispersion théoriques pour une plaque d'aluminium plane infinie de 5 mm d'épaisseur. Dix modes sont observés : les modes symétriques S_0, S_1, S_2, S_3, S_4 et les modes antisymétriques A_0, A_1, A_2, A_3, A_4 .

Une fois les nombres d'onde k calculés, la vitesse de phase v_φ est accessible où $v_\varphi = w/k$. w/k correspond à la vitesse de propagation des fronts d'ondes de fréquence donnée, à l'intérieur d'un paquet d'ondes. Les courbes résultantes pour une plaque d'aluminium pour chacun des modes calculés sont présentées à la figure 1.7. Lorsque la valeur de ce produit avoisine zéro, seuls les modes symétriques et antisymétriques d'ordre zéro sont respectivement solutions des équations de dispersion. Ces modes n'ont pas de fréquence de coupure : ils existent quelle que soit la fréquence, contrairement aux modes d'ordre supérieur. Ceux-ci sont d'autant plus nombreux que le produit $f.e$ augmente.




FIG. 1.7 : Vitesse de phase des ondes de Lamb dans une plaque d'aluminium.

On peut remarquer que les courbes des deux modes ont des pentes différentes. Ainsi que la courbe symétrique est plus haut que la courbe antisymétrique, ce qui signifie que les modes symétriques ont une vitesse de propagation plus grande que les modes antisymétriques. Cela est dû à la façon dont les ondes de surface se propagent le long de la plaque, en fonction de leur mode de vibration.

La vitesse à laquelle se propage un groupe d'ondes de pulsation centrale le long d'une plaque est appelée vitesse de groupe (Figure 1.8). Cette vitesse représente également la vitesse à laquelle l'énergie transportée par l'onde se propage le long de la plaque. La vitesse de groupe est influencée par la vitesse de phase de l'onde et sa variation par rapport à la fréquence. Pour la calculer, on peut utiliser l'équation (1.6) qui a été présentée dans la référence [29].

$$V_g(w) = V_p(w)^2 \left[V_p(w) - w \frac{dV_p(w)}{dw} \right]^{-1} \quad (1.6)$$

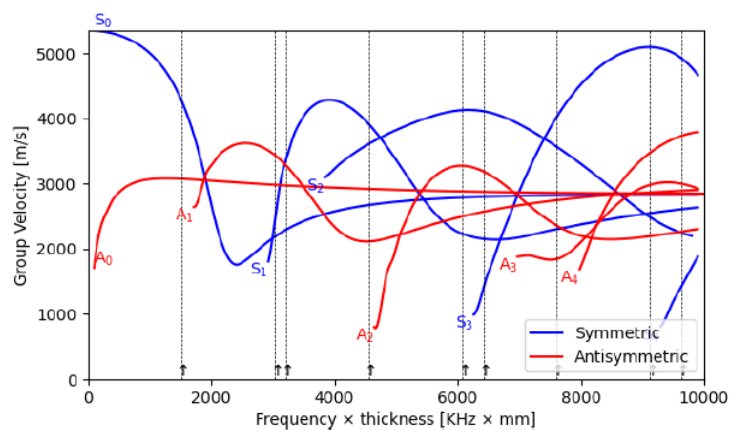


FIG. 1.8 : Vitesse de groupe des ondes de Lamb dans une plaque d'aluminium.

Les courbes de dispersion sont utiles pour comprendre les propriétés des ondes dans les matériaux et peuvent être utilisées pour prédire le comportement des ondes dans des structures complexes et même pour trouver la vitesse de propagation de l'onde. Les modes les plus courants sont les modes symétriques et antisymétriques.

1.9 Paramétrage du logiciel d'acquisition

Pour avoir des signaux fiables et utilisables pour la localisation des défauts, le logiciel d'acquisition nécessite un réglage des paramètres d'acquisition des salves. Parmi ces paramètres nous trouvons : Le seuil d'acquisition, les PDT (Peak Definition Time), HDT (Hit Definition Time) et HLT (Hit Lockout Time) (Figure 1.9)

Seuil d'acquisition utilisé pour marquer le début d'une salve, il doit être réglé pour être juste supérieur au bruit de fond,

PDT(Peak Definition Time) : ce paramètre sert à la détermination du maximum de la salve et à la mesure du temps de montée, il débute lorsque le signal dépasse le seuil et finit quand on a l'amplitude maximale.

HDT(Hit Definition Time) : ce paramètre est utilisé pour individualiser et séparer les salves d'éventuels échos. Il sert à la détermination de la fin de la salve. Le HDT doit être à la fois assez long pour assurer la mesure d'une salve entière et assez court que possible afin d'éviter que deux salves ne soient considérées comme une seule ;

HLT(Hit Lockout Time) : c'est le temps de réarmement, l'intérêt est de ne pas re-déclencher l'acquisition sur des échos ou des réflexions tardives.

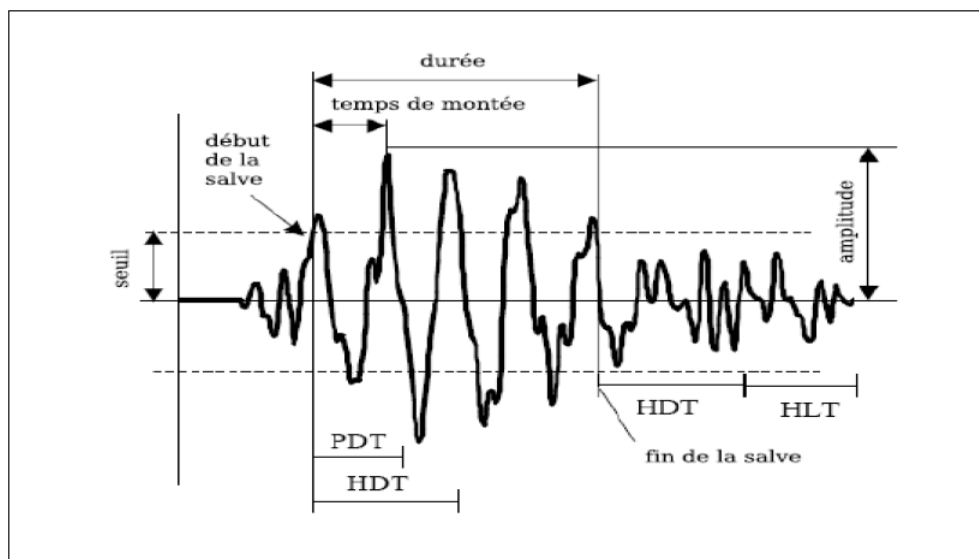


FIG. 1.9 : Paramètres d'acquisition des salves d'EA : PDT (Peak Definition Time), HDT (Hit Definition Time) et HLT (Hit Lockout Time)

1.10 Formation des événements acoustiques

Lorsqu'une source d'émission acoustique est activée, elle produit des ondes mécaniques qui se propagent jusqu'aux capteurs en surface. Les signaux enregistrés par ces capteurs sont regroupés pour former un événement acoustique, représentant une source inconnue. Le regroupement des signaux est basé sur le temps de propagation des ondes et la taille du réseau de capteurs.

La méthodologie illustrée dans la figure 1.10 [30] pour former des événements acoustiques consiste à utiliser des flèches bleues pour représenter le temps pour chaque capteur. Les points orange marquent le début d'une salve enregistrée. Le regroupement des salves en événements se fait en déplaçant une fenêtre temporelle de largeur "T" et en comptant le nombre de salves à l'intérieur. Si ce nombre dépasse 3, les salves sont regroupées pour

former un événement. Une fois qu'un événement est formé, la fenêtre est déplacée immédiatement après la dernière salve incluse, évitant ainsi de compter plusieurs fois une salve dans plusieurs événements.

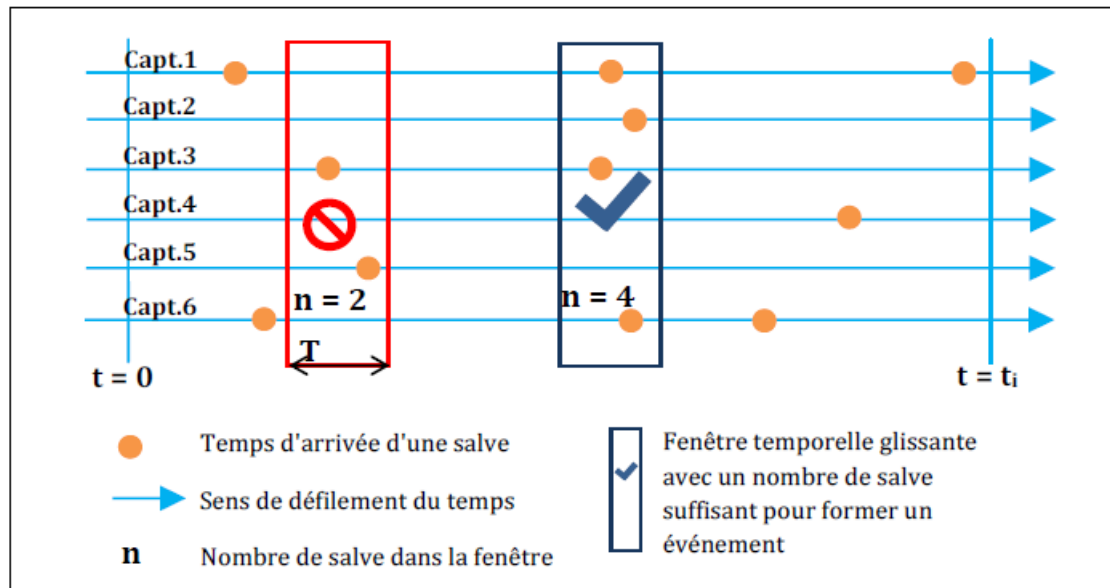


FIG. 1.10 : Méthode de formation des événements en fonction de la chronologie d'arrivée des salves sur chacun des capteurs.

La sélection de la largeur de la fenêtre temporelle revêt une importance cruciale, étant donné qu'elle est liée au temps requis par une onde pour se déplacer sur la distance maximale entre deux capteurs.

1.11 Conclusion

L'émission acoustique est une technique de contrôle non-destructif passive qui présente un intérêt certain pour la surveillance des structures en fonctionnement en raison de sa simplicité de mise en œuvre et de son faible coût et qui s'avère aussi être une méthode prometteuse pour l'analyse et le traitement des ondes générées par les différents mécanismes d'endommagement dans les matériaux. Dans ce chapitre, nous avons décrit le principe général de cette technique qui apporte des informations précieuses sur des détails microstructuraux sensibles dans les matériaux.

L'EA peut localiser efficacement les sources d'EA en utilisant les temps d'arrivée des ondes captées par un réseau de capteurs. Pour cette thèse, nous avons opté pour la localisation à l'aide d'un réseau de neurones artificiels. Les données d'entrée du réseau sont basées sur les différences de temps d'arrivée et la vitesse de groupe des salves enregistrées par les capteurs piézoélectriques. Plusieurs techniques de détermination des temps d'arrivée des salves existent dans la littérature, et l'analyse temps-fréquence semble être la plus appropriée pour résoudre cette problématique. Le chapitre suivant présentera donc une méthode de mesure du temps d'arrivée en nous basant sur la transformée en ondelette continue.

Chapitre 2

Méthode de détermination de temps d'arrivée des ondes d'EA

2.1 Introduction

Le contrôle par émission acoustique (EA) est une technique non-destructive largement utilisée pour détecter les défauts dans les matériaux. Cependant, l'une des inconnues majeures dans un contrôle par EA est le temps d'arrivée des signaux d'EA sur les capteurs. Ce temps d'arrivée est crucial pour localiser précisément l'emplacement des défauts. Ainsi, le calcul précis du temps d'arrivée des signaux d'EA est essentiel pour garantir l'efficacité et la fiabilité de cette technique.

Dans ce contexte, ce travail vise à établir de manière théorique une méthode efficace pour extraire le temps d'arrivée des signaux d'EA. Cette méthode permettra de déterminer la transition entre deux phases dans le signal enregistré par les capteurs : une phase de bruit naturel et une phase où le capteur enregistre à la fois le bruit et l'activité acoustique résultant d'un événement. Cette transition est cruciale pour localiser avec précision l'emplacement des défauts dans les matériaux.

Différentes méthodes de détermination du temps d'arrivée des ondes d'EA ont été proposées dans la littérature, chacune présentant ses avantages et ses limites. Dans les paragraphes suivants, nous présenterons les deux principales méthodes utilisées pour extraire le temps d'arrivée des signaux d'EA : le seuil fixe et l'analyse temps-fréquence utilisant la transformée en ondelette continue.

2.2 Seuil fixe

Le seuil fixe est une méthode couramment utilisée pour extraire le temps d'arrivée des signaux d'émission acoustique (EA). Cette méthode consiste à fixer un seuil d'amplitude pour le signal enregistré par le capteur. Lorsque le signal dépasse ce seuil, cela indique que l'activité acoustique a été détectée et que le temps d'arrivée doit être enregistré (Figure 2.1).

Cependant, cette méthode présente des limites, car le seuil doit être déterminé de manière empirique, ce qui peut entraîner une erreur de détection. De plus, la présence de bruit de fond dans le signal peut rendre la détection difficile, car le seuil peut être déclenché par le bruit plutôt que par l'activité acoustique.

C'est pourquoi d'autres méthodes plus sophistiquées ont été développées, telles que l'analyse temps-fréquence utilisant la transformée en ondelette continue, qui permettent une détection plus précise et fiable du temps d'arrivée des signaux d'EA.




FIG. 2.1 : Représentation schématique du seuil fixe

2.3 Analyse temps-fréquence à l'aide des ondelettes

L'analyse temps-fréquence est une technique couramment utilisée pour l'analyse de signaux qui varient en fréquence au fil du temps. Cette technique permet de décomposer un signal en composantes fréquentielles et temporelles, ce qui permet de mieux comprendre la nature du signal et d'extraire des informations utiles.

L'utilisation de la transformée en ondelette continue est une méthode populaire pour effectuer l'analyse temps-fréquence. Cette méthode utilise des fonctions d'ondelettes qui peuvent être déplacées et dilatées pour couvrir différentes échelles de temps et de fréquence. Les ondelettes sont appliquées au signal pour obtenir une représentation temps-fréquence du signal.

Cette méthode présente des avantages par rapport à d'autres méthodes, comme la transformée de Fourier, car elle permet une analyse à résolution variable, ce qui signifie qu'elle peut fournir une meilleure représentation des caractéristiques du signal à différentes échelles de temps et de fréquence. Cela est particulièrement utile pour l'analyse de signaux non-stationnaires, où les caractéristiques du signal changent avec le temps.

Dans le contexte de l'émission acoustique, l'analyse temps-fréquence à l'aide des ondelettes peut être utilisée pour extraire le temps d'arrivée des signaux d'EA avec une précision accrue. En décomposant le signal en composantes fréquentielles et temporelles, cette méthode permet de mieux isoler l'activité acoustique du bruit de fond et d'obtenir une estimation plus précise du temps d'arrivée.

Dans les sections suivantes, nous détaillerons les étapes impliquées dans l'utilisation de la transformée en ondelette continue pour l'analyse temps-fréquence des signaux d'EA et évaluerons l'efficacité de cette méthode pour la détection de défauts dans les matériaux.

2.3.1 Rappels sur la transformée de fourier et ses limitations

La transformée de Fourier est une technique mathématique couramment utilisée pour analyser les signaux en fréquence. Elle permet de décomposer un signal temporel en ses composantes fréquentielles. Cela est particulièrement utile pour comprendre les caractéristiques d'un signal et pour extraire des informations utiles. L'expression analytique de la transformée de Fourier d'une fonction continue $x(t)$ est définie de façon générale par :

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (2.1)$$

$X(f)$ est continue, bornée et nulle à l'infinie. On peut reconstruire le signal $x(t)$ à partir de sa représentation fréquentiel $X(f)$ à l'aide de la transformée de Fourier inverse définie par la formule :

$$x(t) = \int_{-\infty}^{+\infty} X(f)e^{j2\pi ft} df \quad (2.2)$$

Cependant, la transformée de Fourier a ses limites. L'une des principales limites de la transformée de Fourier est qu'elle ne prend pas en compte les variations de fréquence dans le temps. Cela signifie que si un signal change de fréquence au fil du temps, la transformée de Fourier ne peut pas fournir une représentation précise de ce signal.

Par exemple, si un signal d'EA contient des composantes de fréquence qui varient au fil du temps, la transformée de Fourier ne peut pas fournir une représentation précise de ces composantes. Cela peut rendre difficile l'identification des caractéristiques spécifiques du signal qui sont importantes pour la détection de défauts dans les matériaux.

Une autre limitation de la transformée de Fourier est qu'elle ne permet pas de localiser les événements dans le temps. Elle fournit uniquement une représentation de la fréquence du signal. Cela peut rendre difficile la détermination précise du temps d'arrivée des signaux d'EA sur les capteurs.

En conséquence, pour l'analyse des signaux d'EA, il est souvent nécessaire d'utiliser des techniques d'analyse temps-fréquence plus avancées qui permettent une analyse à résolution variable. Ces techniques incluent la transformée en ondelette continue, qui permet une meilleure séparation des composantes fréquentielles et temporelles du signal, et qui peut fournir une représentation plus précise des caractéristiques du signal à différentes échelles de temps et de fréquence.

2.3.2 Principe d'incertitude d'heisenberg

Le principe d'incertitude d'Heisenberg en temps et fréquence établit que plus la mesure de la largeur temporelle d'un événement est précise, moins on peut connaître précisément

la fréquence de cet événement, et inversement. Plus précisément, si on mesure la largeur temporelle d'un événement avec une incertitude Δt , alors la largeur spectrale minimale Δf de cet événement est donnée par :

$$\Delta t \cdot \Delta f \geq 1/4\pi \quad (2.3)$$

où Δt est l'incertitude sur la mesure de la largeur temporelle de l'événement et Δf est l'incertitude sur la mesure de la fréquence de l'événement. Cette relation indique que plus l'incertitude Δt est petite, plus l'incertitude Δf doit être grande, et vice versa.

2.3.3 Transformée de Fourier à court terme (STFT)

La Transformée de Fourier à Court Terme (STFT pour Short Time Fourier Transform) est une technique de traitement de signal utilisée pour analyser les propriétés spectrales des signaux qui varient dans le temps. Elle permet d'obtenir une représentation de la fréquence du signal qui varie dans le temps (Figure 2.4). La formule de la STFT est la suivante :

$$X(\tau, f) = \int_{-\infty}^{+\infty} [x(t) \cdot h^*(t - \tau)] e^{-j2\pi ft} dt \quad (2.4)$$

où $x(t)$ est le signal analysé, $h(t)$ est une fenêtre de largeur T et centrée en τ qui permet d'extraire une portion du signal. Cette fenêtre est décalée le long du signal au fur et à mesure de l'analyse. $h^*(t)$ est le complexe conjugué de $h(t)$ et la fonction $h(t - \tau)e^{-j2\pi ft}$ est appelée atome de Fourier à fenêtre.

La STFT consiste à prendre des fenêtres de signal (par exemple, des segments de quelques millisecondes) et à appliquer la Transformée de Fourier à chaque fenêtre. La fenêtre est déplacée progressivement le long du signal enregistré, créant ainsi une représentation de la variation temporelle de la fréquence (Figure 2.2).

La STFT est particulièrement utile pour analyser des signaux non-stationnaires, c'est-à-dire des signaux dont les propriétés spectrales varient dans le temps. En utilisant des fenêtres de taille appropriée, Les composantes fréquentielles d'un signal non-stationnaire sont donc extraites par une décomposition pas à pas de signaux supposés stationnaires.

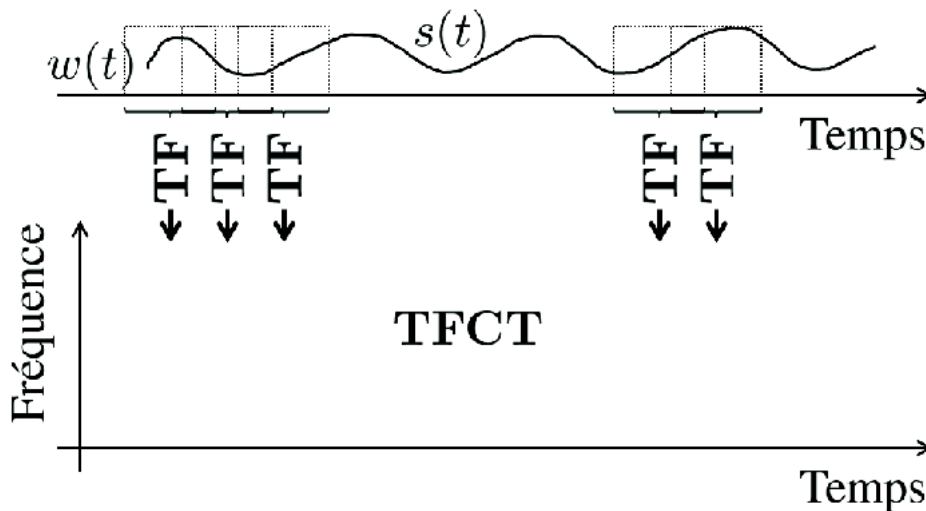


FIG. 2.2 : Principe de la transformée de Fourier à court terme, découpage de signal en fenêtres d'analyse de même taille

Cependant, elle présente certains inconvénients, notamment une résolution fréquentielle variable en fonction de la taille de la fenêtre choisie. Des fenêtres plus petites permettent une meilleure résolution temporelle, mais une résolution fréquentielle moins précise, tandis que des fenêtres plus grandes ont une meilleure résolution fréquentielle mais une résolution temporelle moins précise (Figure 2.3).




FIG. 2.3 : Région étudiée dans le plan temps-fréquence par (a) la transformée de Fourier et (b) l'analyse temps-fréquence.

Les signaux à émission acoustique sont des signaux sonores émis par des structures, qui peuvent fournir des informations sur leur état de fonctionnement. La STFT est souvent utilisée pour analyser ces signaux, car elle permet de décomposer le signal en ses composantes spectrales qui peuvent être utilisées pour identifier les caractéristiques de l'émission acoustique. Cependant, elle présente certains inconvénients dans l'application à des signaux à émission acoustique. Tout d'abord, la résolution temporelle de la STFT peut être insuffisante pour détecter des événements acoustiques rapides tels que des impulsions brèves ou des impacts. Pour obtenir une résolution temporelle suffisante, des fenêtres de taille très petite doivent être utilisées, ce qui diminue la résolution fréquentielle.

tielle et augmente le bruit de fond.

En résumé, la STFT peut être utile pour analyser les signaux à émission acoustique, mais elle présente certains inconvénients en termes de résolution temporelle et fréquentielle. Pour remédier à ces limitations, d'autres techniques ont été développées, comme les transformées en ondelettes, qui offrent une meilleure résolution en temps et en fréquence pour l'analyse de signaux non-stationnaires.




