

Caractérisation non-destructive de joints collés utilisant des réseaux de neurones convolutives sur des ondes guidées Lamb

par

Clément EISERLOH

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAITRISE
AVEC MÉMOIRE EN GÉNIE DE LA PRODUCTION AUTOMATISÉE
M. Sc. A

MONTRÉAL, LE 04 DECEMBRE 2022

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Clément Eiserloh, 2022



Cette licence [Creative Commons](https://creativecommons.org/licenses/by-nc-nd/4.0/) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY
CE RAPPORT DE MÉMOIRE A ÉTÉ ÉVALUÉ
PAR UN JURY COMPOSÉ DE :

Pierre Bélanger, directeur de mémoire
Département de génie mécanique à l'École de technologie supérieure

Matthew Toews, codirecteur de mémoire
Département de génie des systèmes à l'École de technologie supérieure

Ricardo Zednik, président du jury
Département de génie mécanique à l'École de technologie supérieure

Lucas Hof, membre du jury
Département de génie mécanique à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 11/11/2022

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens tout d'abord à remercier ceux qui ont rendu ce projet possible, mon directeur de recherche Pierre Bélanger qui m'a accompagné et aiguillé durant ses deux années à l'ETS. Mon co-directeur Matthew Toews qui m'a donné de bons conseils. Également, la chair de recherche avec Olympus NDT, avec qui le projet était en collaboration, en particulier Guillaume et Alain qui ont été présents chaque semaine lors de nos rencontres pour me conseiller. Et enfin, Daniel Pereira, qui est le postdoctorant qui a travaillé avant moi sur ce projet, il m'a apporté toutes les connaissances nécessaires pour prendre en main le projet.

Je remercie tous les membres du PULETS qui m'ont également beaucoup apporté et se sont toujours rendus disponibles lorsque j'en avais besoin, merci à Baptiste, Aubin, Nathan, Aurélien, Sevan.

Je tiens à remercier tout particulièrement ma famille et surtout mes parents qui m'ont soutenu dans ce choix de partir au Canada. Pour terminer mes études ici. Et malgré la distance d'avoir toujours était présent.

Enfin, je tiens à remercier mes amis ici à Montréal, en particulier, Arthur, Paul, Valentin, pour cette année de vie commune et tous ses bons moments.

Caractérisation non-destructive de joints collés utilisant des réseaux de neurones convolutifs sur des ondes guidées Lamb

Clément EISERLOH

RÉSUMÉ

Il y a une forte sollicitation des industries pour développer des assemblages collés, cette demande est engendrée par les nombreux avantages que peuvent proposer les joints collés. Par exemple, une très bonne résistance aux contraintes mécaniques, la réduction des coûts ou encore l'esthétisme. Cependant, il n'existe actuellement aucune méthode non destructive permettant de garantir et de quantifier la qualité d'un assemblage collé. En effet, les solutions utilisées sont principalement des approches destructives, comme l'application de joint de recouvrement. Ainsi, le but de ces travaux est de mettre en place une méthode capable de reconnaître le niveau d'adhésion d'un assemblage collé. Pour cela, des acquisitions ultrasonores ont été utilisées, les échantillons ont été excités avec des ondes guidées afin d'obtenir les différents modes. Ensuite, l'analyse des courbes de dispersion propre à chaque assemblage, permet l'identification des paramètres mécaniques. Pour effectuer ce travail, un réseau de neurones a été mis en place, celui-ci se base sur des données simulées d'assemblage collées avec une méthode par éléments finis. Puis il a été testé sur des courbes de dispersion expérimentales afin de déterminer les caractéristiques réelles du joint. L'étude est principalement guidée sur l'estimation du module d'Young, que l'on considère comme une image fiable de la qualité du joint. Premièrement, les résultats sont satisfaisants sur les données simulées, une prédiction du module d'un assemblage est réalisée avec une erreur inférieure à 0,05 % sur l'ensemble de la base de données test. Ensuite, de bons résultats ont été obtenus lors du suivi d'un joint collé pendant son séchage. Enfin, pendant l'inversion d'acquisitions sur cinq joints réels, les estimations ont permis de différencier et de classer ces joints en fonction de leurs propriétés de collage. Dans un premier temps, le réseau n'a pas pu se stabiliser sur des estimations correctes, puis la mise en place d'un double réseau de neurones convolutifs a réussi à identifier la qualité des joints. Ils ont été réalisés par le CNRC qui a une expertise dans ce type de fabrication, et également ils peuvent concevoir des joints volontairement faibles. Ces résultats sont intéressants, mais il faut tout de même rester modéré. Puisqu'il s'agit uniquement de cinq échantillons qui ont la même géométrie, de plus, lorsque la FFT2D estimée par le réseau est superposée à la FFT2D acquise les courbes de dispersion ne se chevauchent pas totalement. Il réside des défauts à basse fréquence. Finalement, l'étude montre qu'il est possible de réaliser l'inversion par réseau de neurones convolutifs d'un joint collé en se basant sur des ondes guidées. Cela fonctionne lorsqu'il s'agit de déterminer des paramètres mécaniques réels, par exemple le module d'Young. Cette étude met en lumière que cela fonctionne sans doute avec des aspects plus abstraits comme la qualité globale du joint.

Mots-clés : Joints collés, adhésif, caractérisation, réseaux de neurones, convolutions, ondes Lamb, transformée de Fourier

Non-Destructive Testing of Bonded Joints Using Guided Lamb Ultrasound Waves Convolutional Neural Networks and Machine Learning

Clément EISERLOH

ABSTRACT

Bonded joints are currently being developed in a wide range of industries. These joints offer numerous advantages such as a very good mechanical resistance, cost reduction and they have an aesthetic asset. However, currently there are no nondestructive method to guarantee and quantify the quality of a bonded joint. Indeed, the current solutions are mainly destructive solutions, such as the use of overlap joints. Thus, the aim of this project is to develop a method which allows identifying the adhesion level of a bonded joint. Ultrasonic acquisition were used, the sample were excited with ultrasonic guided waves in order to obtain the