FIG. 2.4 : représentation du signal EA en utilisant la STFT

2.3.4 Transformée en ondelette

La méthode de transformée en ondelettes est devenue un outil très populaire pour l'analyse des signaux non-stationnaires. Bien que la première ondelette, appelée ondelette de Haar, ait été inventée en 1910 [31] [32], c'est grâce aux travaux de Meyer, Morlet et Grossman que le développement de l'analyse des ondelettes a pris son essor. Cependant, c'est avec les innovations de Daubechies et Mallat que l'intérêt et l'activité dans la théorie et les applications des ondelettes ont explosé [33].

Les ondelettes étendent les concepts de l'analyse de Fourier à d'autres bases orthogonales, et surmontent partiellement le principe d'incertitude en exploitant une décomposition multi-résolution (Figure 2.5). Cette approche multi-résolution permet différentes fidélités temporelles et fréquentielles dans différentes bandes de fréquences, ce qui est particulièrement utile pour décomposer des signaux complexes résultant de processus multi-échelles tels que ceux trouvés en EA.




FIG. 2.5 : Analyse multi-résolution

La transformée en ondelettes est une méthode mathématique de traitement de signal qui permet de décomposer un signal en une série d'ondes de différentes fréquences et amplitudes. Elle est utilisée pour l'analyse et la compression de données dans de nombreux domaines, tels que l'imagerie numérique, le traitement du signal audio et la compression de fichiers. La transformée en ondelette utilise une famille d'ondes de différentes tailles et formes, appelées "ondelettes", pour analyser un signal. Ces ondelettes sont générées à partir d'une ondelette de base, appelée "ondelette mère", qui est décalée et dilatée pour former une famille d'ondelettes. Elle consiste à calculer la corrélation entre le signal d'entrée et chaque ondelette de la famille, à différentes échelles et positions. Cela permet de décomposer le signal en une série de coefficients d'ondelettes, qui représentent la contribution de chaque ondelette à la décomposition du signal.

Elle est une alternative à la transformée de Fourier, qui ne prend en compte que les fréquences du signal, mais pas leur localisation dans le temps ou dans l'espace. Elle permet une analyse plus fine et plus précise du signal, en prenant en compte à la fois les fréquences et les localisations spatiales ou temporelles des composantes du signal.

Transformée en Ondelette Continue (CWT)

La transformée en ondelettes continue (CWT) est une méthode d'analyse de signal qui permet d'obtenir une représentation temps-fréquence ou temps-échelle d'un signal. Elle est particulièrement utile pour l'analyse de signaux non-stationnaires, tels que les signaux acoustiques émis par des structures plates.

L'idée de base de l'analyse en ondelettes est de partir d'une fonction $\psi(t)$, appelée l'ondelette mère, et générer une famille de versions mises à l'échelle et translatées de la fonction :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right). \quad (2.5)$$

Les paramètres a et b sont responsables de la mise à l'échelle et de la translation de la fonction $\psi(t)$, respectivement.

La CWT utilise la famille d'ondelettes mères $\psi(t)$, qui sont des fonctions oscillatoires localisées dans le temps et en fréquence. Chaque ondelette est caractérisée par une fréquence centrale f_c et une échelle a . L'ondelette mère est ensuite dilatée ($a > 1$) et contractée ($a < 1$) à différentes échelles, ce qui permet d'analyser le signal à différentes résolutions temporelles et fréquentielles. Lorsque le facteur d'échelle est augmenté, la fréquence est réduite et l'ondelette couvre une plus grande partie du signal, permettant ainsi d'extraire les caractéristiques à long terme du signal. De manière inverse, en réduisant la valeur du facteur d'échelle, la partie du signal analysée est réduite, ce qui permet d'étudier les variations locales à haute fréquence. L'ondelette peut être considérée comme un filtre passe-bande dont la fréquence centrale est déterminée par f_c . Plus la fréquence du signal analysé se rapproche de celle de l'ondelette analysante, plus la fréquence du signal analysé coïncide

avec celle de l'ondelette. La transformée en ondelettes décompose le signal en fréquences allant des plus basses aux plus élevées, donc en modifiant le paramètre a , il est possible de déterminer les composantes du signal correspondant à la fréquence f_a :

$$f_a = \frac{f_c}{T_e \cdot a} \quad (2.6)$$

où T_e est la période d'échantillonnage

La transformée en ondelettes continues (TOC ou CWT pour Continuous Wavelet Transform en anglais) permet de transformer une fonction à une variable en une fonction à deux variables. Elle est définie analytiquement par [34] :

$$C_\psi(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.7)$$

Où :

- ψ^* est le complexe conjugué de l'ondelette mère.
- $C_\psi(a, b)$ sont les coefficients d'ondelettes (nombre à valeur généralement complexe).

Le processus de CWT peut être divisé en deux étapes principales : la convolution et l'échantillonnage. La convolution implique la multiplication du signal avec une ondelette à différentes échelles et positions temporelles, produisant ainsi une série de coefficients de convolution. L'échantillonnage consiste à sélectionner un sous-ensemble de ces coefficients de convolution qui représentent les composantes importantes du signal.

Une fois la CWT effectuée, le signal peut être visualisé dans le plan temps-fréquence ou temps-échelle. Cette représentation permet de localiser les fréquences ou les échelles qui sont les plus actives à un moment donné dans le signal. Cette localisation est particulièrement utile pour la détection de sources acoustiques émettant des signaux à des fréquences spécifiques.

Dans le contexte de la localisation des sources acoustiques dans des structures plates, la CWT peut être utilisée pour détecter les fréquences ou les échelles qui sont les plus actives à un moment donné, ce qui peut aider à localiser la source. Cependant, il est important de prendre en compte les propriétés de propagation des ondes de Lamb dans la structure pour interpréter correctement les résultats de l'analyse.

Incertitude d'Heisenberg dans la CWT

Le principe d'incertitude d'Heisenberg est une contrainte fondamentale qui doit être respectée lors de l'analyse de signaux non-stationnaires par la CWT. Ainsi, la CWT est conçue pour offrir une bonne résolution fréquentielle pour l'analyse des composantes à basses fréquences et une bonne résolution temporelle pour l'analyse des composantes à

hautes fréquences [35] [36]. Les coefficients de la CWT sont donc une mesure de la similitude entre l'ondelette et la fonction $x(t)$, en fonction de l'échelle et de la position.

La résolution temps-fréquence de la transformée en ondelette peut être exprimée en fonction du paramètre d'échelle à travers les relations suivantes [37] :

$$\sigma_t = a\sigma_{t_\psi}, \quad \sigma_w = \frac{\sigma_{w\psi}}{a} \quad (2.8)$$

où σ_{t_ψ} et $\sigma_{w\psi}$ sont la durée et la largeur de bande de l'ondelette mère, respectivement.

Ces deux paramètres sont donc en compétition, ce qui est connu sous le nom de principe d'incertitude de Heisenberg.

Condition d'admissibilité

Les conditions d'admissibilité, également connues sous le nom de conditions d'admissibilité de l'ondelette mère, sont des exigences mathématiques qui doivent être satisfaites pour que la transformée en ondelettes soit bien définie. En d'autres termes, les conditions d'admissibilité garantissent que la transformée en ondelettes peut être inversée pour reconstruire le signal d'origine de manière fiable.

Les conditions d'admissibilité sont exprimées sous la forme d'une équation d'intégrale et sont données par :

$$C_\psi(a, b) = \int_{-\infty}^{+\infty} \frac{|\widehat{\psi}(f)|^2}{|f|} df < \infty \quad (2.9)$$

où $\widehat{\psi}()$ est la transformée de Fourier de l'ondelette mère $\psi(t)$. Cette condition garantit que l'ondelette mère est bien localisée dans le domaine de la fréquence et que sa puissance totale est finie. alors la transformée inverse peut être calculée avec la formule de reconstruction suivante :

$$x(t) = \frac{1}{C_\psi(a, b)} \iint X(a, b) \frac{\psi_{a,b}(t)}{a^2} da db \quad (2.10)$$

En outre, l'ondelette mère doit également avoir une moyenne nulle :

$$\int_{-\infty}^{+\infty} \psi_{a,b}(t) dt = 0 \quad (2.11)$$

et être normée :

$$\int_{-\infty}^{+\infty} |\psi_{a,b}(t)|^2 dt = 1 \quad (2.12)$$

Les ondelettes complexes doivent remplir une condition supplémentaire pour être admissibles : elles doivent être des fonctions analytiques, c'est-à-dire que leur transformée de Fourier doit être réelle et nulle pour les fréquences négatives.

Algorithme pour calculer les Coefficients d'ondelette

Pour calculer les coefficients de la transformée en ondelettes continue (CWT), on utilise l'algorithme suivant :

- 1 Commencez par choisir une fonction d'ondelette mère et un ensemble d'échelles pour la transformée.
- 2 Pour chaque échelle, dilatez la fonction d'ondelette mère en multipliant sa fréquence par l'échelle. Cela vous donne une famille de fonctions d'ondelettes dilatées.
- 3 Pour chaque fonction d'ondelette dilatée, calculez le produit scalaire entre cette fonction et le signal que vous voulez analyser. Cela vous donne une fonction d'ondelette continue qui capture les caractéristiques du signal à cette échelle (le degré de corrélation de l'Ondelette avec cette portion du signal).
- 4 Répétez les étapes 2 et 3 pour toutes les échelles que vous avez choisies. Cela vous donne une famille de fonctions d'ondelettes continues pour différentes échelles.
- 5 Utilisez ces fonctions d'ondelettes continues pour construire une représentation en deux dimensions du signal, appelée scalogramme. Les coefficients du scalogramme représentent l'amplitude et la phase des ondes dans le signal à différentes échelles et positions.
- 6 Analysez le scalogramme en ondelettes pour extraire les caractéristiques du signal.




FIG. 2.6 : Etapes de calcul des Coefficients d'ondelette.

Choix de l'Ondelette mère

Le choix de la fonction d'ondelette mère est important car elle détermine les propriétés de la transformation en ondelettes et la capacité de la transformée à capturer les caractéristiques du signal.


Parmi les ondelettes les plus utilisées pour la transformée en ondelette continue on trouve : l'ondelette gaussienne, le chapeau mexicain et l'ondelette de Morlet, l'ondelette gaussienne complexe, l'ondelette de Shannon complexe, l'ondelette B-spline fréquentielle complexe ainsi que l'ondelette de Morlet complexe.

Voici une brève description de quelques-unes de ces ondelettes :

Ondelette gaussienne : définie comme suit :

$$\psi(t) = \frac{1}{\sqrt{a}} \exp\left(-\frac{t^2}{2a^2}\right) \quad (2.13)$$


où t est la variable de temps, a est l'échelle de l'ondelette.



Ondelette de morlet : L'ondelette de Morlet est utilisée pour l'analyse de signaux qui varient à des vitesses différentes dans le temps. Elle a une réponse impulsionnelle en forme de cloche et est définie à la fois dans le domaine de l'espace et de la fréquence. Elle définie est comme suit :

$$\psi(t) = \frac{1}{\sqrt{2\pi}} e^{-t^2/2} e^{-i\omega t} \quad (2.14)$$


où le nombre d'oscillations reste constant et la taille de la fenêtre varie



Chapeau mexicain : cette ondelette correspond à la dérivée seconde d'une fonction, elle est définie comme suit ;

$$\psi(t) = \frac{2}{\sqrt{3}} \pi^{-1/4} (1 - t^2) e^{-t^2/2} \quad (2.15)$$

Cette ondelette est régulière, symétrique et de support infini.



Ondelette de Morlet Complexe

Nous avons choisi pour notre étude l'ondelette de Morlet complexe.

L'ondelette de Morlet complexe est une ondelette qui combine une fonction d'onde

sinusoïdale avec une gaussienne. Cette combinaison permet d'avoir une ondelette qui est à la fois localisée dans le temps et en fréquence. En d'autres termes, elle permet de détecter des oscillations de différentes fréquences à différents moments dans le temps. De plus, cette ondelette a souvent été choisie pour l'étude des signaux ultrasonores ; elle s'adapte à la forme des signaux acquis et elle présente l'avantage d'être plus simple à calculer [38] [39] [40].

Elle est caractérisée par deux paramètres : la fréquence centrale f_c et la largeur de la gaussienne f_b . La fréquence centrale est la fréquence de l'onde sinusoïdale et détermine la fréquence de l'ondelette. La largeur de la gaussienne détermine la résolution temporelle de l'ondelette, c'est-à-dire la précision avec laquelle elle peut détecter des oscillations dans le temps.

Elle est utilisée dans la CWT pour décomposer un signal en une série d'ondelettes de différentes fréquences et résolutions temporelles. Cette décomposition permet d'analyser le signal à différentes échelles et d'extraire des informations sur les oscillations présentes dans le signal.

L'ondelette de Morlet complexe est définie mathématiquement comme suit :

$$\psi(t) = \frac{1}{\sqrt{\pi f_b}} e^{-t^2/f_b} \cdot e^{2i\pi f_c t} \quad (2.16)$$

où t est le temps, f_c est la fréquence centrale de l'ondelette et i est l'unité imaginaire. Cette ondelette est définie comme une gaussienne e^{-t^2/f_b} modulée par une onde sinusoïdale de fréquence f_c .

La figure 2.7 illustre la représentation de l'ondelette de morlet complexe

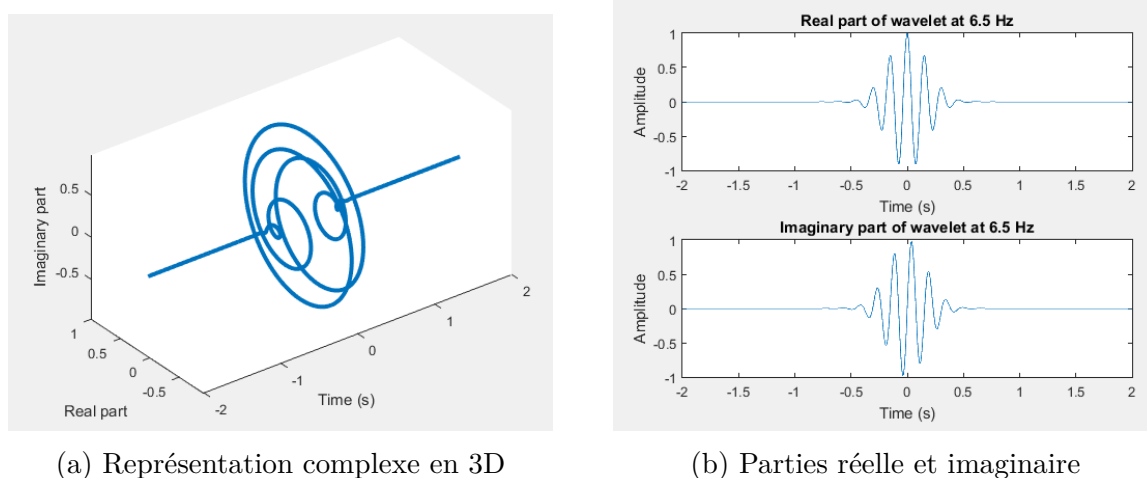


FIG. 2.7 : Ondelette de Morlet complexe

La fréquence centrale f_c détermine la fréquence de l'ondelette et peut être ajustée pour adapter l'ondelette aux propriétés du signal à analyser. Une fréquence centrale plus élevée

est utilisée pour détecter des oscillations de plus haute fréquence, tandis qu'une fréquence centrale plus basse est utilisée pour détecter des oscillations de plus basse fréquence.

La largeur de la gaussienne dans l'ondelette de Morlet complexe est un paramètre important qui détermine la résolution temporelle de l'ondelette. Une gaussienne plus étroite permet une meilleure résolution temporelle, c'est-à-dire une capacité à détecter des oscillations plus courtes dans le temps, mais cela se fait au détriment d'une résolution fréquentielle plus faible. À l'inverse, une gaussienne plus large permet une meilleure résolution fréquentielle mais au détriment de la résolution temporelle.

La transformée en ondelette de Morlet complexe est souvent utilisée pour déterminer le temps d'arrivée des signaux d'émission acoustique en raison de ses propriétés favorables. Sa forme ressemble à une onde sinusoïdale, ce qui permet de capturer efficacement les caractéristiques temporelles des signaux acoustiques. Elle est capable de fournir à la fois des informations en fréquence et en temps, ce qui en fait un outil puissant pour l'analyse des signaux transitoires. Elle peut être ajustée pour avoir une résolution temporelle élevée, permettant ainsi de détecter précisément les instants d'arrivée des événements acoustiques. De plus, la transformée en ondelette de Morlet complexe est capable de localiser les changements brusques dans le signal, ce qui est important pour identifier les moments où les signaux acoustiques émis par différentes sources arrivent à un récepteur. Cela permet de distinguer et de séparer les différents composants des signaux, facilitant ainsi l'analyse et l'interprétation des données acoustiques.

L'utilisation de l'ondelette de Morlet complexe pour déterminer le temps d'arrivée des signaux d'émission acoustique est justifiée par sa ressemblance aux signaux EA et sa capacité à fournir une résolution temporelle élevée, à localiser les changements brusques dans le signal et à capturer les caractéristiques temporelles des signaux de manière précise et efficace.

2.3.5 Comparaison entre la CWT et STFT

La transformée en ondelettes continue (CWT) et la transformée de Fourier à court terme (STFT) sont toutes deux des outils utilisés pour analyser les signaux en domaine fréquentiel et temporel. Bien qu'elles partagent des similitudes dans leur approche, elles diffèrent dans leur capacité à représenter les variations de fréquence au fil du temps. Voici une comparaison détaillée des deux techniques, mettant en évidence pourquoi la CWT est souvent préférée pour le calcul des temps d'arrivée des signaux à émission acoustique :

- En terme de résolution : la STFT utilise des fenêtres temporelles fixes pour calculer les fréquences locales via une transformée de Fourier. Cela limite la résolution fréquentielle à travers le signal, ce qui rend difficile la détection précise des changements de fréquence dans le temps, tandis que la CWT utilise des filtres d'ondelettes à différentes échelles, permettant une résolution fréquentielle variable selon le contenu du signal. Cela permet de capturer des variations de fréquence à différentes échelles temporelles, offrant ainsi une

meilleure représentation des temps d'arrivée des signaux acoustiques ainsi qu'un calcul précis de la fréquence dominante.




FIG. 2.8 : CWT

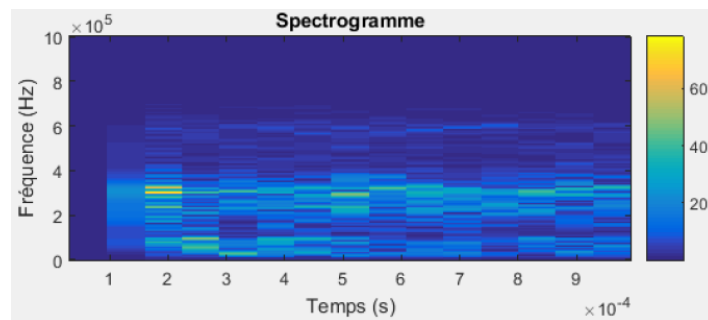


FIG. 2.9 : Représentation STFT d'un signal EA de capteur N°1

Dans la figure ci-dessus on voit clairement la différence entre les deux représentations dans le calcul de temps d'arrivée des signaux d'émissions acoustiques telle qu'on remarque que la CWT est plus adaptée à la détection des événements transitoires, car les filtres d'ondelettes peuvent être adaptés à l'échelle appropriée pour capturer ces événements de manière précise, même s'ils sont de courte durée. alors qu'en raison de sa fenêtre fixe, la STFT a du mal à détecter avec précision les événements transitoires dans le signal, car ils peuvent être étalés sur plusieurs fenêtres et donc dilués.

La CWT est généralement préférée à la STFT pour le calcul des temps d'arrivée des signaux à émission acoustique en raison de sa meilleure capacité à représenter les variations de fréquence au fil du temps, sa résolution temporelle variable, sa meilleure représentation des structures temporelles complexes et sa capacité à détecter précisément les événements transitoires. Cela permet d'obtenir des estimations plus précises et détaillées des temps d'arrivée des signaux acoustiques dans des scénarios réels.

2.3.6 Utilisation de la CWT pour la détermination du temps d'arrivée TOA des ondes

En raison de la complexité des signaux d'EA. La CWT est plus adaptée pour visualiser le contenu temps-fréquence des signaux d'EA qui sont des signaux non-stationnaire que la STFT qui est adaptée aux signaux stationnaires « par morceaux » [41], [42].

Nous avons utilisé deux méthodes pour la détermination de TOA des signaux d'EA issus de source d'impacts en utilisant la CWT :

1) Par maximum d'énergie :

Appliquez la transformée en ondelette à notre signal d'émission acoustique pour extraire les coefficients et visualiser le scalogramme qui est module au carré des coefficients de CWT

et qui indique l'amplitude de chaque fréquence en fonction du temps.

$$Sc(a, b) = |C_\psi(a, b)|^2 = C_\psi(a, b) \cdot C_\psi(a, b)^* \quad (2.17)$$

On identifie le pic d'énergie qui correspond au plus fort coefficient d'ondelette ensuite on met une projection sur l'axe des temps et des échelles pour extraire le temps d'arrivée et la fréquence instantanée (la fréquence dominante) correspondant.

$$t_i = \text{Arg} (\max |C(a, b)|^2) \quad (2.18)$$

Puisque dans ce travail, la fréquence dominante peut être différente pour chaque capteur, la fréquence moyenne est utilisée pour calculer la vitesse de propagation de paquets d'onde.

$$\bar{f} = \frac{\sum_1^n f_i}{n} \quad (2.19)$$

Une fois le TOA connu, on peut calculer les différences de temps par rapport au capteur maître par :

$$\Delta t_{mi} = t_i - t_m \quad (2.20)$$

Où la variance de la différence de temps d'arrivée est donnée par :

$$\sigma_{\Delta t_{mi}}^2 = 2 \left(\frac{f_c \sqrt{f_b}}{2\bar{f}} \right)^2 \quad (2.21)$$

2) Par entropie des ondelette (wavelet entropy)

Dans cette méthode, on utilise un critère quantitatif, basé sur le calcul d'entropie de Shannon, pour sélectionner les valeurs d'échelle les plus pertinentes.

Entropie de shannon : L'entropie de Shannon, également connue sous le nom d'entropie d'information, est une mesure de l'incertitude ou de la quantité d'informations contenues dans une source de données ou un ensemble de données. Elle est utilisée en théorie de l'information et en statistiques pour quantifier l'efficacité de la compression des données, la redondance dans les données et la capacité de prédire les données.

L'entropie de Shannon est calculée en utilisant la formule suivante :

$$H(X) = - \sum_{i=1}^n P(x_i) \log P(x_i) \quad (2.22)$$

où H est l'entropie, $p(x_i)$ est la probabilité de l'événement i , et \log_2 est le logarithme en base 2. La somme s'étend sur tous les événements possibles.

L'entropie de Shannon est maximale lorsque tous les événements ont la même probabilité, c'est-à-dire lorsque l'ensemble de données est le plus imprévisible ou aléatoire. Elle est minimale lorsque l'ensemble de données est composé d'un seul événement, c'est-à-dire

lorsque l'ensemble de données est totalement prévisible.

Elle peut être interprétée comme la quantité minimale de bits d'information nécessaires pour transmettre efficacement un message provenant d'une source de données. Plus la distribution de probabilité est uniforme, plus l'entropie est élevée et plus il est difficile de compresser l'information. En revanche, si la distribution de probabilité est biaisée, l'entropie est plus faible, ce qui signifie qu'il y a moins d'incertitude et donc moins d'information à transmettre.

Entropie des ondelettes L'entropie des ondelettes (wavelet entropy en anglais) est une mesure d'information qui utilise l'analyse des ondelettes pour caractériser la structure à différentes échelles dans un signal. Elle correspond à une mesure d'information qui utilise l'analyse des ondelettes pour caractériser la structure à différentes échelles dans un signal. Cette mesure est couramment utilisée en analyse du signal.

Leur concept est basé sur l'utilisation de transformées en ondelettes pour décomposer un signal en différentes échelles. Cette décomposition en échelles permet d'analyser le signal à différents niveaux de détail, ce qui peut mettre en évidence des structures et des régularités cachées dans le signal. L'entropie des ondelettes mesure la complexité du signal en évaluant l'entropie de Shannon de la distribution des coefficients d'ondelettes à différentes échelles. Plus précisément, elle quantifie la régularité de la distribution des coefficients à différentes échelles en utilisant une fonction de probabilité qui prend en compte les différences entre les coefficients d'ondelettes voisins.

Ce critère consiste à calculer l'entropie de Shannon normalisée des coefficients de CWT telle que définie par :

$$S(a) = \sum_{i=1}^n \left(\frac{w_{a,i}^2}{A} \cdot \ln \left(\frac{w_{a,i}^2}{A} \right) \right) \quad (2.23)$$

telle que : $A = \sum_{a=1}^m \sum_{i=1}^n w_{a,i}^2$
 et $p_i = w_{a,i}^2 / A$

où $w_{a,i}$ sont les coefficients d'ondelettes à différentes échelles a , et p_i est la fonction de probabilité. L'entropie de Shannon mesure le caractère aléatoire du CWT dans le domaine de l'échelle et de temps, où une faible valeur d'entropie indique une concentration d'énergie élevée[43].

Transformée de Hilbert : La transformée de Hilbert FH d'un signal réel $x(t)$ peut être représentée par l'équation ci-dessous[44] :

$$F_{\text{Hi}}(t) = \frac{-1}{\pi t} * x(t) \quad (2.24)$$

La transformée de Hilbert peut être utilisée pour créer un signal analytique à partir d'un signal réel. Considérons $x(t)$ un signal réel. Le signal analytique $x_a(t)$ est calculé

comme suit :

$$x_a(t) = x(t) + iH\{x(t)\} \quad (2.25)$$

où $H\{x(t)\}$ est la transformée de Hilbert du signal réel.

En écrivant le signal analytique sous forme polaire, on a :

$$x_a(t) = re^{-j\theta} \quad (2.26)$$

où r est la valeur absolue et θ est la phase du signal analytique. La valeur absolue du signal analytique correspond à l'enveloppe du signal qui est calculé par la formule suivant [41], [44] :

$$R(t) = \sqrt{x(t)^2 + F_{\text{Hi}}(t)^2} \quad (2.27)$$

Algorithme à suivre :

- 1) On calcule l'entropie de Shannon normalisée des coefficients CWT
- 2) On extrait le signal des coefficients d'ondelette à l'échelle qui correspond au minimum entropie (maximum d'énergie)
- 3) On calcule la transformée d'hilbert du signal
- 4) On extrait le signal analytique de signal réel par la formule (2.25)
- 5) extraction de l'enveloppe pour obtenir le peak qui correspond au TOA en utilisant le module de signal analytique.

2.4 Conclusion

En conclusion, l'utilisation de la transformée en ondelette "l'ondelette de Morlet complexe" au lieu de STFT pour la détermination des temps d'arrivée dans le cadre de la localisation des défauts sur des structures sous forme plate présente des avantages significatifs. Cette approche permet une analyse précise et efficace des signaux, en identifiant les caractéristiques temporelles et fréquentielles des ondes de lamb générées par les défauts. Grâce à cette méthode, il est possible de localiser les défauts avec une meilleure résolution. L'utilisation de la transformée en ondelette offre également une flexibilité en permettant de choisir des fonctions d'ondelette adaptées au problème spécifique, ce qui peut améliorer encore les performances de localisation. En résumé, l'approche basée sur la transformée en ondelette constitue une contribution prometteuse pour la localisation des défauts sur des structures plates en utilisant les différences de temps d'arrivée et la vitesse de groupe calculées comme des entrées de notre réseau ANN. Le chapitre suivant présentera donc les réseaux de neurones Artificiels et convolutifs ainsi que les architectures étudiées.

Chapitre 3

ANN et CNN

3.1 Introduction

Les réseaux de neurones artificiels (ANN) sont un type d'algorithme d'apprentissage automatique inspiré de la structure et de la fonction du cerveau humain. Ils sont composés de nœuds ou de neurones interconnectés qui reçoivent des entrées, les traitent et produisent des sorties. Les poids des connexions entre les neurones sont ajustés pendant l'entraînement pour permettre au réseau d'apprendre à classer ou à prédire avec précision de nouvelles entrées. Il existe de nombreux types de ANN, chacun ayant ses propres forces et faiblesses, et ils sont utilisés dans une large gamme d'applications, de la reconnaissance d'images et de la parole au traitement du langage naturel et à la modélisation prédictive. Ils ont permis aux ordinateurs d'accomplir des tâches qui étaient auparavant réservées aux humains. Avec l'augmentation de la quantité de données disponibles aujourd'hui, les ANN deviennent de plus en plus puissants et efficaces, et leurs applications ne sont limitées que par notre imagination. En tant que tel, ils sont un outil crucial dans le domaine de l'intelligence artificielle, et leur potentiel de transformer diverses industries est énorme.

Ce chapitre présente un aperçu théorique de l'évolution des réseaux de neurones artificiels et les réseaux de neurones convolutifs utilisé dans ce travail pour la localisation des dommages dans des structures sous forme de plaque.

3.2 Intelligence artificielle

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à créer des systèmes capables de réaliser des tâches qui nécessitent normalement une intelligence humaine. Les systèmes d'IA peuvent apprendre, raisonner, percevoir et agir de manière autonome, en utilisant des algorithmes d'apprentissage automatique et d'autres techniques.

L'IA peut être utilisée pour résoudre une grande variété de problèmes. Elle est de plus en plus utilisée dans de nombreux secteurs, notamment la santé, les transports, la finance, l'énergie, l'agriculture, et les sciences. Au cours des dernières années, les progrès de l'intelligence artificielle (IA) et de l'apprentissage automatique ont été spectaculaires. De nouvelles méthodes d'apprentissage, telles que les réseaux de neurones profonds, ont permis d'améliorer considérablement les performances de nombreux systèmes d'IA. Les réseaux de neurones profonds sont capables d'apprendre des représentations de plus en plus abstraites des données, ce qui permet de résoudre des tâches de plus en plus complexes.

3.3 Histoire des réseaux de neurones

L'idée des réseaux neuronaux a débuté comme un modèle de fonctionnement des neurones dans le cerveau, appelé "connexionnisme" (Figure 3.1) et utilisant des circuits connectés pour simuler un comportement intelligent. En 1943, le neurophysiologiste Warren McCulloch et le mathématicien Walter Pitts ont fait le portrait d'un simple circuit électrique [45]. Donald Hebb a poussé l'idée plus loin dans son livre *The organization of*

behavior (1949)[46], en proposant que les voies neuronales se renforcent au fil des utilisations successives, en particulier entre les neurones qui ont tendance à s'allumer en même temps, entamant ainsi le long voyage vers la quantification des processus complexes du cerveau.

Dans les années 1950, alors que les chercheurs commençaient à essayer de transposer ces réseaux sur des systèmes informatiques, le premier réseau de Hebbian a été mis en œuvre avec succès au MIT en 1954.




FIG. 3.1 : Neurone biologique

À la même époque, Frank Rosenblatt, psychologue à Cornell, s'efforçait de comprendre les systèmes de décision relativement simples présents dans l'œil d'une Mouche Pour tenter de comprendre et de quantifier ce processus, il a proposé l'idée d'un perceptron en 1958, qu'il a appelé Mark I Perceptron [47]. Il s'agit d'un système doté d'une relation entrée-sortie simple modelée sur le neurone de McCulloch-Pitts (figure 3.2), proposé en 1943 pour expliquer les processus de décision complexes dans un cerveau à l'aide d'une porte à seuil linéaire. Un neurone reçoit des entrées, fait une somme pondérée et renvoie "0" si le résultat est inférieur au seuil et "1" dans le cas contraire.




FIG. 3.2 : Un neurone McCulloch-Pitts

L'intérêt du perceptron Mark I perceptron dans le fait que ses poids sont "appris" par des entrées successives, tout en minimisant la différence entre la sortie souhaitée et la

sortie réelle.

C'est à cette époque que les choses ont commencé à évoluer rapidement pour les réseaux neuronaux. En 1959, à Stanford, Bernard Widrow et Marcian Hoff ont mis au point le premier réseau neuronal appliqué avec succès à un problème réel. Ces systèmes ont été baptisés ADALINE et MADALINE en raison de leur utilisation d'éléments linéaires adaptatifs multiples.

En 1969 avec la publication du livre "Perceptrons" de Marvin Minsky, fondateur du laboratoire d'intelligence artificielle du MIT, et de Seymour Papert, directeur du laboratoire. Ce livre a démontré de manière concluante que l'approche des réseaux neuronaux fondée sur la perception unique de Rosenblatt ne pouvait pas être traduite efficacement en réseaux neuronaux multicouches. L'évaluation des valeurs relatives correctes des poids des neurones répartis sur plusieurs couches en fonction de la sortie finale nécessiterait plusieurs itérations, voire un nombre infini d'itérations, et prendrait beaucoup de temps à calculer.

À cette époque, les ordinateurs ne disposaient pas de la puissance de traitement nécessaire pour gérer efficacement le temps requis par les grands réseaux neuronaux, ce qui a entraîné une stagnation de la recherche dans le domaine des réseaux neuronaux pendant de nombreuses années. Ce n'est qu'au milieu des années 1980, lorsque les ordinateurs ont atteint une puissance de traitement supérieure, que l'on a reconnu qu'un réseau neuronal à deux couches ou plus est beaucoup plus puissant en termes de traitement qu'un perceptron à une seule couche. Ainsi, le perceptron multicouche (en anglais Multi-Layer Perceptron ou MLP) est né. Cependant, l'utilisation du modèle MLP a été mise en attente en raison du manque d'outils conceptuels nécessaires pour analyser et prédire son comportement. Ce n'est qu'à la fin des années 1980, avec l'apparition de l'algorithme d'apprentissage par rétropropagation[48], que les réseaux neuronaux ont réellement pris leur essor, suite à plusieurs travaux menés durant la décennie, principalement ceux de Hopfield[49]. D'autres modèles de réseaux de neurones ont été développés pour résoudre différents problèmes de prédiction, de classification, de détection, et autres.

3.4 Perceptron

Le perceptron est un type de réseau de neurones artificiels qui a été proposé pour la première fois en 1957 par le psychologue et informaticien américain Frank Rosenblatt. Il s'agit d'un modèle de classification binaire qui prend en entrée un vecteur de données et fournit en sortie une décision de classe.

Le perceptron se compose d'une couche de neurones qui effectuent des opérations linéaires sur les entrées pondérées par des poids, suivies d'une fonction d'activation non linéaire. Les poids sont ajustés de manière itérative en fonction de l'erreur de prédiction sur un ensemble de données d'entraînement jusqu'à ce que le modèle atteigne une perfor-

mance satisfaisante.

Le perceptron figure 3.3 est l'algorithme le plus basique de réseau de neurones utilisé pour des tâches de classification binaire simples. Il a également été utilisé comme bloc de construction pour des réseaux de neurones plus complexes.

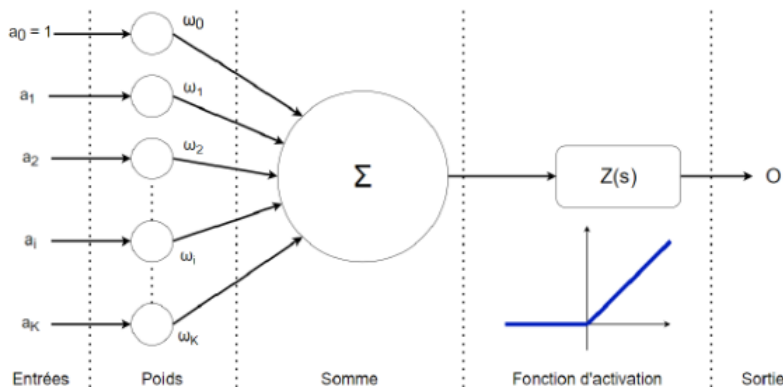


FIG. 3.3 : Architecture d'un Perceptron

La figure étant donné un vecteur d'entrée $A = (a_0, a_1, \dots, a_K) \in \mathbb{R}^K$ et le vecteur de poids synaptique : $W = (w_0; w_1; \dots; w_K) \in \mathbb{R}^K$, le neurone procède par une sommation des éléments de A , pondérés par les éléments du vecteur de poids w .

$$S = w_0 + \sum_{i=1}^K a_i w_i \quad (3.1)$$

La somme obtenue dite potentiel est évaluée par une fonction d'activation qui fournit une sortie Z .

3.5 Perceptron multicouches (MLP)

Le perceptron multicouche (MLP) (Figure 3.4) est une extension du perceptron de base qui comprend plusieurs couches de neurones interconnectées, également appelées couches cachées. Le MLP est capable d'effectuer des tâches de classification et de régression non linéaires en utilisant une fonction d'activation non linéaire pour chaque couche de neurones.

La première couche du MLP est la couche d'entrée, qui prend en entrée les données à traiter. La dernière couche est la couche de sortie, qui fournit la réponse du modèle. Les couches intermédiaires sont les couches cachées, qui effectuent des transformations non linéaires des entrées.

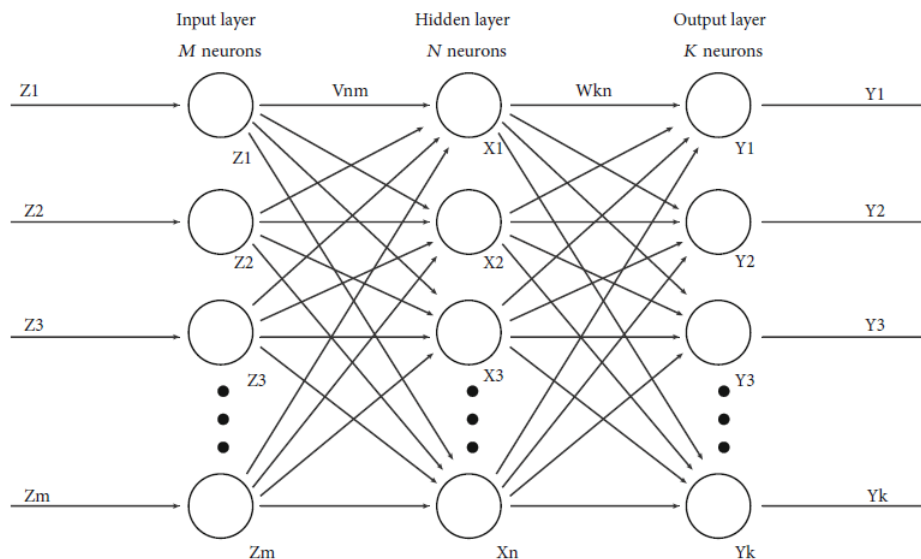


FIG. 3.4 : Réseaux de neurones MLP

3.6 Les Éléments de l'architecture d'un réseau neuronal MLP

Couche d'entrée : La couche d'entrée reçoit les données brutes du domaine. Aucun calcul n'est effectué dans cette couche. Les nœuds de cette couche transmettent simplement les informations (caractéristiques) à la couche cachée.

Couches cachées : La couche cachée effectue toutes sortes de calculs sur les caractéristiques introduites par la couche d'entrée et transfère le résultat à la couche de sortie.

Couche de sortie : C'est la couche finale du réseau qui apporte les informations apprises par la couche cachée et fournit la valeur finale comme résultat.

Toutes les couches cachées utilisent généralement la même fonction d'activation. Cependant, la couche de sortie utilisera généralement une fonction d'activation différente de celle des couches cachées. Le choix dépend de l'objectif ou du type de prédiction effectué par le modèle.

3.7 Entraînement des réseaux de neurones

Le MLP est entraîné par l'algorithme de retropropagation du gradient de l'erreur proposé par Rumelhart et al., [50]. Il permet aux informations de circuler en sens inverse dans le réseau afin de calculer le gradient. Il consiste à ajuster les poids synaptiques de tous les neurones des différentes couches en calculant l'erreur quadratique moyenne E

entre le vecteur de sortie estimé y et le vecteur de sortie réelle y_r par l'équation suivante

$$E = \frac{1}{2} \sum_{i=1}^N (y_r^i - y^i)^2 \quad (3.2)$$

Les poids synaptiques sont ensuite modifiés tel que :

$$\begin{aligned} w(t+1) &= w(t) + \Delta w(t+1) \\ \Delta w(t+1) &= -\alpha \frac{\partial E}{\partial w} + \mu \Delta w(t) \end{aligned} \quad (3.3)$$

t : itération en cours (elle correspond au passage d'une donnée à travers le réseau).

$\Delta w()$: Changement de poids au fil des itérations.

$\frac{\partial E}{\partial w}$: gradient de l'erreur par rapport au poids w .

Il est à noter que l'objectif est de minimiser une fonction coût représentée par l'erreur quadratique moyenne E jusqu'à son minimum local ce qui est appelée descente du gradient.

3.8 Paramètres des réseaux de neurones artificiels

3.8.1 Taux d'apprentissage (Learning rate) :

Le taux d'apprentissage (learning rate en anglais) est un hyperparamètre crucial dans l'entraînement des réseaux de neurones. Il détermine la rapidité avec laquelle les poids et les biais du réseau sont ajustés pendant l'entraînement.

Plus précisément, le taux d'apprentissage est utilisé dans l'algorithme d'optimisation pour contrôler la taille des pas que le processus d'optimisation prend dans l'espace de recherche pour minimiser la fonction de coût. Un taux d'apprentissage élevé signifie que les poids et les biais du réseau sont ajustés rapidement, ce qui peut entraîner des oscillations et des instabilités dans le processus d'entraînement. À l'inverse, un taux d'apprentissage trop faible peut entraîner un processus d'entraînement très lent ou même bloqué dans un minimum local de la fonction de coût (figure 3.5). Le choix du taux d'apprentissage dépend de la complexité du problème, de la taille du réseau de neurones, de la taille du lot de données, et d'autres facteurs. En général, il est recommandé de commencer avec un taux d'apprentissage relativement élevé et de le réduire progressivement au cours de l'entraînement pour atteindre une convergence plus stable.

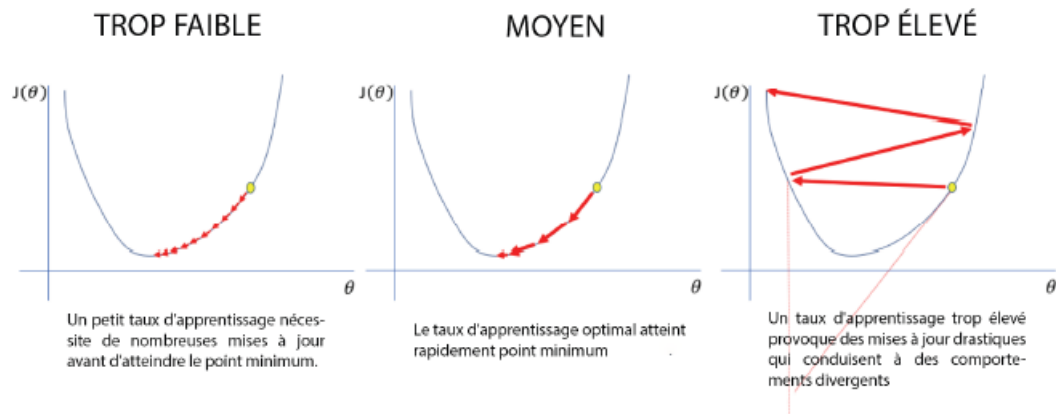


FIG. 3.5 : Illustration du taux d'apprentissage

3.8.2 Nombre de couches cachées

Le nombre de couches cachées d'un réseau de neurones est un hyperparamètre important qui détermine la complexité et la capacité du modèle. Les couches cachées sont des couches de neurones qui ne sont ni l'entrée ni la sortie, et qui effectuent des transformations non linéaires des données d'entrée pour produire les sorties du réseau.

Le choix du nombre de couches cachées dépend de la complexité de la tâche à accomplir et de la quantité de données disponibles pour l'entraînement. En général, les problèmes plus complexes nécessitent des réseaux de neurones avec plus de couches cachées pour modéliser des relations plus complexes entre les variables d'entrée et de sortie. Cependant, il est important de noter que l'ajout de couches cachées peut également rendre le modèle plus complexe et plus difficile à entraîner, car il y a plus de paramètres à ajuster et le risque de surajustement (overfitting) augmente. De plus, l'ajout de couches cachées peut également augmenter le temps nécessaire pour l'entraînement du réseau.

En pratique, le choix du nombre de couches cachées se fait souvent par essais et erreurs, en testant différentes architectures de réseau de neurones et en évaluant leur performance sur un ensemble de validation. Des techniques telles que la régularisation et le dropout peuvent également être utilisées pour aider à prévenir le surajustement lors de l'ajout de couches cachées.

3.8.3 Nombre de neurones cachés

Le choix du nombre de neurones cachés dans chaque couche cachée d'un réseau de neurones dépend de la complexité de la tâche à accomplir, du nombre de couches cachées et de la quantité de données disponibles pour l'entraînement. Un nombre plus élevé de neurones cachés peut aider le réseau à modéliser des relations plus complexes, mais peut également augmenter le risque de surapprentissage. Il est donc important de choisir un nombre de neurones cachés suffisamment grand pour capturer les relations complexes dans les données, tout en évitant le surajustement en utilisant des techniques de régularisation.

3.8.4 Nombre d'itérations

Le nombre d'itérations est un hyperparamètre important dans l'entraînement d'un réseau de neurones. Il représente le nombre de fois que l'algorithme d'apprentissage parcourt l'ensemble de données d'entraînement complet (ou un sous-ensemble aléatoire de celui-ci) pour ajuster les poids du modèle.

Le choix du nombre d'itérations dépend de la complexité de la tâche à accomplir et de la quantité de données disponibles pour l'entraînement. En général, les tâches plus complexes nécessitent plus d'itérations pour que le modèle converge vers une solution optimale. Il est également important de surveiller la performance du modèle sur un ensemble de validation pendant l'entraînement pour déterminer si le modèle continue de s'améliorer ou commence à surajuster.

3.8.5 Choix de fonction d'activation

La fonction d'activation est une fonction mathématique appliquée à la sortie d'un neurone (ou d'une couche de neurones) dans un réseau de neurones. Elle constitue une étape supplémentaire à chaque couche lors de la propagation vers l'avant. Elle est utilisée pour introduire la non-linéarité dans le modèle et permettre ainsi de modéliser des relations non-linéaires entre les variables.

Il existe 2 types de fonctions d'activation des réseaux neuronaux :

Fonction d'activation linéaire

La fonction d'activation linéaire (Figure 3.6), également appelée "fonction d'identité" est une fonction dont l'activation est proportionnelle à l'entrée. Elle est souvent utilisée dans les couches de sortie dans les problèmes de régression. La fonction ne fait rien à la somme pondérée de l'entrée, elle recrache simplement la valeur qui lui a été donnée. Mathématiquement, elle peut être représentée comme suit : $y = x$




FIG. 3.6 : Fonction d'activation linéaire

Cependant, une fonction d'activation linéaire présente deux problèmes majeurs :

- Il n'est pas possible d'utiliser la rétropropagation car la dérivée de la fonction est une constante et n'a aucun rapport avec l'entrée x .

- Toutes les couches du réseau neuronal se fondent en une seule si une fonction d'activation linéaire est utilisée. Quel que soit le nombre de couches du réseau neuronal, la dernière couche sera toujours une fonction linéaire de la première couche. Ainsi, une fonction d'activation linéaire transforme le réseau neuronal en une seule couche.

Fonctions d'activation non linéaires

La fonction d'activation linéaire présentée ci-dessus est simplement un modèle de régression linéaire. En raison de sa puissance limitée, elle ne permet pas au modèle de créer des correspondances complexes entre les entrées et les sorties du réseau.

Les fonctions d'activation non linéaires résolvent les limites suivantes des fonctions d'activation linéaires :

- Elles permettent la rétropropagation, car la fonction dérivée est désormais liée à l'entrée, et il est possible de revenir en arrière et de comprendre quels poids dans les neurones d'entrée peuvent fournir une meilleure prédiction.

- Ils permettent l'empilement de plusieurs couches de neurones, car la sortie est alors une combinaison non linéaire de l'entrée passée par plusieurs couches. Toute sortie peut être représentée comme un calcul fonctionnel dans un réseau neuronal.

Sigmoïde :

Elle représente la fonction de répartition de la loi logistique. Elle est couramment utilisée pour les tâches de classification binaire car elle produit une sortie comprise entre 0 et 1, qui peut être interprétée comme une probabilité. (Figure 3.7)




FIG. 3.7 : Fonction d'activation sigmoïde

La valeur de probabilité est calculée comme suit :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.4)$$

La fonction tangente hyperbolique (tanh) : La fonction tanh (Figure 3.8) produit une sortie comprise entre -1 et 1, ce qui la rend similaire à la fonction sigmoïde mais avec une sortie centrée autour de zéro. Cette propriété peut faciliter l'apprentissage pour certaines tâches en permettant une meilleure convergence des poids du réseau de neurones.




FIG. 3.8 : Fonction d'activation tanh

Fonction Relu(Rectified Linear Unit.) :

Bien qu'elle donne l'impression d'être une fonction linéaire, la fonction ReLU possède une fonction dérivée et permet la rétropropagation tout en étant efficace sur le plan informatique. (Figure 3.9)




FIG. 3.9 : Fonction d'activation Relu

Mathématiquement donné par :

$$G(E) = \max(0, E) = \begin{cases} E & \text{si } E \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (3.5)$$

Leaky Relu :

Leaky ReLU (Figure 3.10) est une fonction d'activation utilisée dans les réseaux de neurones. Elle permet un faible débit d'information pour les valeurs négatives, évitant ainsi la saturation des neurones. Dans les problèmes de régression, où la prédiction de valeurs continues est nécessaire, Leaky ReLU prévient la perte d'informations importantes et permet à la rétropropagation du gradient de fonctionner pour les valeurs négatives. Cela améliore la capacité d'apprentissage du modèle et conduit à de meilleures performances de prédiction. mathématiquement elle est donnée comme suit :

$$R(z) = \begin{cases} z & z > 0 \\ \alpha z & z \leq 0 \end{cases} \quad (3.6)$$




FIG. 3.10 : Fonction d'activation Leaky relu

3.9 Introduction sur les CNN

Au cours de la dernière décennie, les réseaux de neurones convolutifs (CNN) sont devenus la norme standard pour diverses opérations de vision par ordinateur et d'apprentissage automatique. Les CNN sont des réseaux de neurones artificiels (ANN) avec alternance de couches de convolution et de sous-échantillonnage (pooling). Les CNN 2D profonds avec de nombreuses couches cachées et des millions de paramètres ont la capacité d'apprendre des modèles complexes à condition qu'ils puissent être formés sur une base de données visuelle de taille massive avec des étiquettes. Avec une formation appropriée, cette capacité unique en fait l'outil principal pour diverses applications d'ingénierie pour les signaux 2D tels que les images et les trames vidéo. Pourtant, cela peut ne pas être une option viable dans de nombreuses applications sur des signaux 1D, en particulier lorsque les données d'entraînement sont rares ou spécifiques à l'application. Pour résoudre ce problème, des CNN-1D ont récemment été proposés et ont immédiatement atteint les niveaux de performance de pointe dans plusieurs applications telles que la classification personnalisée des données biomédicales et le diagnostic précoce, la surveillance de la santé structurelle, (SHM), la détection et l'identification des anomalies dans l'électronique de puissance et la détection des défauts des moteurs électriques. Un autre avantage majeur est qu'une implémentation matérielle en temps réel et à faible coût est possible grâce à la configuration simple et compacte des CNN 1D qui n'effectuent que des convolutions 1D (multiplications et additions scalaires). Ce chapitre présente un examen complet de l'architecture générale et des principes des CNN 1D ainsi que leur application sur la localisation des signaux émissions acoustiques.

3.10 Présentation des réseaux de neurones convolutifs

Deep Learning (DL) est la dernière réalisation de l'apprentissage automatique où il a présenté initialement des capacités quasi humaines, et de nos jours des capacités surhumaines dans de nombreuses applications, y compris les traductions voix-texte, la détection et la reconnaissance d'objets, la détection d'anomalies, la reconnaissance des émotions.

Dans cette section, nous commencerons par les CNN2d profonds tout en expliquant leurs fonctionnalités et blocs de base. Nous discuterons brièvement sur les CNN2D et les paramètres des CNN profonds les plus populaires, puis passerons au CNN 1D qui se concentrent uniquement sur les référentiels de signaux et de données 1D. L'accent sera mis en particulier sur les modèles CNN 1D compacts et adaptatifs, qui peuvent promettre certains avantages et supériorités par rapport à leurs homologues 2D profonds.

3.11 Réseaux de neurones convolutionnels 2D

Bien que près de 30 ans se soient écoulés depuis la proposition du premier CNN, les architectures CNN modernes partagent toujours les propriétés communes avec la toute

première, telles que les couches convolutionnelles et les couches pooling. De plus, outre quelques variantes, la méthode d'entraînement populaire, la technique de rétropropagation, est un autre point commun depuis les années 90. Cette section fournira un bref aperçu des CNN profonds conventionnels tout en présentant les idées les plus fondamentales.

Pour commencer, Les CNN profonds peuvent être attribués aux avantages suivants :

1. Les CNN peuvent apprendre à identifier les caractéristiques importantes des données d'entrée (par exemple, les bords, les textures, les couleurs) et les utiliser directement pour la classification sans avoir besoin de processus de prétraitement séparés.
2. les CNN peuvent traiter des données d'entrée volumineuses de manière plus efficace que les réseaux MLP traditionnels grâce à leur architecture sparsément connectée avec des poids partagés. Cela signifie que les CNN n'ont pas besoin de traiter tous les éléments d'entrée individuellement, mais seulement les éléments qui sont directement liés aux caractéristiques détectées. Cette caractéristique permet aux CNN de traiter les images et les données volumineuses avec une grande efficacité de calcul.
3. Les CNN sont insensibles aux petites transformations des données d'entrée, notamment la traduction, la mise à l'échelle, l'inclinaison et la distorsion.
4. Les CNN peuvent s'adapter à différentes tailles d'entrée.

Dans un MLP, chaque neurone caché contient des poids scalaires, une entrée et une sortie. Cependant, en raison de la nature 2D des images, chaque neurone d'un CNN contient des plans 2D pour les poids appelés noyau, et une entrée et une sortie appelées carte de caractéristiques. 'La figure 3.11' illustre les blocs de base d'un exemple de configuration CNN qui classe une image en niveaux de gris de 24 x 24 pixels en deux classes. Cet exemple de réseau se compose de deux blocs de couches. Un premier bloc contenant les couches convolutionnelles, celles-ci sont responsables de la génération des caractéristiques, et un second bloc de classification ou de régression qui contient des couches entièrement connectées, d'architecture similaire au MLP.

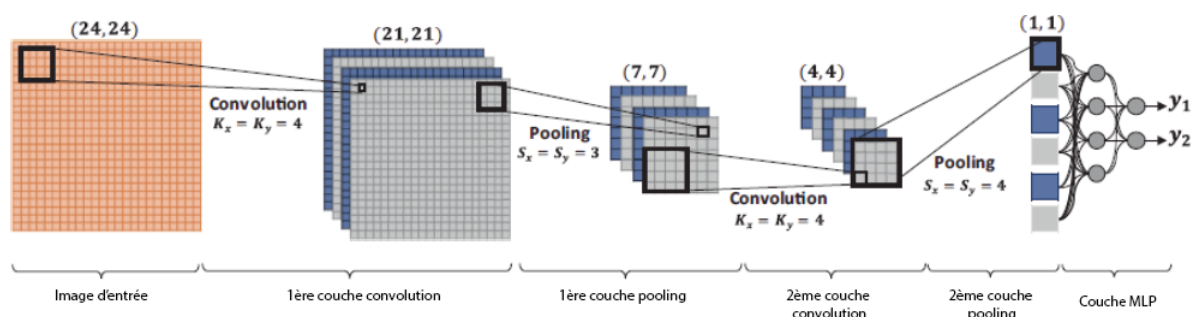


FIG. 3.11 : L'illustration d'un exemple de CNN avec 2 couches de convolution et une couche entièrement connectée.

3.11.1 Bloc des couches d'extraction des caractéristiques

Le premier bloc de ce réseau est spécial car il agit comme un extracteur de caractéristiques. La première couche de ce bloc applique plusieurs noyaux (filtre) de convolution

à l'image pour produire une carte de caractéristiques. Cette carte de caractéristiques est ensuite normalisée ou redimensionnée à l'aide d'une fonction d'activation. Ce processus peut être répété plusieurs fois en utilisant de nouveaux noyaux à chaque fois pour produire de nouvelles cartes de caractéristiques. Enfin, les valeurs des dernières cartes de caractéristiques sont concaténées et aplaties en un vecteur colonne. Ce vecteur définit la sortie du premier bloc et l'entrée du deuxième bloc.

Couches convolutionnelles

La couche convolutive 2D permet d'extraire les caractéristiques d'une image tout en conservant la relation entre les pixels grâce à l'apprentissage de filtres carrés. Elle prend en entrée une matrice d'image de dimensions $h \times w \times d$ (où h représente la hauteur de la matrice d'image, w sa largeur et d le nombre de canaux) et un filtre de dimensions $f_h \times f_w \times d$ (où f_h représente la hauteur du filtre, f_w sa largeur et d le nombre de canaux). Habituellement, pour une image RGB, la couche convolutive utilise trois canaux. Pour une image binaire ou en niveaux de gris, la couche convolutive utilise un seul canal. Le produit scalaire entre le filtre et une partie de la matrice d'entrée est calculé pour obtenir la matrice de sortie. Le filtre se déplace sur l'image en effectuant ce calcul avec des pas appelés "strides". Cette opération est répétée en glissant le filtre de gauche à droite et de haut en bas comme illustré dans la figure 3.12.




FIG. 3.12 : L'illustration d'un exemple d'opération de convolution

Couches de Pooling

La couche de pooling permet de réduire le nombre de paramètres et la puissance de calcul nécessaire tout en préservant les caractéristiques les plus importantes de l'image. Cette couche effectue une opération de sous-échantillonnage de l'image en divisant l'image en carrés non superposés et en prenant la valeur maximale ou moyenne de chaque carré. Cela produit une carte de caractéristiques de sortie avec un nombre de pixels réduit. Le max-Pooling est le type le plus courant de pooling et donne de meilleurs résultats que le average-Pooling. La figure 3.13 montre un exemple d'opérations de max-Pooling et de average-Pooling. Le Pooling est souvent utilisé entre deux couches convolutionnelles consécutives d'un CNN pour réduire la complexité et augmenter l'efficacité de l'apprentissage.




FIG. 3.13 : L'illustration d'un exemple d'opération de pooling

Couche d'aplatissement (Flatten layer)

L'étape d'aplatissement est la dernière étape du bloc d'extraction de caractéristiques. Elle consiste à transformer les matrices en une seule dimension en concaténant les lignes des matrices pour produire un vecteur unidimensionnel. Ce vecteur peut alors être connecté au bloc de prédiction comme illustré dans la figure 3.14.




FIG. 3.14 : Opération de concaténation du vecteur de caractéristiques

3.11.2 Bloc des couches entièrement connectées

Le processus de régression est assuré par des couches entièrement connectées qui sont similaires au perceptron multicouche. Ces couches ont pour objectif d'utiliser le vecteur aplati en entrée pour apprendre les meilleurs paramètres qui permettent de prédire ou détecté un objet donnée. En pratique, plusieurs couches sont empilées les unes sur les autres pour renforcer l'apprentissage des caractéristiques et améliorer la détection.

3.11.3 Paramètres d'un CNN

Filtre :

La convolution est un processus qui implique le déplacement d'un ensemble de filtres ou de noyaux de convolution sur l'image d'entrée. La taille, le nombre et le type de filtres à utiliser sont des choix qui dépendent de l'application et doivent être déterminés expérimentalement. La profondeur d'une couche convolutionnelle se réfère au nombre de noyaux qui sont utilisés, et c'est cette caractéristique qui est à l'origine du terme "Deep Learning". En utilisant un nombre q de filtres, l'image d'entrée est convoluée q fois, créant ainsi q matrices filtrées appelées "cartes de caractéristiques". La figure 3.15 illustre un exemple de filtrage.




FIG. 3.15 : Cartes de caractéristiques

Stride

Le stride désigne le nombre de pixels de décalage entre chaque position des filtres sur la matrice d'entrée. Lorsque le stride est de 1, les filtres se déplacent d'un pixel à chaque position. Avec un stride de 2, les filtres se déplacent de 2 pixels à chaque position, et ainsi de suite, comme représenté sur la figure 3.16 :

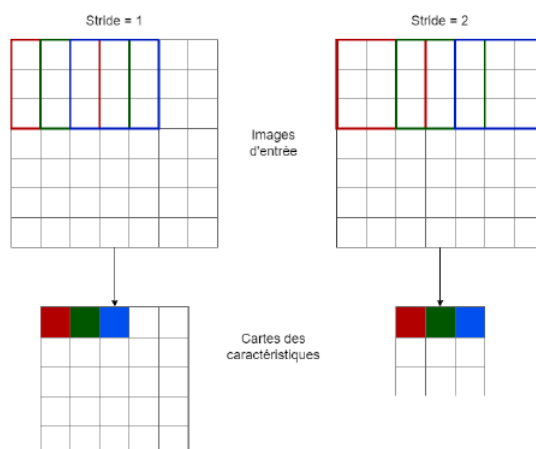


FIG. 3.16 : principe de stride

Zero-padding [51]

Après chaque couche de convolution, la taille de l'image en sortie est généralement plus petite que celle de l'image d'entrée en raison du traitement des pixels de bordure par le filtre. L'utilisation de plusieurs couches de convolution peut conduire à une image de sortie considérablement réduite par rapport à l'image d'entrée. Pour éviter cela et conserver la taille de l'image d'entrée, on utilise une technique appelée zéro padding, qui consiste à ajouter des zéros autour des bords de l'image en fonction de la taille du filtre utilisé. Ainsi, quelle que soit la profondeur du réseau de convolution, la taille de l'image en sortie est la même que celle de l'image d'entrée.

Les fonctions d'activation

Les fonctions d'activation sont également utilisées dans les réseaux de neurones convolutifs (CNN).

Dans les CNN, les fonctions d'activation sont appliquées après chaque couche de convolution pour introduire de la non-linéarité dans le réseau. Les fonctions d'activation les plus couramment utilisées dans les CNN sont la fonction d'activation ReLU (Rectified Linear Unit) et ses variantes, telles que la fonction d'activation Leaky ReLU que nous avons utilisé.

Dropout

Le "dropout" est une technique régulièrement utilisée en apprentissage profond pour réduire le surapprentissage et améliorer la généralisation du modèle. Elle consiste à supprimer de manière aléatoire un pourcentage des neurones dans une couche donnée pendant l'entraînement. Cette suppression force le réseau à apprendre des représentations plus robustes et à ne pas dépendre d'un sous-ensemble spécifique de neurones. Le taux de dropout K_p est un hyperparamètre qui peut être optimisé pour obtenir les meilleurs résultats. La figure 3.17 donne un exemple de dropout




FIG. 3.17 : Principe du drop-out durant l'entraînement d'un modèle

3.12 1D convolutional neural networks

Les CNN profonds conventionnels présentés dans la section précédente sont conçus pour fonctionner exclusivement sur des données 2D telles que des images et des vidéos. C'est pourquoi ils sont souvent appelés « CNN 2D ». Comme alternative, une version modifiée des CNN 2D appelée 1D Convolutional Neural Networks (CNN1D) a récemment été développée [52][53]. Ces études ont montré que pour certaines applications, les CNN 1D sont avantageux et donc préférables à leurs homologues 2D pour traiter les signaux 1D pour les raisons suivantes :

- Il existe une différence significative en termes de complexité de calcul des convolutions 1D et 2D, c'est-à-dire qu'une image de dimensions $N \times N$ convolué avec le noyau $K \times K$ aura une complexité de calcul ($N^2 K^2$) alors que dans la convolution 1D (avec les mêmes dimensions, N et K) c'est de complexité (NK). Cela signifie que dans des conditions équivalentes (même configuration, réseau et hyper paramètres), la complexité de calcul d'un CNN 1D est nettement inférieure à celle du CNN 2D.

- En tant qu'observation générale, en particulier au cours des études récentes, la plupart des applications CNN 1D utilise des configurations compactes (avec 1 à 2 couches CNN cachées) et avec des réseaux ayant des paramètres $< 10K$ alors que presque toutes les applications CNN 2D ont utilisé des architectures " profondes " avec plus de $1M$ habituellement au-dessus de $10M$ paramètres. De toute évidence, les réseaux avec des architectures peu profondes sont beaucoup plus faciles à former et à mettre en oeuvre.

- La formation de CNN 2D profonds nécessite une configuration matérielle spéciale (par exemple, le cloud computing ou les fermes GPU). D'autre part, toute implémentation de CPU sur un ordinateur standard est faisable et relativement rapide pour former des CNN 1D compacts avec peu de couches cachées (par exemple 2 ou moins) et de neurones (par exemple < 50).

- En raison de leurs faibles exigences de calcul, les CNN 1D sont bien adaptés aux applications en temps réel et à faible coût, en particulier sur les carte électronique et les appareils mobiles ou portables [52][54].

3.12.1 Architecture

les CNN 1D ont démontré une performance supérieure sur les applications qui ont des données étiquetées limitées et des variations de signal élevées acquises à partir de différentes sources. Comme illustré à la figure 3.18, deux types de couches distincts sont proposés dans les CNN 1D : 1) les « couches CNN » où se produisent à la fois les convolutions 1D, la fonction d'activation et le pooling, et 2) Entièrement connecté (denses) qui sont identiques aux couches d'un Perceptron multicouche typique (MLP) et donc appelées « couches MLP ». La configuration d'un 1D-CNN est formée par les hyperparamètres suivants :

- Nombre de couches/neurones CNN et MLP cachés.

- Taille du filtre (noyau) dans chaque couche CNN
- Facteur de pooling dans chaque couche CNN
- Le choix des fonctions d'activation.




FIG. 3.18 : configuration 1dcnn

Comme dans les CNN 2D classiques, la couche d'entrée est une couche passive qui reçoit le signal 1D brut et la couche de sortie est une couche MLP avec un nombre de neurones égal au nombre de classes à prédire.

Trois couches CNN consécutives d'un CNN 1D sont présentées à la figure 3.19, les noyaux de filtre 1D ont une taille de 3 et le facteur de pooling est de 2 où le k ème neurone de la couche CNN cachée, l , effectue d'abord une séquence de convolutions, dont la somme passe par la fonction d'activation, f , suivie de l'opération de pooling. C'est en effet la principale différence entre les CNN 1D et 2D, où les tableaux 1D remplacent les matrices 2D pour les noyaux et les cartes de caractéristiques.

Dans une prochaine étape, les couches CNN traitent les données 1D brutes et "apprennent à extraire" ces caractéristiques qui sont utilisées dans la tâche de classification ou de prédiction effectuée par les couches MLP. Par conséquent, les opérations d'extraction de caractéristiques et de régression sont fusionnées en un seul processus qui peut être optimisé pour maximiser les performances. C'est le principal avantage des CNN 1D qui peuvent également entraîner une faible complexité de calcul puisque la seule opération avec un coût significatif est une séquence de convolutions 1D qui sont simplement des sommes linéaires pondérées de deux tableaux 1D.




FIG. 3.19 : Trois couches CNN cachées consécutives

3.12.2 La propagation et la rétropropagation dans les CNN1D :

Dans chaque couche CNN1D la propagation (forward propagation) est exprimé comme suit :

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} \text{conv1D}(w_{ik}^{l-1}, s_i^{l-1}) \quad (3.7)$$

où x_k^l définie l'entrée, b_k^l est défini comme le biais de k^{th} neurone dans la couche l , s_i^{l-1} est la sortie de i^{th} neurone de la couche $l-1$, w_{ik}^{l-1} est le noyau (filtre) entre i^{th} neurone de la couche $l-1$ et le k^{th} de la couche l , $\text{conv1D}(\cdot, \cdot)$ est utilisé pour effectuer une 1D convolution sans zéro-padding. par conséquent la dimension de vecteur d'entrée x_k^l est inférieure à la dimension de vecteur de sortie s_i^{l-1} . La sortie y_k^l peut être exprimé en passant l'entrée x_k^l par la fonction d'activation $f(\cdot)$ telle que :

$$y_k^l = f(x_k^l)$$

L'algorithme de rétropropagation (BP) peut être résumé comme suit :

La rétropropagation de l'erreur commence à partir de la couche MLP de sortie. Supposons $l=1$ pour la couche d'entrée et $l=L$ pour la couche de sortie. prenons N_L le nombre de neurones de sortie et pour un vecteur d'entrée p , et ses vecteurs cible et de sortie t^p et $[y_1^L, \dots, y_{N_L}^L]$. Avec cela, l'erreur quadratique moyenne (MSE) [55] est exprimée comme suit :

$$E_p = \text{MSE}(t^p, [y_1^L, \dots, y_{N_L}^L]^T) = \sum_{i=1}^{N_L} (y_i^L - t_i^p)^2 \quad (3.8)$$

Pour trouver la dérivée de E_p par chaque paramètre de réseau, l'erreur delta, $\Delta_k^l = \frac{\partial E}{\partial x_k^l}$ (le gradient de l'erreur des poids et des biais) doit être calculée. Plus précisément, pour mettre à jour le biais de ce neurone et tous les poids des neurones de la couche précédente, on peut utiliser la règle suivant :

$$\frac{\partial E}{\partial w_{ik}^{l-1}} = \Delta_k^l y_i^{l-1} \text{ and } \frac{\partial E}{\partial b_k^l} = \Delta_k^l \quad (3.9)$$

Lorsque le gradient de l'erreur des poids et des biais sont calculées, elles peuvent être utilisées pour mettre à jour les biais et les poids avec le facteur d'apprentissage, α comme,

$$w_{ik}^{l-1}(t+1) = w_{ik}^{l-1}(t) - \alpha \frac{\partial E}{\partial w_{ik}^{l-1}} \quad \text{and} \quad b_k^l(t+1) = b_k^l(t) - \alpha \frac{\partial E}{\partial b_k^l} \quad (3.10)$$

Par conséquent, le flux itératif du BP pour les signaux bruts 1D dans l'ensemble d'apprentissage peut être énoncé comme suit :

- 1) initialisé les poids et les biais (en generale sont générés de façon aléatoire et compris de entre (-0.5, 0.5))
- 2) FP : propagation directe de la couche d'entrée à la couche de sortie pour trouver les sorties de chaque neurone à chaque couche
- 3) BP : Calculer l'erreur delta au niveau de la couche de sortie et la rétropropager à la première couche cachée pour calculé le gradient de l'erreur des poids et des biais
- 4) Mettre à jour les poids et les biais en utilisant le taux d'apprentissage α

3.13 Conclusion

Dans ce chapitre, nous avons commencé par évoquer l'histoire des réseaux neuronaux. Puis nous avons décrit les deux méthodes de l'intelligence artificielles utilisés dans notre mémoire ; à savoir, les réseaux de neurones artificiels et les réseaux de neurones convolutifs.

Ces deux techniques présentées dans ce chapitre sont utilisés dans le cadre de validation expérimentale qui fait l'objet du Chapitre 4. En effet, la phase expérimentale de ce travail va maintenant permettre d'observer la performance de ces méthodes pour la localisation des sources d'EA.

Chapitre 4

Validations expérimentales

4.1 Introduction

L'objectif de ce chapitre est de valider expérimentalement les performances des algorithmes proposés basés sur la transformée en ondelette continue et des modèles ANN et CNN pour la localisation des signaux d'émissions acoustiques dans une structure en forme de plaque. Les essais de rupture de mine sur une plaque en aluminium ont été réalisés au sein du laboratoire LAUM en France

Dans ce chapitre, nous allons décrire le matériau étudié, ses caractéristiques, ainsi que sa géométrie. Nous allons aussi définir les paramètres du système d'acquisition des données et d'évaluation. Ensuite, la transformée de l'ondelette continue à base de l'ondelette de Morlet complexe est utilisée pour calculer les temps d'arrivées des ondes de propagation mécaniques dans la pièce sous forme de plaque et les vitesses de propagation. La localisation des sources d'EA est réalisée à l'aide des méthodes à base du réseau de neurones artificiels ou à base du réseau de neurones convolutifs

4.2 Dispositif expérimental

4.2.1 Matériau utilisé dans le problème de localisation

Le choix est porté sur un matériau simple (c'est-à-dire homogène et isotrope par rapport aux fréquences considérées) : l'aluminium. Les constantes élastiques de l'aluminium, utilisées dans les calculs, sont listées dans le Tableau 4.1

Module d'Young E(Gpa)	Coefficient de poisson (ν)	Masse volumique ρ (kg/m ³)	Vitesse de l'onde longitudinale (m/s)	Vitesse de l'onde de cisaillement (m/s)
69	0,34	2700	6270	3080

TAB. 4.1 : Propriétés du matériau d'aluminium

Notre étude consiste à réaliser, dans une éprouvette en aluminium, un rupture de mine et à enregistrer l'allongement résultant à travers les signaux d'EA.

4.2.2 Caractéristiques de l'Aluminium

L'aluminium et ses alliages occupent une place prépondérante dans divers secteurs industriels et applications, et ce pour plusieurs raisons significatives :

Léger : L'aluminium est un métal très léger, avec une densité d'environ un tiers de celle du fer. C'est l'un des principaux attributs qui rend l'aluminium très utilisé dans de nombreuses applications, notamment dans l'industrie aérospatiale et automobile.

Bon conducteur électrique : L'aluminium est un excellent conducteur d'électricité. Sa conductivité électrique est d'environ 60% de celle du cuivre, ce qui en fait un matériau

couramment utilisé dans les câbles électriques, les fils et les lignes de transmission électrique.

Résistant à la corrosion : L'aluminium forme une couche d'oxyde d'aluminium sur sa surface qui le protège de la corrosion. Cette couche d'oxyde est très fine mais stable, ce qui confère à l'aluminium une excellente résistance à la corrosion dans de nombreux environnements.

Bon conducteur thermique : L'aluminium est également un bon conducteur thermique, ce qui signifie qu'il peut transférer efficacement la chaleur. C'est pourquoi il est souvent utilisé dans les radiateurs, les ustensiles de cuisine, les radiateurs de moteur, etc.

Malléable et ductile : L'aluminium est un métal malléable et ductile, ce qui signifie qu'il peut être facilement façonné et étiré en feuilles minces ou en fils. Cela le rend très adaptable à différentes formes et utilisations, notamment dans la fabrication de pièces moulées, de tôles et d'emballages.

Réfléchissant : L'aluminium possède une excellente réflectivité pour la lumière et les rayons thermiques. Il est donc souvent utilisé dans les réflecteurs, les miroirs, les isolants thermiques et les pare-soleil.

Recyclable : L'aluminium est entièrement recyclable, ce qui signifie qu'il peut être fondu et réutilisé sans perdre ses propriétés essentielles. Cela en fait un matériau respectueux de l'environnement et économiquement avantageux.

4.2.3 Géométrie de l'éprouvette

Les mesures effectuées dans ce travail portent sur un seul type de matériau largement utilisé dans de nombreuses applications industrielles qui est l'aluminium. La géométrie de l'éprouvette élaboré au cours de cette étude, est de forme carrée et de dimensions presque identiques. Sa mise en oeuvre est réalisée au sein du Laboratoire. Les dimensions de cette plaque sont $250 \times 230 \text{ mm}^2$ et une épaisseur de 2 mm . La figure 4.1 et le Tableau 4.2 montrent et donnent l'emplacement des capteurs piézoélectriques, la géométrie et la dimension de l'échantillon retenue dans notre étude.

Capteurs	S1	S2	S3	S4
Coordonnées (mm)	(0, 0)	(0, 60)	(40, 60)	(40, 0)

TAB. 4.2 : Coordonnées des capteurs sur la plaque en aluminium.




FIG. 4.1 : Plaque d'aluminium utilisé et sa photographie.

4.2.4 Acquisition des signaux d'EA

Un dispositif électronique composé d'un étage amplificateur et de filtrage, d'un système d'acquisition et d'enregistrement des signaux, ainsi qu'un micro-ordinateur de type PC, est utilisé pour l'acquisition des signaux d'activité acoustique (EA). Quatre capteurs piézoélectriques large bande (Nano30) sont fixés sur les échantillons à l'aide d'un couplant acoustique. La qualité du couplant est évaluée en effectuant plusieurs tests de cassure (test Hsu-Nielsen) sur l'échantillon. Ce test permet également de vérifier le bon fonctionnement des capteurs et la transmission des signaux acoustiques entre la surface de l'échantillon et le capteur. Les signaux acquis sont préalablement amplifiés à l'aide de préamplificateurs avec un gain de 40 dB, puis filtrés par un filtre passe-haut avant d'être enregistrés par un système d'acquisition MISTRAS (Euro Physical Acoustics) doté de 8 voies analogiques, chacune étant équipée d'un convertisseur analogique-numérique (CAN) 32 bits avec une fréquence d'échantillonnage allant jusqu'à 25 MHz. Ce système est composé d'une carte d'acquisition PCI qui convertit les signaux en données numériques afin d'extraire les caractéristiques acoustiques pertinentes. Les données d'EA sont ensuite transmises à l'ordinateur qui permet de visualiser les caractéristiques en temps réel, de les stocker et de les traiter ultérieurement. Cette étape finale permet de connaître l'intensité de l'émission acoustique, d'analyser le contenu des signaux et donc de différencier les mécanismes d'endommagement. L'enregistreur est également équipé d'une fonction de pré-déclenchement permettant de conserver en mémoire les signaux précédant le phénomène qui a déclenché l'acquisition.

Avant les essais, nous avons procédé à différents ajustements du système en utilisant le test Hsu-Nielsen [56]. Parmi ces réglages, nous utilisons des fenêtres d'acquisition temporelle glissantes appelées PDT, HDT et HLT. Ces valeurs sont utilisées pour séparer les salves d'activité acoustique (EA) et dépendent des propriétés du matériau. Les valeurs que nous avons choisies et évaluées expérimentalement sont les suivantes : $PDT = 300\mu s$, $HDT = 600\mu s$ et $HLT = 1000\mu s$. Des valeurs PDT-HDT trop courtes pourraient entraîner une acquisition tronquée des formes d'ondes (FO). D'autre part, si les valeurs HDT sont trop longues, des échos pourraient être enregistrés en plus des salves d'EA. Un temps d'aveuglement adéquat (HLT) permet également d'éviter de déclencher l'acquisition sur

des échos.

Une fois que l'échantillon et les capteurs sont mis en place, nous ajustons le seuil d'acquisition, qui correspond à l'amplitude minimale nécessaire pour enregistrer un signal, en fonction du bruit ambiant (externe et généré par la machine). L'objectif est d'éviter l'enregistrement de salves lorsque l'échantillon n'est pas sollicité, dans des conditions d'essai normales (positionnement des capteurs, couplage, bruit de fond généré par la machine, etc.). (positionnement des capteurs, couplage, bruit de fond généré par la machine, etc.. Dans nos condition de travail, nous avons choisi un seuil de $50dB$, qui est maintenu constant tout au long de l'essai. Lorsque l'amplitude des signaux dépasse le seuil d'acquisition, le système enregistre les données sur les quatre canaux. Plus précisément, 2048 points sont enregistrés par canal à une fréquence d'échantillonnage (F_e) de $2MHz$.

Différents filtres analogiques sont appliqués aux signaux afin de supprimer les bruits parasites. La carte d'acquisition est équipée d'une plage de filtrage de $20 - 400kHz$, qui a été choisi pour les essais.

Une fois l'acquisition terminée, les signaux sont portés dans MATLAB et PYTHON.

4.3 Sources d'EA Artificielles Utilisées

La source d'EA artificielle est produite par la rupture d'une mine de crayon (PLB) en graphite. Cette rupture engendre un signal très énergétique. C'est une source intéressante pour effectuer une validation expérimentale puisqu'elle a déjà été largement étudiée [143-146]. On en connaît donc suffisamment bien les paramètres temporels et spatiaux. La rupture de mine est une source artificielle en surface du matériau, et peu étendue.

Les mines de crayon utilisées pour les ruptures sont des mines 2H de diamètre $0,5\text{ mm}$. La longueur de mine est de 4 mm et fait un angle de 45° avec la surface de l'éprouvette. La mine est cassée dans plusieurs endroits choisis arbitrairement à la surface de la plaque en aluminium.




FIG. 4.2 : Représentation schématique du protocole expérimental utilisé pour valider les signaux simulés

4.4 Paramètres d'évaluation

Comme notre problème est un problème de régression où le but est de localiser avec précision l'emplacement des événements acoustiques sur la plaque d'aluminium, les métriques d'évaluation appropriées sont différentes de celles utilisées pour la classification. Pour cela on a fait le choix d'utiliser les métriques suivantes pour juger de la qualité de notre modèle :

4.4.1 L'erreur absolue moyenne MAE

L'erreur absolue moyenne est une paramètre utilisée pour évaluer la performance d'un modèle de régression. Elle mesure l'écart moyen entre les valeurs prédites par le modèle et les valeurs réelles dans un ensemble de données. Pour chaque échantillon, la différence absolue entre la valeur prédite et la valeur réelle est calculée. Ensuite, la moyenne de toutes ces différences absolues est obtenue, donnant ainsi l'erreur absolue moyenne. Ce paramètre est utilisée pour évaluer la précision globale du modèle en termes d'écart moyen entre ses prédictions et les valeurs réelles. Une valeur d'erreur absolue moyenne plus faible indique une meilleure performance du modèle.

L'erreur absolue moyenne est donnée comme suit :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (4.1)$$

4.4.2 La racine de l'erreur quadratique moyenne (Root Mean Squared Error, RMSE)

La racine de l'erreur quadratique moyenne (Root Mean Squared Error, RMSE) est un paramètre couramment utilisée pour évaluer la performance des modèles de régression. Elle mesure l'écart moyen quadratique entre les valeurs prédites par le modèle et les valeurs réelles dans un ensemble de données de test. Pour chaque échantillon, la différence entre la valeur prédite et la valeur réelle est calculée, puis élevée au carré pour obtenir les écarts quadratiques. Ensuite, la moyenne de tous les écarts quadratiques est calculée. Enfin, la racine carrée de cette moyenne est prise pour obtenir la racine de l'erreur quadratique moyenne. La racine de l'erreur quadratique moyenne donne une indication de l'adéquation du modèle aux données réelles, en accordant plus de poids aux erreurs plus importantes en raison du carré des écarts. Une valeur plus faible de RMSE indique une meilleure précision du modèle dans ses prédictions.

La formule mathématique pour le calcul de la racine de l'erreur quadratique moyenne est la suivante :

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (4.2)$$

4.5 Résultats expérimentaux

4.5.1 Représentation temporelle des signaux d'EA

Nous avons choisi 46 positions sur la surface de la plaque pour réaliser des ruptures de mine. A chaque position nous avons effectué 7 ruptures de mine. Donc nous avons eu au total 322 événements acoustiques.

Les signaux d'émission acoustique sont des signaux transitoires, courts en durée (typiquement quelques microsecondes à quelques millisecondes) et de haute énergie, généralement compris entre 20 kHz et 1 MHz. Ils sont caractérisés par des pics d'amplitude relativement élevés, qui sont souvent causés par des changements brusques dans la matière, tels que des fissures, des frottements, des déformations, etc. Puisque nous travaillons sur des structure en forme de plaque, nous allons avoir des ondes Lamb qui ont la particularité de mettre en mouvement la totalité de l'épaisseur de la plaque pour détecter les anomalies et les défauts. Ces ondes de Lamb sont aussi dispersives, c'est-à-dire que leur vitesse (vitesse de phase et de groupe) dépend de la fréquence.




FIG. 4.3 : Formes d'onde des signaux d'EA générés sur la plaque de d'aluminium

La figure 4.3 montre les formes d'onde des signaux d'EA émises par quatre impacts et reçus par le capteur N°1 (les impacts sont choisis au hasard). Les signaux obtenus sont de type résonnant et caractérisés par un temps de montée rapide et une longue durée.

Puisque la rupture de mine de plomb (source d'EA) est effectuée à la surface du matériau, le mode antisymétrique est le mode de l'onde de Lamb le plus sollicité et le plus

dominant. La vitesse de groupe de cette plaque est obtenue analytiquement. A partir de la théorie classique des plaques élastiques mince, la vitesse de l'onde de mode symétrique S_0 est :

$$V_{S0}(w) = \sqrt{\frac{E}{\rho(1-v)^2}} \quad (4.3)$$

et la vitesse de l'onde de mode antisymétrique A_0 est donné par :

$$V_{A0}(w) = 2 \left[\frac{Eh^2}{12\rho(1-v^2)} \right]^{1/4} \quad (4.4)$$




FIG. 4.4 : Représentation de mode symétrique et antisymétrique

Le signal dans la figure 4.4 montre que le mode d'onde symétrique (S_0) se propage plus rapidement que le mode d'onde antisymétrique (A_0) et que l'amplitude du mode S_0 est inférieure à celle du mode A_0 . Les analyses effectuées ont montré qu'en fonction de l'impact AE détecté, certains des capteurs recevaient les modes A_0 et S_0 (ainsi que leurs réflexions) et d'autres recevaient un seul mode, à savoir le mode A_0 (également pour localiser la position de la source AE correctement, il reste important d'utiliser le même mode de propagation qui peut être soit en extension, soit en flexion. Les données enregistrées ont révélé que le mode de flexion A_0 est toujours détecté par tous les capteurs et contient en même temps l'énergie maximale de l'EA détecté. Selon la fréquence impliquée, les vitesses de groupe correspondant aux modes A_0 détectés étaient comprises entre 2200 m/s et 3400 m/s [57]. Pour cette raison, nous choisirons de prendre seulement les mode A_0 dans nos expériences comme donné d'entrée de notre modèle ANN, négligeons les mode S_0 .

4.5.2 Analyse temps-fréquence des signaux d'EA

L'analyse temps-fréquence, utilisant une transformée en ondelettes continue (CWT), présente des incertitudes intrinsèques quant à la localisation dans le temps et dans la fréquence, en raison de l'inégalité de Heisenberg. La figure 4.5 présente les incertitudes en temps et en fréquence de l'ondelette de Morlet Complexe utilisée dans cette étude, avec une fréquence centrale f_c de 1,2 Hz et une large bande f_b de 0,7 Hz. Les équations qui sont utilisées pour calculer ces incertitudes peut être défini par :

$$\sigma_t = \frac{f_c \sqrt{f_b}}{2\bar{f}} \quad (4.5)$$

$$\sigma_w = \frac{\bar{f}}{f_c \sqrt{f_b}}, \quad \sigma_f = \frac{\bar{f}}{2\pi f_c \sqrt{f_b}}$$

Comme on peut l'observer sur la figure 4.5, l'incertitude de résolution en fréquence augmente aux fréquences plus élevées, tandis que l'incertitude de résolution en temps diminue.




FIG. 4.5 : Incertitude dans la résolution en temps et en fréquence de l'ondelette de Morlet Complexe

En général, l'analyse en ondelettes offre une flexibilité accrue car elle permet à l'opérateur de choisir les facteurs d'échelle en fonction de l'ondelette utilisée.

4.5.3 Représentation de la CWT

La figure ci-dessous 4.6 donne un exemple d'une représentation temps-fréquence issue d'une CWT (dans notre cas, l'ondelette mère utilisée est l'ondelette de Morlet complexe avec des paramètres fixés à $f_c=1.2\text{Hz}$ et $f_b= 0.7\text{Hz}$) d'un événement acoustique. La variation de couleur représente l'amplitude des coefficients de l'ondelette. Les amplitudes les plus élevées sont inférieures à environ 350 kHz. Ainsi, la valeur maximale des coefficients de module au carré de la CWT correspond à la fréquence dominante. En projetant le pic d'énergie correspondant à la fréquence dominante, il est possible de déterminer le temps d'arrivée du signal au capteur. La CWT est appliquée aux signaux d'EA reçus de chaque événement acoustique afin de calculer leurs temps d'arrivée Cette opération est appliquée jusqu'au dernier événement acoustique.




FIG. 4.6 : Représentation temps-fréquence issue d'une CWT des signaux EA générés par la rupture de mine

La figure 4.7 nous donne une représentation 3D de scalogram

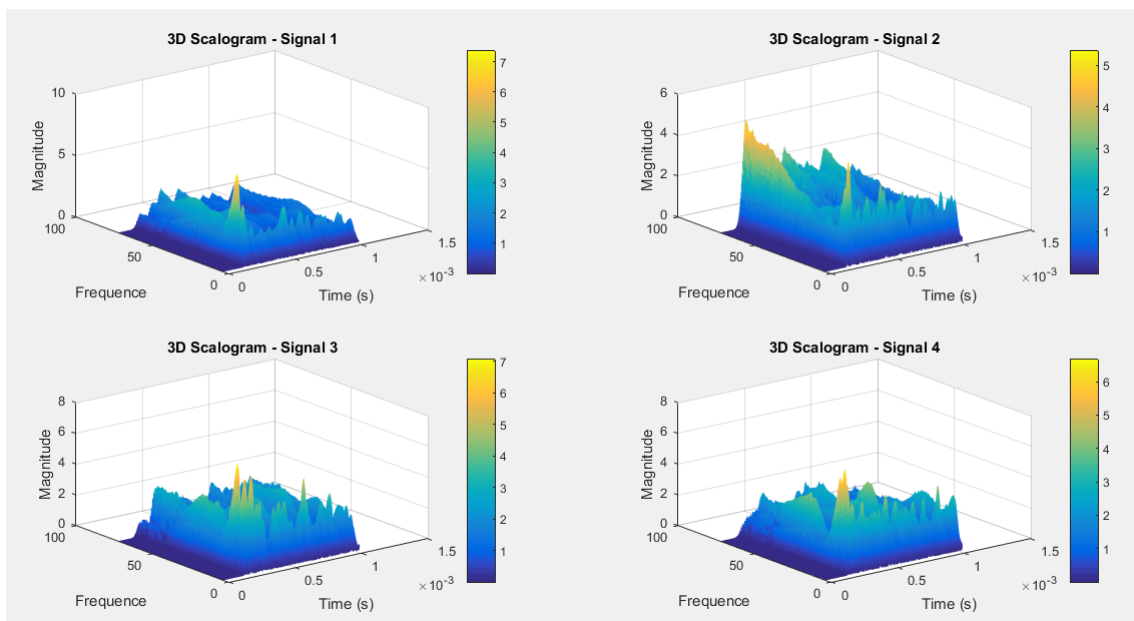


FIG. 4.7 : Représentation 3D de la CWT des signaux EA générés par la rupture de mine sur une plaque d'aluminium

4.5.4 Calcul du temps d'arrivée (TOA)

Afin de calculer le temps d'arrivée (TOA) des signaux directement propagés à partir des impacts (sources d'EA), On a utilisé deux techniques largement utilisées qui sont : 'maximum d'énergie' et 'entropie des ondelettes'

maximum d'énergie

Afin de déterminer le temps d'arrivée (TOA) d'un signal, il est essentiel de connaître la fréquence dominante extraite à partir des représentations obtenues par la transformée en ondelette continue (CWT). La fréquence instantanée, qui correspond à la fréquence dominante du signal analysé, est identifiée grâce à la valeur maximale des coefficients du scalogramme. Ces coefficients à valeurs maximales dans un domaine temps-fréquence, sont représentés par des pics d'énergie. La projection du pic correspondant à la fréquence dominante indique le moment d'arrivée du paquet d'ondes.

Une fois les temps d'arrivée sont calculés on calcule la différence de temps d'arrivée par rapport au capteur maître par la formule suivante $\Delta t = t_m - t_i$. Cette dernière valeur est utilisée comme une entrée dans notre modèle ANN.

La vitesse de groupe de mode Antisymétrique A0 choisit est calculée soit analytiquement par la formule suivante :

$$V_{gA0}(f) = 2 \left[\frac{E(2\pi fh)^2}{12\rho(1-v^2)} \right]^{1/4} \quad (4.6)$$

f est la fréquence dominante.

soit à travers la courbe de dispersion par projection sur l'axe de la vitesse de groupe de la valeur du produit fréquence dominante X épaisseur, comme l'illustre la figure 4.8.

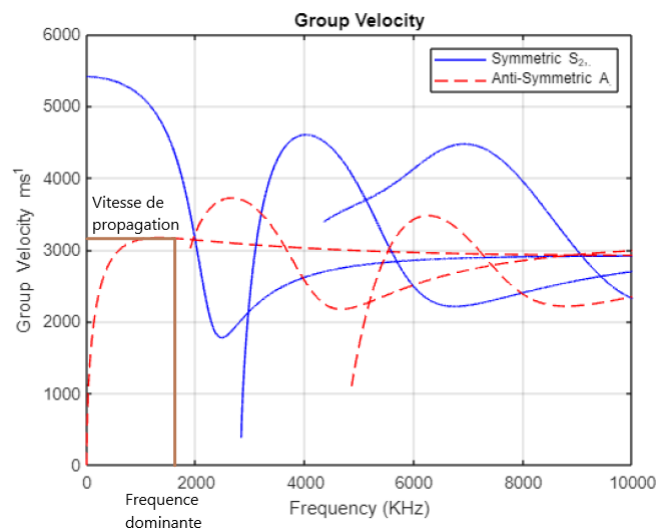


FIG. 4.8 : Extraction de la vitesse de propagation à partir de la courbe de dispersion

Les résultats des données TDOA sont listés dans le tableau 4.3 suivant :

	Impact 1	Impact 2	Impact 3	Impact 4	Impact 5	Impact 6	Impact 7	Impact 8
DTOA 1	8,7500e-05	0,0002530	8,200e-05	4,8000e-05	-0,0002370	0,0001295	0,000347	7,500e-05
DTOA 2	-9,250e-05	-7,750e-05	0,00017	-4,60e-05	-0,0002285	0,0002155	0,000131	-9,49999e-06
DTOA 3	-9,50e-05	-1,050e-05	5,49999e-06	-0,00010250	-1,10e-05	0,0001070	4,99999e-06	6,500e-06

TAB. 4.3 : Données des TDOA calculés par CWT 'maximum d'énergie'

Entropie des ondelettes

L'entropie des ondelettes permet de mesurer la complexité d'un signal en évaluant l'entropie de Shannon de la répartition des coefficients d'ondelettes à différentes échelles. Plus précisément, elle permet de quantifier la régularité de cette répartition en utilisant une fonction de probabilité qui tient compte des variations entre les coefficients d'ondelettes adjacents de sorte que plus l'entropie est élevée plus il est difficile de voir les variations entre les coefficients. En revanche, si la distribution de probabilité des coefficients d'ondelettes est biaisée l'entropie est plus faible, ce qui signifie qu'il y a une grande variation donc l'apparition d'un événement. Le but est de trouver la variation la plus importante qui correspond au minimum d'entropie et qui indique l'échelle de maximum des coefficients d'ondelettes.

Calculons l'entropie de Shannon des coefficients d'ondelettes voisin des signaux pris au hasard, nous allons avoir les courbes suivants : 4.9




FIG. 4.9 : l'entropie des ondelettes




FIG. 4.10 : Comparaisons des courbes d'entropie des ondelettes

La figure ci-dessus 4.10 donne les courbes de l'entropie des ondelettes (la valeur d'entropie en fonction de l'échelle) des 4 signaux d'un événement acoustique. La valeur minimale de chaque courbe correspond à l'échelle qui contient la plus grande énergie. Nous avons constaté que les valeurs minimales d'échelles est comprise entre 40 et 55 ce qui correspond aux fréquences entre 250kHz et 350kHz , ces fréquences sont considérées comme des fréquences dominantes. C'est à partir de ces fréquences que nous avons déterminé les vitesses de groupe utiliser dans notre modèle ANN.

Une fois les échelles sont trouvées on extrait le signal des coefficients d'ondelette à l'échelle qui correspond au minimum entropie (maximum d'énergie) de chaque signal (Figure 4.11).




FIG. 4.11 : Courbe indique l'énergie des coefficients d'ondelettes voisin qui correspond a l'échelle d'entropie minimale en fonction de temps

On peut trouvé a partir de cette représentation du signal des coefficients d'ondelettes voisin le temps d'arrivée qui corresponde a l'énergie la plus importante dans le signal d'EA en utilisant la transformée d'helbert pour obtenir le peak d'énergie (Figure 4.12).




FIG. 4.12 : Courbe indique l'énergie des coefficients d'ondelettes voisin qui correspond a l'échelle d'entropie minimale en fonction de temps

Les résultats des données TDOA sont listés dans le tableau 4.4 suivant :

	Impact 1	Impact 2	Impact 3	Impact 4	Impact 5	Impact 6	Impact 7	Impact 8
DTOA 1	8,7200e-05	0,000230	7,55e-05	5,8000e-05	-0,0005370	0,00081	0,00038	800e-05
DTOA 2	-8,380e-05	-6,770e-05	0,00011	-4,90e-05	-0,00033	0,0003354	0,000175	-9,8e-06
DTOA 3	-8.0e-05	-9.90e-06	5,65654e-06	-0,000450	-1,840e-05	0,0001050	3,3543e-06	5,9900e-06

TAB. 4.4 : Données des TDOA calculés par CWT 'Entropie des ondelettes'

4.6 Localisation des sources d'EA

Dans cette section, nous allons présenté les essais réalisés pour la localisation des sources d'EA, ainsi qu'une comparaison des performances des différents modèles développés en fonction des métriques précédemment décrites. Il convient de noter que nous avons utilisé deux approches distinctes pour nos expériences : un réseau de neurones artificiels optimisé et un modèle basé sur les réseaux de neurones convolutifs.

4.6.1 Méthodologie

Notre objectif principal est de développer éventuellement un modèle pour localisé les signaux d'émission acoustique dans un matériau en forme plaque. Nous avons proposé deux modèles d'IA :

Un réseaux de neurones artificiels optimisé en utilisant les différences temps d'arrivées des signaux EA et leur vitesse de groupe (propagation) comme entrée de réseaux et un réseau de neurone convolutifs d'une seul dimension à travers des signaux d'émission acoustique brut comme entrée. La figure suivante résume les configurations proposées :

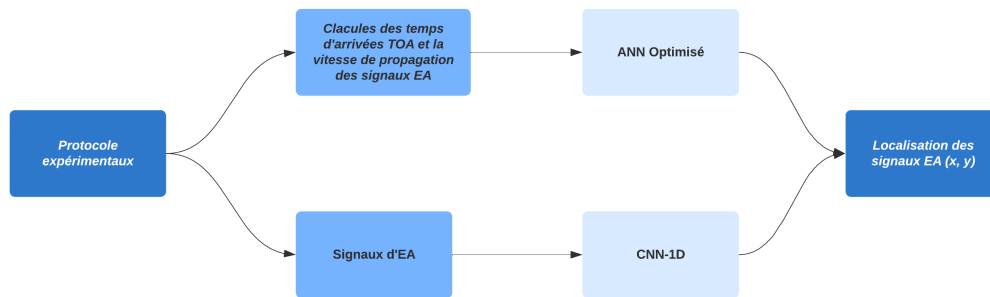


FIG. 4.13 : Méthodes adoptées pour la localisation des signaux EA

4.6.2 Répartition des données

Durant nos entraînements et évaluations, nous avons utilisé les trois subdivisions cité dans les tableaux 4.5, 4.6 et 4.7 :

- **La première subdivision** concerne le première réseau ANN_322 qui contient un ensemble de 322 événements acoustique construit sur la base de 46 positions. Dans chaque position nous avons effectué sept ruptures de mine.

- **La deuxième subdivision** est un réseaux de neurone ANN avec 966 événement acoustique. Nous avons triplé notre base de donnée par quelque modification dans les paramètres de détermination de temps d'arrivée.

- **La troisième subdivision** est à base de réseau CNN-1D, dont les signaux de différentes capteurs d'un même événement sont concaténé pour formé un seul signal avec 8192 échantillons.

ensembles	Pourcentage (%)	Nombre d'échantillon
Entraînement	65	218
Validation	20	55
Test	15	49

TAB. 4.5 : répartition des différents ensembles : entraînement, validation et test Pour le modèle ANN_322

ensembles	Pourcentage (%)	Nombre d'échantillon
Entraînement	65	656
Validation	20	165
Test	15	145

TAB. 4.6 : répartition des différents ensembles : entraînement, validation et test Pour le modèle ANN après l'augmentation des données

ensembles	Pourcentage (%)	Nombre de signaux
Entraînement	64	206
Validation	16	51
Test	20	65

TAB. 4.7 : répartition des différents ensembles : entraînement, validation et test Pour le modèle CNN-1D

4.6.3 Localisation Par un réseau de neurone artificiel optimisé ANN

Un réseau de neurone artificiel nécessite des ensembles de données pour établir la relation entrée-sortie. L'approche de réseau de neurone utilisée dans ce travail est basée sur les différences de temps d'arrivée et la vitesse de groupe de mode propagation A0 qui a été décrite dans la section précédente. Par conséquent, le vecteur d'entrée multidimensionnel est composé de 3 différences de temps d'arrivée, liés à la différence de chaque capteur piézoélectrique avec le capteur maître, et de la vitesse de propagation (groupe) des ondes générées par la source d'EA. Le vecteur de sortie, quant à lui, comprend les coordonnées (x, y) des dommages. Après avoir généré les vecteurs d'entrée et de sortie, l'architecture du réseau de neurone peut être définie. Il est clairement indiqué que l'efficacité du réseau de neurone augmente lorsque la dimension de l'ensemble de données augmente et pour cela nous avons utilisé deux ensemble de données :

- Le première ensemble (tab 4.5) contient les différences de temps d'arrivée et leur vitesse de groupe générer à partir des 322 signaux EA par les paramètres suivants :

Wavelet	Fréquence centrale	Largeur de bande	Echelle	Fréquence minimale	Fréquence maximale	Méthode
Morlet complexe	1.2	0.7	Exponentielle	120000	480000	Maximum d'énergie

TAB. 4.8 : Les paramètres utilisées pour l'acquisition de TOA pour le modèle ANN_322

- Le deuxième ensemble (tab 4.6) contient les mêmes différences de temps d'arrivée générées à partir des 322 signaux EA, mais aussi d'autres paramètres que nous avons calculer par la modification en deux fois des paramètres cités ci-dessus pour essayer d'éliminer les incertitudes de calcul. Par conséquent, nous avons choisi les ensembles de paramètres suivants :

1ère ensemble des paramètres	Wavelet	Fréquence centrale	Largeur de bande	Echelle	Fréquence minimale	Fréquence maximale	Méthode
	Morlet complexe	1.2	0.7	Exponentielle	120000	480000	Maximum d'énergie
2ème ensemble des paramètres	Wavelet	Fréquence centrale	Largeur de bande	Echelle	Fréquence minimale	Fréquence maximale	Méthode
	Morlet complexe	1.5	0.6	Exponentielle	150000	450000	Maximum d'énergie
3ème ensemble des paramètres	Wavelet	Fréquence centrale	Largeur de bande	Echelle	Fréquence minimale	Fréquence maximale	Méthode
	Morlet complexe	1.2	0.7	Exponentielle	120000	480000	Entropie des ondelettes

TAB. 4.9 : Les paramètres utilisés pour l'acquisition de TOA pour le modèle ANN_966

La Figure 4.14 montre le réseau de neurone développé ici qui comprend une quatre (04) entrées (3 différences de temps d'arrivée TDOA, et une vitesse de groupe) et une couche de sortie avec deux (02) éléments, à savoir les coordonnées du défaut (x, y). Des couches cachées avec plusieurs neurones ont été définies pour connecter les données d'entrée et de sortie, ce qui donne un réseau de neurone entièrement connecté MLP, conformément à la littérature [58].

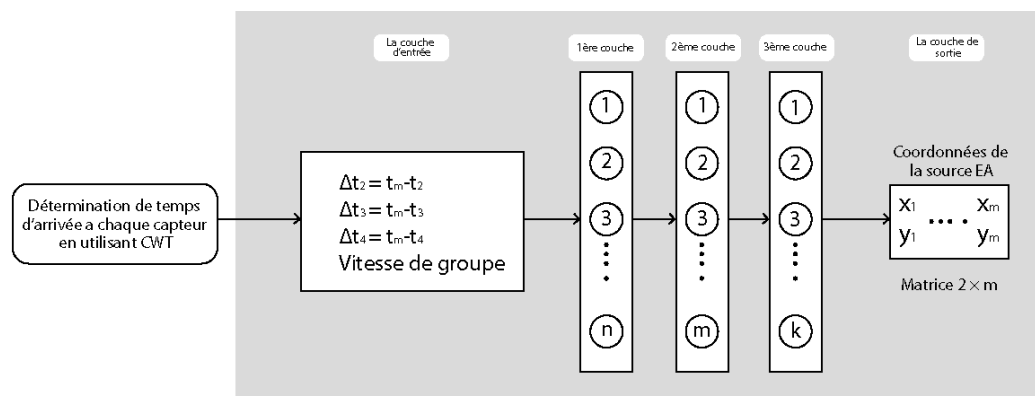


FIG. 4.14 : méthode de localisation des sources basé sur les ANN

Entraînement de ANN

Avant d'entamer la construction d'un modèle ANN optimale pour la localisation des signaux EA, il faut d'abord analyser et traiter les données d'entrées (les TDOA et la vitesse de groupe). Par ailleurs, il faut noter quelque détails à savoir ;

- Normalisation de nos données à l'aide de la bibliothèque scikit-learn, en utilisant la classe 'StandardScaler'. La normalisation des entrées peut aider à améliorer la performance et la stabilité des modèles d'IA, y compris les modèles utilisés pour la localisation des sources d'émission acoustique. Elle consiste à transformer les données d'entrée en les mettant à l'échelle de sorte que leur moyenne soit proche de zéro et leur écart-type soit proche de 1. Cela peut aider à rendre les données plus comparables entre elles et faciliter l'apprentissage pour le modèle. Et aussi on peut améliorer la convergence de l'algorithme

d'optimisation utilisé pour entraîner le modèle, et permettre une meilleure exploration de l'espace des paramètres. De plus, la normalisation peut aider à réduire les effets de la covariance des variables d'entrée, qui peut causer des problèmes de sur-apprentissage et de généralisation pour le modèle. Enfin, la normalisation peut aider à réduire la sensibilité des modèles à des écarts ou des variations dans les données d'entrée.

- Nous avons choisi d'utiliser la différence de temps d'arrivée DTOA comme entrée au lieu des temps d'arrivée TOA qui est utilisé dans la littérature car elle permet de réduire les erreurs systématiques liées à la calibration des capteurs et à la synchronisation des signaux. En utilisant des différences de temps d'arrivée, ces erreurs systématiques sont éliminées, ce qui peut améliorer la précision de la localisation des sources d'émission acoustique. En outre, l'utilisation de différences de temps d'arrivée peut être bénéfique pour l'optimisation de l'architecture du modèle car cela permet de réduire la dimension de l'espace d'entrée. Au lieu de traiter chaque temps d'arrivée individuellement, ce qui peut nécessiter un grand nombre de paramètres et conduire à un surapprentissage, le modèle peut être entraîné pour apprendre les relations entre les différences de temps d'arrivée, ce qui peut réduire la complexité du modèle et améliorer sa généralisation.

- En ajoutant la vitesse de groupe (v_g) en tant que paramètre d'entrée, le modèle peut apprendre à prendre en compte cette variable importante lors de la localisation des sources d'émission acoustique. Cela peut aider à réduire les erreurs de localisation dues à des variations dans la vitesse de groupe, telles que des changements de température, de pression ou d'humidité.

Nous avons divisé l'ensemble de données dont nous disposons en trois sous-ensembles : l'ensemble d'entraînement, l'ensemble de validation et l'ensemble de test. Ces sous-ensembles représentent respectivement 65%, 20% et 15% du total des données, comme indiqué dans les tableaux précédents (tab 4.5). L'ensemble d'entraînement est utilisé pour former le modèle d'apprentissage profond, tandis que l'ensemble de validation est utilisé pour évaluer les performances du modèle pendant l'entraînement. Enfin, les données de test constituent l'ensemble final utilisé pour mesurer les performances du modèle sur des données totalement nouvelles et inconnues.

Lors de la phase d'entraînement, l'algorithme Adam a été utilisé pour entraîner le réseau neuronal et faire la mise à jour des points w en raison de ses bonnes performances empiriques dans de nombreux problèmes de machine learning. De plus, Adam est souvent considéré comme étant moins sensible aux choix des hyperparamètres que d'autres algorithmes d'optimisation, ce qui peut simplifier la tâche de recherche d'hyperparamètres. Le taux d'apprentissage a été défini à 0.001 ou 0.01 durant la totalité de l'entraînement ainsi que on a utilisé un callback qui diminue le taux d'apprentissage avec un pourcentage de 0.4 si l'erreur ne fait pas diminuer pendant plus de 4 époques. On a ensuite sélectionné le nombre d'époques et l'architecture ayant eu les meilleurs résultats.

Nous avons choisi dans la couche de sortie la fonction d'activation Linear car elle est

souvent utilisée dans les couches de sortie des réseaux de neurones pour les tâches de régression. Dans ces cas, la fonction Linear permet au réseau de produire des sorties qui sont directement interprétables comme des prédictions de valeurs numériques. Cependant, elle n'est généralement pas utilisée dans les couches cachées des réseaux de neurones, car elle ne permet pas d'introduire de la non-linéarité dans le modèle. Les réseaux de neurones avec des fonctions d'activation linéaires dans les couches cachées sont équivalents à des modèles linéaires, qui ont des limitations importantes pour modéliser des fonctions non linéaires.

Dans le tableau suivant 4.10 nous présentons quelques architectures que nous avons évaluées telle que nous avons pris la meilleure pour nos expériences.

Données	architecture des couches	époque	α	$F()$	MAE training	RMSE training	MAE Test	RMSE Test
322	6	80	0,001	tanh	29,97	42	26,97	30
322	6_6	100	0,001	tanh	24	40	25	28
322	6_6_8_4	120	0,01	tanh	11,24	16,88	13,45	31
322	6_6_8_8_8_4	150	0,001	tanh	11,48	31,06	9,07	15,66
322	4_6_2	100	0,001	relu	29,84	41,8	27,36	31,1
322	6_4	150	0,01	relu	6,4	18,67	8,01	23,446
322	8_16_16_8	90	0,001	Leaky_relu(0,1)	4,45	12,61	6,7	18
966	12_16_16_12	80	0,001	relu	2,86	10,11	4,13	13,96
966	12_16_16_12	80	0,001	relu	16	30,2	14,86	25,215
966	8_16_16_8	90	0,001	Leaky_relu(0,1)	3,2	11	3,2	11,8
966	12_16_16	90	0,001	relu	4	12	3,17	12
966	12_32_32_32	90	0,001	Leaky_relu(0,1)	3,6	11	2,4	9,32

TAB. 4.10 : Architectures ANN

Les paramètres de l'architecture que nous avons utilisée dans le modèle ANN est dans ce tableau 4.11 :

Paramètres	Valeurs
Couche cachées	4
Neurones cachées	8_16_16_8
Epoque	90
taux d'apprentissage	0,001
Optimiseur Adam β	0,9
Fonction d'activation	Leaky_relu(0,1)
Fonction d'activation (sortie)	linear
Batch size	10

TAB. 4.11 : Architecture utilisée

4.6.4 Localisation Par un réseau de neurones convolutifs 1D CNN-1D

La localisation des sources d'EA peut également être réalisée à l'aide d'un réseau de neurones convolutifs 1D (CNN-1D). Contrairement au CNN traditionnel qui est principalement utilisé pour l'analyse d'images 2D, le CNN-1D est spécifiquement conçu pour traiter des données séquentielles, telles que celle de notre cas 'les signaux EA bruts'. Par conséquent, le vecteur d'entrée considéré est le signal d'EA mesuré et le vecteur de sortie est le même que celui de la localisation par ANN optimisé.

La subdivision de l'ensemble de données est donnée dans le tableau 4.7

Entraînement de CNN-1D

Dans le cadre de cette étude, nous avons entraîné un modèle de réseau de neurones convolutifs 1D (CNN-1D) pour la localisation des sources d'EA en utilisant les signaux générés par les ruptures de mine de crayon. L'objectif était de développer un système de détection précis et fiable capable d'estimer les emplacements des sources d'EA dans des plaques d'aluminium en analysant les caractéristiques des signaux acoustiques émis.

Notre modèle CNN-1D a été conçu en utilisant des couches de convolution 1D avec des filtres adaptés à l'analyse des signaux acoustiques. Les couches de pooling ont été utilisées pour réduire la dimensionnalité, ainsi que éliminer le problème de la malédiction de la dimension. La couche de sortie était une couche dense avec une fonction d'activation 'linéaire' appropriée pour prédire les coordonnées de la localisation des sources d'EA. Lors de l'entraînement, nous avons divisé nos données en ensembles d'entraînement, de validation et de test comme nous avons cité dans la section avant. Nous avons utilisé l'ensemble de validation pour ajuster les hyperparamètres du modèle, tels que le taux d'apprentissage, le nombre de filtres convolutifs, etc. L'optimiseur Adam a été utilisé avec une fonction de perte adaptée à la régression des coordonnées de localisation.

La figure 4.15 montre l'architecture CNN-1D utilisé

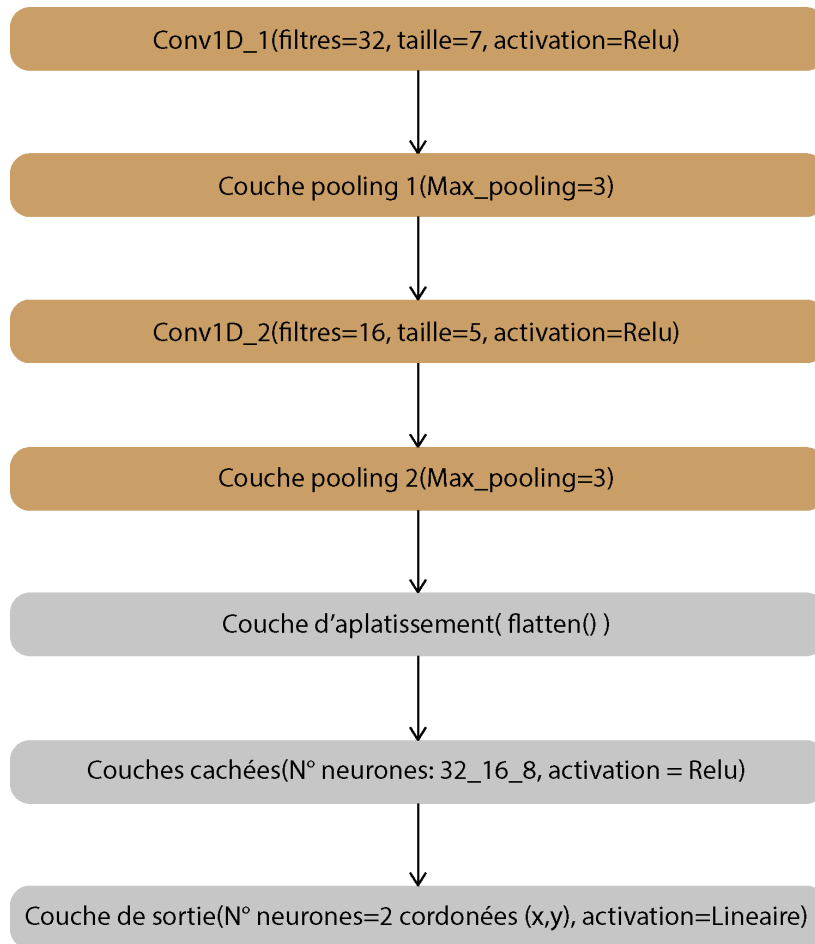


FIG. 4.15 : Procédure d'architecture CNN

Le tableau 4.12 récapitule les autres paramètres utilisés lors de l'entraînement de notre modèle

Taux d'apprentissage	Optimiseur	Nombre d'époque	Nombre totale de paramètre
0,001	Adam	80	469466

TAB. 4.12 : Les paramètres utilisés pour le modèle CNN-1D

Une fois l'entraînement terminé, nous avons évalué les performances du modèle sur l'ensemble de test. Pour évaluer la précision de la localisation, nous avons utilisé des mesures telles que l'erreur moyenne absolue et la racine de l'erreur quadratique moyenne entre les prédictions du modèle et les véritables emplacements des sources d'EA.

4.6.5 Performances atteintes

Dans cette section, nous allons évaluer nos différents modèles ANN optimisés et CNN-1D adoptés pour la localisation des sources d'EA d'émission acoustique dans la plaque d'aluminium selon les procédures présentées précédemment.

Performances atteintes par ANN avec l'ensemble de 322 échantillons

Dans un premier temps, nous allons évaluer les résultats fournis par l'ANN avec l'ensemble de 322 échantillons. Plus précisément, l'ANN entièrement entraîné a été testé à l'aide des 49 cas de test de dommages. La Figure 4.16 montre un bon accord entre les emplacements de dommages prédits et ceux modélisés.

Les tableaux 4.13 et 4.14 représentent respectivement quelle que résultats de prédiction des sources d'EA dans l'ensemble d'entraînement et de test dans le cas de 322 échantillons. les résultats sont évaluer à l'aide de l'erreur moyenne absolue MAE (Mean Absolute Error) et la racine d'erreur quadratique moyenne RMSE (Root Mean Square Error)

Coordonnées réelle (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[19.5, 30]	[19.106634, 30.737907]	0.4602715	0.5909191
[-160, -95]	[-160.050842, -94.030891]	0.0529715	0.0728551
[10, 30]	[9.603605, 30.804419]	0.396397	0.441126
[45, 60]	[45.653458, 56.039562]	3.634020	4.039996
[-2, 23]	[-1.598199, 23.409578]	0.598199	0.624468

TAB. 4.13 : la prédiction des sources d'EA sur l'ensemble d'entraînement

Coordonnées réelle (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[11.5, 35]	[12.289974, 35.135464]	0.462719	0.567151
[-36, -6]	[-34.6468, -14.338403]	4.8458015	8.615217
[32, 70]	[30.074377, 69.125473]	1.400075	1.498918
[-50, -6.5]	[-41.997818, -6.922339]	8.002182	8.242268
[-4, 22.5]	[-4.888270, 21.433359]	1.0561545	1.1316154

TAB. 4.14 : la prédiction des sources d'EA sur l'ensemble de test

Tableau 4.13 et 4.14 présente respectivement l'emplacement des dommages représenté par les coordonnées cartésiennes en millimètres. La deuxième colonne présentes les prédiction des sources d'EA, et les deux dernières colonnes présentent l'erreur moyenne absolue (MAE) et la racine de l'erreur quadratique moyenne (RMSE) de la position estimée des dommages par ANN. L'équation suivant calcule le MAE et le RMSE des positions des dommages :

$$RMSE = \frac{1}{2} \sqrt{\sum_{n=1}^N (x_{ann}(n) - x(n))^2 + (y_{ann}(n) - y(n))^2} \quad (4.7)$$

$$MAE = \frac{1}{2} \sum_{i=1}^n (|x_{ann}(n) - x(n)| + |y_{ann}(n) - y(n)|) \quad (4.8)$$

Les coordonnées réelles et les coordonnées prédites représentent la localisation des sources d'EA sur un matériau d'aluminium. Dans ce contexte, les coordonnées réelles

correspondent aux positions réelles des sources d'EA sur le matériau, tandis que les coordonnées prédites sont les positions estimées des sources d'EA obtenues par notre modèle ANN optimisé de prédiction.

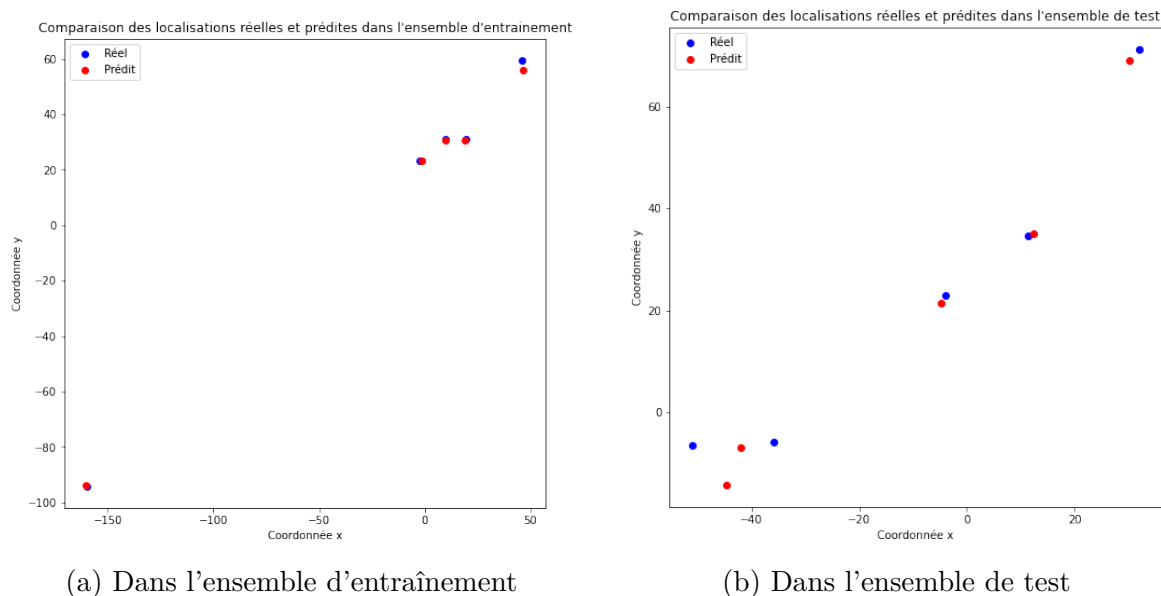


FIG. 4.16 : Comparaison entre les positions réelle et les positions prédites

En comparant les coordonnées réelles avec ceux prédites, nous pouvons évaluer la précision de notre modèle de prédiction. L'erreur MAE (Mean Absolute Error) et le RMSE (Root Mean Square Error) que nous avons calculés précédemment nous donnent une mesure de la différence moyenne et de la dispersion entre les coordonnées réelles et prédites.

À partir des résultats présentés dans les Tableaux, on constate de bon résultats dans la localisation de dommages et surtout dans l'ensemble d'entraînement. Dans le tableau 4.15 on donne les résultats de prédiction en générale :

MAE Entrainement	RMSE Entrainement	MAE Validation	RMSE Validation	MAE Test	RMSE Test
4.45 mm	12.61 mm	5.15 mm	15 mm	6.7 mm	13.45 mm

TAB. 4.15 : Les erreurs dans l'ensemble de 322 échantillons

La figure ci-dessous présente tous les sources d'EA que nous avons appliquées a la plaque avec les prédictions obtenues :




FIG. 4.17 : Estimation des emplacements des sources d’EA en utilisant ANN_322

Les résultats obtenus pour le modèle ANN avec 322 échantillons fournissent des indications sur sa performance dans la localisation des sources d’EA. L’erreur absolue moyenne (MAE) est de 4,45 mm pour l’entraînement, ce qui signifie qu’en moyenne, les prédictions du modèle diffèrent de 4,45 mm par rapport aux valeurs réelles dans l’ensemble d’entraînement. De même, l’erreur quadratique moyenne (RMSE) est de 12,61 mm ce qui indique que les prédictions du modèle présentent une certaine variation par rapport aux valeurs réelles, mais avec une importance pondérée par les écarts plus importants.

Lors de la validation, l’erreur absolue moyenne (MAE) est de 5.15 mm et l’erreur quadratique moyenne (RMSE) est de 18 mm cela reflète une légère augmentation de l’écart entre les prédictions et les valeurs réelles par rapport à l’ensemble d’entraînement. Cela peut suggérer que le modèle présente une certaine généralisation mais rencontre des difficultés lorsqu’il est confronté à de nouvelles données lors de la phase de validation.

Enfin, lors du test, l’erreur absolue moyenne (MAE) est de 6.7 mm et l’erreur quadratique moyenne (RMSE) est de 13.45 mm indiquant que le modèle conserve une performance similaire à celle de la validation. Cela peut indiquer que le modèle a une capacité de généralisation raisonnable et qu’il est capable de fournir des prédictions cohérentes sur des données inconnues.

Dans l’ensemble, ces résultats suggèrent que le modèle ANN avec 322 échantillons présente une certaine précision dans la localisation des sources d’EA. Cependant, il existe encore une marge d’amélioration pour réduire les écarts entre les prédictions et les valeurs réelles. Une exploration plus approfondie et une augmentation de la taille de l’échantillon pourraient potentiellement améliorer les performances du modèle et permettre une meilleure précision dans la localisation des sources d’EA.

Performances atteintes par ANN avec l'ensemble de 966 échantillons

Dans la deuxième partie de notre étude, nous avons étendu notre évaluation des performances de l'ANN en utilisant l'ensemble de données de 966 échantillons. Quelques résultats obtenus à partir du réseau entraîné ANN en utilisant l'ensemble de 966 échantillons des emplacements de dommages sur l'ensemble d'entraînement et de test sont donnés dans les deux Tableaux 4.16 et 4.17 .

Coordonnées réelles (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[22.5, 38]	[22.014023, 37.940071]	0.485977	0.541047
[-52.5, 24.5]	[-49.527595, 24.958321]	2.972405	3.168597
[120, -160]	[118.605217, -161.339783]	1.394783	1.486801
[5, 30]	[5.150822, 30.560366]	0.150822	0.172651
[-3, -6]	[-3.103446,-6.251364]	0.103446	0.127286


TAB. 4.16 : la prédiction des sources d'EA sur l'ensemble d'entraînement

Coordonnées réelles (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[17.5, 35,5]	[17.585981, 36.217518]	0.135981	0.151407
[55, 91,5]	[54.907833, 91.418991]	0.092167	0.110057
[-58, -22.5]	[-57.628334, -23.254799]	0.371666	0.414485
[-35, -6]	[-36.338390, -6.245626]	1.338390	1.454888
[32,5, 41]	[32.263573, 40.959694]	0.236427	0.252456

TAB. 4.17 : la prédiction des sources d'EA sur l'ensemble de test

On remarque que l'utilisation de 966 échantillons est significativement supérieure à celui de 322 échantillons, ce qui renforce la qualité de notre analyse. La disponibilité d'un plus grand nombre d'échantillons a permis d'améliorer la précision et la fiabilité de notre modèle.

La figure 4.18 présente respectivement les positions des sources d'EA donnés par les deux tableaux d'entraînement et de test précédents. Les points bleus représentent les coordonnées réels et les points rouges représente les coordonnées prédites.



(a) Dans l'ensemble d'entraînement

(b) Dans l'ensemble de test

FIG. 4.18 : Comparaison entre les positions réelles et les positions prédites

Le tableau 4.18 présente les résultats de prédiction en générale

MAE Entraînement	RMSE Entraînement	MAE Validation	RMSE Validation	MAE Test	RMSE Test
2.2 mm	11 mm	3.1 mm	10.7 mm	3.2 mm	11.2 mm

TAB. 4.18 : Les erreurs dans l'ensemble de 966 échantillons

La figure ci-dessous présente toutes les source d'EA que nous avons appliquées a la plaque avec les prédictions obtenues :




FIG. 4.19 : Estimation des emplacements des sources d'EA en utilisant ANN_996

Les résultats obtenus pour le modèle ANN avec 966 échantillons révèlent une nette amélioration de sa performance dans la localisation des sources d'EA, par rapport au modèle précédent avec seulement 322 échantillons. Lors de l'entraînement, le modèle a affiché une erreur absolue moyenne (MAE) de seulement 2,2 mm, indiquant une différence moyenne de 2.2 mm entre les valeurs prédites et les valeurs réelles. Cette précision accrue est confirmée par l'erreur quadratique moyenne (RMSE) qui est 11 mm, une valeur significativement plus faible que celle obtenue avec le modèle précédent.

Lors de la phase de validation, le modèle a continué à démontrer de bonnes performances, avec une MAE de 3,1 mm et un RMSE de 10,7 mm. Ces valeurs témoignent de la capacité du modèle à généraliser et à fournir des résultats précis sur de nouvelles données. Ils suggèrent également que le modèle est capable de capturer les motifs et les caractéristiques des données de manière plus précise, grâce à la plus grande taille de l'échantillon.

Lors du test, le modèle a maintenu une performance solide, avec une MAE de 3.2 mm et un RMSE de 11,2 mm indiquent que le modèle conserve une performance similaire à celle de la validation, ces valeurs restent dans une fourchette raisonnable, confirmant la capacité du modèle à généraliser sur des données inconnues.

Dans l'ensemble, ces résultats démontrent que l'augmentation de la taille de l'échantillon à 966 a conduit à une amélioration significative de la précision du modèle ANN dans la localisation des sources d'EA. Cela souligne l'importance d'une plus grande quantité de données pour permettre au modèle d'apprendre de manière plus approfondie et d'obtenir des prédictions plus précises. Ces résultats renforcent la confiance dans l'efficacité du modèle ANN pour la localisation des sources d'EA et encouragent à poursuivre les efforts visant à améliorer davantage sa performance.

Performances atteintes en utilisant le CNN-1D

Pour notre dernière approche, e, nous avons étendu notre évaluation des performances à l'utilisation d'un réseau de neurones convolutifs avec comme données d'entrées les signaux d'EA mesurés. Quelques résultats obtenus à partir du réseau entraîné CNN-1D en utilisant l'ensemble de 322 événements des emplacements de dommages sur l'ensemble d'entraînement et de test sont donnés dans les deux Tableaux 4.19 et 4.20.

Coordonnées réelles (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[-21, 13.5]	[-19.330185, 13.308125]	1.670185	1.714209
[-160, -95]	[-158.050842, -93.030891]	2.028116	2.733315
[1, -12,5]	[2.002002, -12.979149]	1.002002	1.003737
[32.5, 39]	[32.653458, 38.039562]	0.960438	1.029598
[-2.5, 23]	[-1.998199, 23.409578]	0.501801	0.501803

TAB. 4.19 : la prédiction des sources d'EA sur l'ensemble d'entraînement

Coordonnées réelles (x, y)(mm)	Coordonnées prédites (x, y)(mm)	Erreur moyenne absolue MAE	RMSE
[11,5, 35]	[12.768140, 33.920769]	1.268140	1.395194
[32, 70]	[34.751244, 69.735756]	2.751244	2.828408
[-17, 18,5]	[-10.197569, 17.946289]	6.802431	6.861805
[-2, 25.5]	[-5.693963, 24.471939]	3.693963	3.741069
[-35, -6]	[-28.494026, 0.980172]	6.505974	7.273163

TAB. 4.20 : la prédiction des sources d’EA sur l’ensemble de test

Bien que les performances du modèle CNN-1D ne soient peut-être pas aussi élevées que celles du modèle ANN, il a tout de même démontré une capacité solide à détecter et à localiser les sources d’EA avec précision. Les résultats obtenus avec le modèle CNN-1D sont encourageants et satisfaisants, offrant une alternative pour l’analyse des sources d’EA.

La figure 4.20 présentent les positions des sources d’EA dans les tableaux d’entraînement et de test précédents. Les points bleus représentent les coordonnées réelles, tandis que les points rouges représentent les coordonnées prédites.

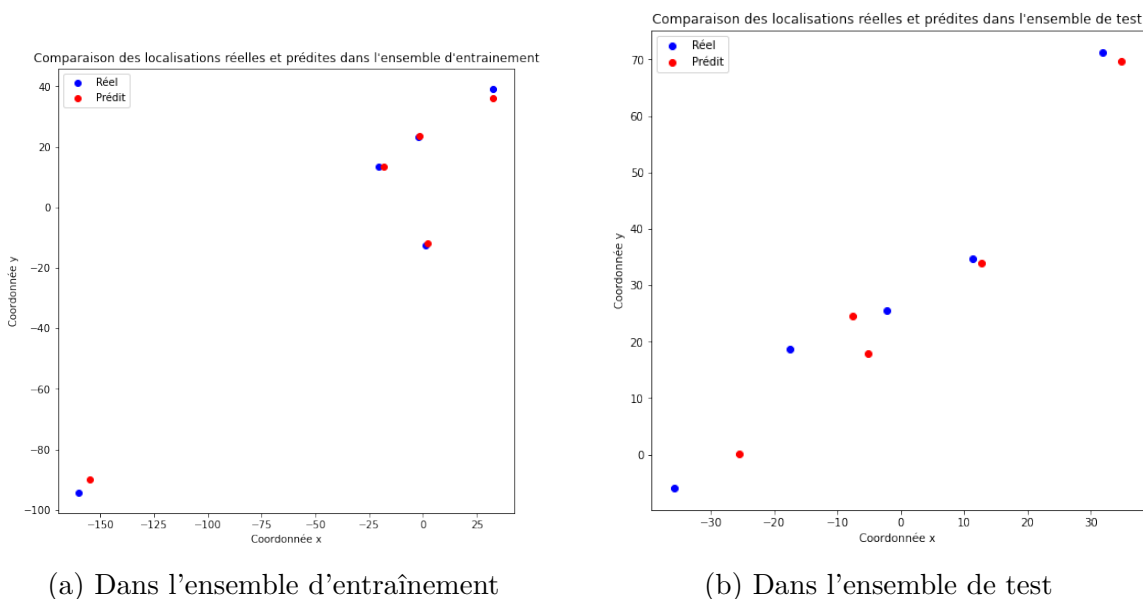


FIG. 4.20 : Comparaison entre les positions réelles et les positions prédites

Le tableau qui suit 4.21 présente de manière exhaustive les résultats de prédiction obtenus dans tout l’ensemble de données.

MAE Entraînement	RMSE Entraînement	MAE Validation	RMSE Validation	MAE Test	RMSE Test
4,06 mm	6,6 mm	5 mm	9,3	7.62 mm	10,31 mm

TAB. 4.21 : Les erreurs pour le modèle de CNN-1D

La figure ci-dessous présente tous les sources d’émissions acoustiques que nous avons

appliquées à la plaque avec les prédictions obtenues :




FIG. 4.21 : Estimation des emplacements des sources d'EA en utilisant CNN-1D

Il convient de mentionner que notre modèle CNN-1D (Convolutional Neural Network 1D) a donné de bon résultats dans la localisation des sources d'EA. Bien que les performances du modèle CNN-1D ne soient peut-être pas assez élevées que celles du modèle ANN, elles restent tout de même satisfaisantes. Le modèle CNN-1D a démontré sa capacité à extraire efficacement les caractéristiques pertinentes des données d'entrée et à détecter les sources d'EA avec une précision raisonnable. Il a fourni des résultats solides dans la tâche de localisation des sources d'EA. Dans l'ensemble, le modèle CNN-1D a montré des performances encourageantes.

Les résultats obtenus par le modèle CNN-1D avec 322 signaux fournissent des informations clés sur sa performance dans la localisation des sources d'EA. Une analyse approfondie de ces résultats révèle les observations suivantes :

Pendant la phase d'entraînement, le modèle a atteint une précision satisfaisante, avec une erreur absolue moyenne (MAE) de 4,06 mm. Cela signifie que les prédictions du modèle présentaient en moyenne une différence de 4,06 mm par rapport aux valeurs réelles dans l'ensemble d'entraînement. De plus, l'erreur quadratique moyenne (RMSE) de 6,6 mm démontre une adéquation raisonnable entre les prédictions et les valeurs réelles, en tenant compte des écarts de toutes les tailles.

Lors de la phase de validation, le modèle a affiché une MAE de 5 mm, indiquant une augmentation légère de l'écart moyen entre les prédictions et les valeurs réelles par rapport à l'ensemble d'entraînement. Cela renseigner que le modèle rencontre certains défis lorsqu'il est confronté à de nouvelles données pendant la phase de validation. En outre, le RMSE de 9,3 mm confirme cette augmentation de l'écart moyen, avec une pondération plus importante accordée aux écarts plus significatifs.

Au cours des tests effectués sur des données inconnues, le modèle a révélé une MAE de 7,62 mm, indiquant un écart moyen de 7,62 mm entre les prédictions et les valeurs réelles. Le RMSE de 10,31 mm souligne également une légère augmentation de la variation des prédictions par rapport aux valeurs réelles lors des tests.

Dans l'ensemble, les résultats du modèle CNN-1D avec 322 signaux témoignent d'une performance acceptable dans la localisation des sources d'EA. Toutefois, des améliorations sont envisageables pour réduire davantage les écarts entre les prédictions et les valeurs réelles. Une exploration plus approfondie des caractéristiques des données, une optimisation des hyperparamètres du modèle et des ajustements supplémentaires pourraient potentiellement améliorer ses performances et permettre une localisation plus précise des sources d'EA. Il est essentiel de poursuivre l'évaluation et le développement du modèle afin de maximiser sa précision et sa fiabilité.

4.6.6 Récapitulatif des résultats et Comparaison

La figure ci-dessous 4.22 englobent les meilleurs résultats de chaque modèle et montre l'évolution des performances :




FIG. 4.22 : Les erreurs relatives des modèles sur la prédiction des coordonnées des sources d'EA en mm

- Le résultat de performance d'entraînement de l'ANN, présenté dans la figure 4.22, indique que l'ANN peut trouver la position correcte des dommages renseignés.

- La figure 4.22 montre les résultats d'entraînement pour l'ANN_322, ANN_966 et CNN-1D. L'ANN_966 présente de bonnes performances par rapport aux deux autres modèles. Les résultats montrent la bonne capacité de généralisation de l'ANN_966 par rapport à ANN_322 et CNN-1D.

- Deux paramètres l'un est appelé erreur absolue moyenne (MAE) et l'autre est appelé racine d'erreur quadratique moyenne (RMSE) sont utilisées pour comparer le résultat global de la performance de généralisation.

- Les valeurs de MAE affichées dans la figure 4.22 pour les trois algorithmes avec une erreur maximale de 0.7cm montre que la meilleure performance était celle de ANN_966, ces résultats montrent la bonne information de localisation des dommages contenue dans les TDOA et la vitesse de groupe calculés en utilisant la CWT (Ondelette de morlet complexe). En revanche les valeurs de RMSE montre que la meilleure performance était celle de des deux algorithmes ANN_966 et CNN-1D. Ce résultat confirme la grande capacité de CNN-1D à extraire des caractéristiques pertinentes à partir des données d'entrée. Cependant, la structure CNN-1D a un coût de calcul élevé par rapport au modèle ANN Car on remarque clairement que le nombre de paramètres utilisé pour le modèle ANN est 640 et le nombre de paramètres utilisé pour le CNN-1D est 469466. Le calcul le plus faible est lié à ANN, en raison de la conception basée sur la recherche de la structure neuronale la plus simple. Cette faible complexité du réseau de neurone montre l'adéquation pour les applications embarquées, avec une capacité de calcul limitée, ou pour être implémentée dans un dispositif de traitement matériel, tout en maintenant une bonne capacité de généralisation.

4.7 Conclusion

Dans ce chapitre nous avons validé expérimentalement les performances des approches proposées pour la localisation des sources d'EA (rupture de mine de crayon) dans une structure en forme de plaque. L'une des méthodes proposées est basée un réseaux de neurones artificiel avec comme entrée les différences de temps d'arrivée et les vitesses de groupes, tandis que l'autre méthode proposée est basée sur les réseaux de neurones convolutif 1D.

La transformée en ondelettes continue estime les temps d'arrivée et la fréquence dominante des ondes de Lamb générées par les ruptures de mine de crayon. Le critère basé sur l'entropie de Shannon est utilisé pour trouver les meilleures valeurs d'échelle.

Les résultats expérimentaux de détection et de localisation des dommages dans la plaque d'aluminium valident la robustesse et l'efficacité de de notre réseaux de neurones artificiels optimisé. Les performances de généralisation de ANN ont été comparées à celle de réseaux CNN-1D. Les résultats montrent que le ANN présente de bonnes performances par rapport aux structures complexes CNN-1D.

Conclusion et perspectives

L'objectif principal de ce mémoire de fin d'étude est la mise en place de techniques de traitement du signal avancées pour la localisation des sources d'EA dans des structures en forme plaque, basée sur les réseaux de neurones artificiels. Les outils que nous avons développés dans ce travail de mémoire ont fait l'objet de validations expérimentales. Nous nous sommes intéressés à des plaques en aluminium.

L'approche proposée comprend deux étapes principales. Au cours de la première étape, les mesures du temps d'arrivée (TOA) des ondes d'EA sont effectuées par une transformée en ondelettes continue (CWT), tenant compte des erreurs systématiques dues à l'incertitude de Heisenberg. L'ondelette de Morlet complexe a été utilisée. La deuxième étape utilise soit la technique basée sur les réseaux de neurones artificiels (ANN), soit la technique basée sur les réseaux de neurones convolutifs à une seule dimension (CNN-1D). À partir de l'étude, les conclusions suivantes sont tirées :

- L'approche que nous avons mise en place pour l'estimation de la position et de l'emplacement des sources d'EA générées artificiellement par des ruptures des mines de plomb (PLB) en surface d'une plaque d'aluminium offre des résultats satisfaisants, ce qui mis en évidence sa robustesse, son efficacité et sa précision.

- D'abord, une analyse temps-fréquence issue d'une transformée en ondelettes continue (CWT) a été appliquée afin d'estimer le DTOA et la fréquence dominante des signaux des ondes de Lamb mesurés. Le critère basé sur l'entropie de Shannon permet de trouver les meilleures valeurs d'échelle où se situe l'énergie maximale. Les amplitudes les plus élevées se trouvent en deçà de 350 kHz environ.

- Les résultats expérimentaux montrent que l'approche à base de l'ANN estime l'emplacement des sources d'EA dans la plaque d'aluminium. Tous les réseaux entraînés peuvent prédire l'emplacement de la source avec une moyenne d'erreur inférieure à 7mm. Les avantages de l'algorithme proposé résident dans la prise en compte des incertitudes dans les mesures de TOA et de la vitesse des ondes.

- L'approche à base des réseaux de neurones convolutifs avec une seule dimension (CNN-1D) pour l'estimation des sources d'EA offre de bons résultats avec une moyenne d'erreur de 7.6 mm, malgré l'utilisation de 322 signaux seulement.

Cette précision obtenue a été encourageante pour l'investigation de véritables sources d'EA générées par des sollicitations mécaniques. Ainsi, ce travail peut être étendu à d'autres types de structures plus complexes telles que les poutres et matériaux composites.

Bibliographie

1. MEJLEJ, Wahid Ghaffari ; OSORIO, Daniel ; VIETOR, Thomas. An Improved Fatigue Failure Model for Multidirectional Fiber-reinforced Composite Laminates under any Stress Ratios of Cyclic Loading. *Procedia CIRP*. 2017, t. 66, p. 27-32. ISSN 2212-8271. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.procir.2017.03.303>. 1st CIRP Conference on Composite Materials Parts Manufacturing (CIRP CCMPM 2017).
2. HOLFORD, K. M. ; DAVIES, A. W. ; PULLIN, R. ; CARTER, D. C. Damage Location in Steel Bridges by Acoustic Emission. *Journal of Intelligent Material Systems and Structures*. 2001, t. 12, n° 8, p. 567-576. Disp. à l'adr. DOI : [10.1177/10453890122145311](https://doi.org/10.1177/10453890122145311).
3. CHENG, Lu ; XIN, Haohui ; GROVES, Roger M. ; VELJKOVIC, Milan. Acoustic emission source location using Lamb wave propagation simulation and artificial neural network for I-shaped steel girder. *Construction and Building Materials*. 2021, t. 273, p. 121706. ISSN 0950-0618. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.conbuildmat.2020.121706>.
4. A PILLAI, Minu ; GHOSH, Alwyn ; JOY, Jestin ; KAMAL, Suraj ; CHANDRAN, Sathesh ; BALAKRISHNAN, Arun ; M H, Supriya. Acoustic Source Localization using Random Forest Regressor. In : 2020. Disp. à l'adr. DOI : [10.1109/SYMPOL48207.2019.9005303](https://doi.org/10.1109/SYMPOL48207.2019.9005303).
5. LIU, Zenghua ; PENG, Q. ; LI, X. ; HE, C. ; WU, B. Acoustic Emission Source Localization with Generalized Regression Neural Network Based on Time Difference Mapping Method. *Experimental Mechanics*. 2020, t. 60. Disp. à l'adr. DOI : [10.1007/s11340-020-00591-8](https://doi.org/10.1007/s11340-020-00591-8).
6. C. S. WANG F. Wu, F. K. Chang. *Structural health monitoring from fiber-reinforced composites to steel-reinforced concrete*, t. 10. 2001. Smart Materials and Structures.
7. NIETHAMMER, Marc ; JACOBS, Laurence J. ; QU, Jianmin ; JARZYNSKI, Jacek. Time-frequency representations of Lamb waves. *The Journal of the Acoustical Society of America*. 2001, t. 109, n° 5, p. 1841-1847. ISSN 0001-4966. Disp. à l'adr. DOI : [10.1121/1.1357813](https://doi.org/10.1121/1.1357813).
8. SALAS, K ; CESNIK, Carlos. Guided wave excitation by a CLoVER transducer for structural health monitoring : Theory and experiments. *Smart Materials and Structures*. 2009, t. 18, p. 075005. Disp. à l'adr. DOI : [10.1088/0964-1726/18/7/075005](https://doi.org/10.1088/0964-1726/18/7/075005).

9. CHRISTIAN GROSSE, Masayasu Ohtsu. Acoustic Emission Testing. 2008, t. 141, p. X, 406.
10. ZINOVIY N Valentyn S, Oleh S. Acoustic Emission : Methodology and Application (Foundations of Engineering Mechanics). 2017, p. 297.
11. SCRUBY, C. An introduction to acoustic emission. *Journal of Physics E : Scientific Instruments*. 2000, t. 20, p. 946. Disp. à l'adr. DOI : [10.1088/0022-3735/20/8/001](https://doi.org/10.1088/0022-3735/20/8/001).
12. ZHANG, Fengqiao ; YANG, Yuguang ; NAAKTGEBOREN, Marius ; HENDRIKS, Max A.N. Probability density field of acoustic emission events : Damage identification in concrete structures. *Construction and Building Materials*. 2022, t. 327, p. 126984. ISSN 0950-0618. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.conbuildmat.2022.126984>.
13. KHARGHANI, Mehdi ; GOSHTASBI, Kamran ; NIKKHAH, Majid ; AHANGARI, Kaveh. Investigation of the Kaiser effect in anisotropic rocks with different angles by acoustic emission method. *Applied Acoustics*. 2021, t. 175, p. 107831. Disp. à l'adr. DOI : [10.1016/j.apacoust.2020.107831](https://doi.org/10.1016/j.apacoust.2020.107831).
14. SCHOFIELD, B. H. ACOUSTIC EMISSION UNDER APPLIED STRESS. 1963, t. 63, p. 509.
15. TATRO, C.A. Sonic techniques in the detection of crystal slip in metals. 1959, t. 1, p. 23-28.
16. DAHMENE, Fethi ; YAACOUBI, Slah ; EL MOUNTASSIR, Mahjoub. Acoustic Emission of Composites Structures : Story, Success, and Challenges. *Physics Procedia*. 2015, t. 70, p. 599-603. Disp. à l'adr. DOI : [10.1016/j.phpro.2015.08.031](https://doi.org/10.1016/j.phpro.2015.08.031).
17. GORMAN, Michael R. Plate wave acoustic emission. *The Journal of the Acoustical Society of America*. 1991, t. 90, n° 1, p. 358-364. ISSN 0001-4966. Disp. à l'adr. DOI : [10.1121/1.401258](https://doi.org/10.1121/1.401258).
18. SCOTT, I.G. *Basic Acoustic Emission*. Gordon et Breach Science Publishers, 1991. Nondestructive testing monographs and tracts. ISBN 9782881243523.
19. KHAN, Md. Structural Health Monitoring by Acoustic Emission Technique. In : 2018. ISBN 978-1-78923-787-0. Disp. à l'adr. DOI : [10.5772/intechopen.79483](https://doi.org/10.5772/intechopen.79483).
20. ONO, Kanji. Structural Health Monitoring of Large Structures Using Acoustic Emission—Case Histories. *Applied Sciences*. 2019, t. 9, n° 21. ISSN 2076-3417. Disp. à l'adr. DOI : [10.3390/app9214602](https://doi.org/10.3390/app9214602).
21. GALL, T. Le. *Simulation de l'émission acoustique : Aide à l'identification de la signature acoustique des mécanismes d'endommagement*. 2016. Thèse de doct.
22. KHALIFA, W. B. *Modélisation de la propagation et de la réception des ondes élastiques émises par un défaut sous contrainte. Application à la simulation des contrôles non destructifs par émission acoustique,* Thèse de doctorat de l'Université de Valenciennes et du Hainaut-Cambresis. 2013. Thèse de doct.
23. ONO, Kanji. Calibration Methods of Acoustic Emission Sensors. *Materials*. 2016, t. 9, p. 508. Disp. à l'adr. DOI : [10.3390/ma9070508](https://doi.org/10.3390/ma9070508).
24. LAMB, Horace Sir. On waves in an elastic plate. *Proceedings of The Royal Society A : Mathematical, Physical and Engineering Sciences*. 1917, t. 93, p. 114-128.

25. LAMB, Horace. On waves in an elastic plate. *Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character*. 1917, t. 93, n° 648, p. 114-128. Disp. à l'adr. DOI : [10.1098/rspa.1917.0008](https://doi.org/10.1098/rspa.1917.0008).
26. YADAV, Susheel ; BANERJEE, Sourav ; KUNDU, Tribikram. On sequencing the feature extraction techniques for online damage characterization. *Journal of Intelligent Material Systems and Structures*. 2013, t. 24, p. 473-483. Disp. à l'adr. DOI : [10.1177/1045389X12463466](https://doi.org/10.1177/1045389X12463466).
27. BARZEGAR, Mohsen ; PASADAS, Dario Jerónimo ; LOPES RIBEIRO, Artur ; RAMOS, Helena Geirinhas. Experimental Estimation of Lamb Wave Dispersion Curves for Adhesively Bonded Aluminum Plates, Using Two Adjacent Signals. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*. 2022, t. 69, n° 6, p. 2143-2151. Disp. à l'adr. DOI : [10.1109/TUFFC.2022.3164731](https://doi.org/10.1109/TUFFC.2022.3164731).
28. XIE, Qingnan ; NI, Chenyin ; SHEN, Zhonghua. Defects Detection and Localization in Underwater Plates Using Laser Laterally Generated Pure Non-Dispersive S0 Mode. *Applied Sciences*. 2019, t. 9, p. 459. Disp. à l'adr. DOI : [10.3390/app9030459](https://doi.org/10.3390/app9030459).
29. ROSE, J.L. *Ultrasonic Waves in Solid Media*. Cambridge University Press, 1999. Ultrasonic Waves in Solid Media. ISBN 9780521548892.
30. BONIFACE, Antoine. *Détection et évaluation de l'endommagement mécanique du béton par émission acoustique*. 2017. Thèse de doct.
31. A. COHEN, R.D. Ryan. *Wavelets and Multiscale Signal Processing*. Chapman et Hall, London, 1995.
32. STRANG, G. ; NGUYEN, T. *Wavelets and Filter Banks*. Wellesley-Cambridge Press, 1996. ISBN 9780961408879.
33. GABRIELLI, F. *Apport des techniques temps-fréquence à la caractérisation mécanique du corps humain en choc*. Université de la Méditerranée Aix marseille II, 2010. Thèse de doct.
34. MALLAT, S. *A Wavelet Tour of Signal Processing*. Elsevier Science, 1999. Wavelet Tour of Signal Processing. ISBN 9780080520834.
35. COHEN, L. The scale representation. *IEEE Transactions on Signal Processing*. 1993, t. 41, n° 12, p. 3275-3292. Disp. à l'adr. DOI : [10.1109/78.258073](https://doi.org/10.1109/78.258073).
36. RILLING, G. *Décompositions Modales Empiriques : Contributions à la théorie, l'algorithme et l'analyse de performances*. Thèse de doctorat, Université de Lyon, 2007. Thèse de doct.
37. LE, Thien-Phu ; ARGOUL, Pierre. Continuous wavelet transform for modal identification using free decay response. *Journal of Sound and Vibration*. 2004, t. 277, n° 1, p. 73-100. ISSN 0022-460X. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.jsv.2003.08.049>.

38. DRIS, El yamine; DRAI, R.; BENTAHAR, M.; BERKANI, D.; BENAMMAR, A. Comparative study between EKF and Geometrical methods for the Acoustic Emission source localization. *Procedia Computer Science*. 2019, t. 148, p. 438-447. ISSN 1877-0509. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.procs.2019.01.056>. THE SECOND INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING IN DATA SCIENCES, ICDS2018.
39. XU, Longtao; WANG, Yi-Shou; CAI, Yongchao; WU, Zhanjun; PENG, Weibin. Determination of impact events on a plate-like composite structure. *The Aeronautical Journal*. 2016, t. -1, p. 1-21. Disp. à l'adr. DOI : [10.1017/aer.2016.36](https://doi.org/10.1017/aer.2016.36).
40. MEO, M.; ZUMPANO, G.; PIGGOTT, M.; MARENGO, G. Impact identification on a sandwich plate from wave propagation responses. *Composite Structures*. 2005, t. 71, n° 3, p. 302-306. ISSN 0263-8223. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.compstruct.2005.09.028>. Fifth International Conference on Composite Science and Technology.
41. SOUZA, Pablo; NOBREGA, Euripedes. A Fault Location Method Using Lamb Waves and Discrete Wavelet Transform. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*. 2012, t. 34, p. 515-524. Disp. à l'adr. DOI : [10.1590/S1678-58782012000400013](https://doi.org/10.1590/S1678-58782012000400013).
42. GOSWAMI, J.C.; CHAN, A.K. *Fundamentals of Wavelets : Theory, Algorithms, and Applications*. Wiley, 2011. Wiley Series in Microwave and Optical Engineering. ISBN 9780470934647.
43. LI, Fucai; MENG, Guang; KAGEYAMA, Kazuro; SU, Zhongqing; YE, Lin. Optimal Mother Wavelet Selection for Lamb Wave Analyses. *Journal of Intelligent Material Systems and Structures - J INTEL MAT SYST STRUCT*. 2009, t. 20, p. 1147-1161. Disp. à l'adr. DOI : [10.1177/1045389X09102562](https://doi.org/10.1177/1045389X09102562).
44. BRACEWELL, R.N. *The Fourier Transform and Its Applications*. McGraw Hill, 2000. Electrical engineering series. ISBN 9780073039381.
45. FITCH, Frederic B. Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, vol. 5 (1943), pp. 115-133. *The Journal of Symbolic Logic*. 1944, t. 9, n° 2, p. 49-50. Disp. à l'adr. DOI : [10.2307/2268029](https://doi.org/10.2307/2268029).
46. HEBB, D.O. *The Organization of Behavior : A Neuropsychological Theory*. Taylor & Francis, 2005. ISBN 9781135631918.
47. PARHI, Keshab; UNNIKRIISHNAN, Nanda. Brain-Inspired Computing : Models and Architectures. *IEEE Open Journal of Circuits and Systems*. 2020, t. 1, p. 185-204. Disp. à l'adr. DOI : [10.1109/OJCAS.2020.3032092](https://doi.org/10.1109/OJCAS.2020.3032092).
48. RUMELHART, David E.; DURBIN, Richard; GOLDEN, Richard; CHAUVIN, Yves. Backpropagation : The Basic Theory. In : *Backpropagation : Theory, Architectures, and Applications*. USA : L. Erlbaum Associates Inc., 1995, p. 1-34. ISBN 0805812598.

49. HOPFIELD, John. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the United States of America*. 1982, t. 79, p. 2554-8. Disp. à l'adr. DOI : [10.1073/pnas.79.8.2554](https://doi.org/10.1073/pnas.79.8.2554).
50. RUMELHART, David E. ; HINTON, Geoffrey E. ; WILLIAMS, Ronald J. Learning representations by back-propagating errors. *Nature*. 1986, t. 323, p. 533-536.
51. KIRANYAZ, Serkan ; AVCI, Onur ; ABDELJABER, Osama ; INCE, Turker ; GABBOUJ, Moncef ; INMAN, Daniel J. 1D convolutional neural networks and applications : A survey. *Mechanical Systems and Signal Processing*. 2021, t. 151, p. 107398. ISSN 0888-3270. Disp. à l'adr. DOI : <https://doi.org/10.1016/j.ymsp.2020.107398>.
52. KIRANYAZ, Serkan ; INCE, Turker ; RIDHA, Hamila ; GABBOUJ, Moncef. Convolutional Neural Networks for Patient-Specific ECG Classification. In : 2015, t. 2015. Disp. à l'adr. DOI : [10.1109/EMBC.2015.7318926](https://doi.org/10.1109/EMBC.2015.7318926).
53. KIRANYAZ, Serkan ; GASTLI, Adel ; BEN-BRAHIM, L. ; ALEMADI, Nasser ; GABBOUJ, Moncef. Real-Time Fault Detection and Identification for MMC Using 1-D Convolutional Neural Networks. *IEEE Transactions on Industrial Electronics*. 2018, t. PP, p. 1-1. Disp. à l'adr. DOI : [10.1109/TIE.2018.2833045](https://doi.org/10.1109/TIE.2018.2833045).
54. EREN, Levent. Bearing Fault Detection by One Dimensional Convolutional Neural Networks. *Mathematical Problems in Engineering*. 2017, t. 2017. Disp. à l'adr. DOI : [10.1155/2017/8617315](https://doi.org/10.1155/2017/8617315).
55. HAYKIN, S.S. *Neural Networks : A Comprehensive Foundation*. Prentice Hall, 1999. International edition. ISBN 9780132733502.
56. NIELSEN, A. *Acoustic Emission Source Based on Pencil Lead Breaking*. 1980. Publication : Svejsecentralen.
57. JEONG, Hyunjo ; JANG, Young-Su. Fracture source location in thin plates using the wavelet transform of dispersive waves. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*. 2000, t. 47, n° 3, p. 612-619. Disp. à l'adr. DOI : [10.1109/58.842048](https://doi.org/10.1109/58.842048).
58. PHAM, Duc Truong ; PHAM, P. T. N. Artificial intelligence in engineering. *International Journal of Machine Tools & Manufacture*. 1999, t. 39, p. 937-949.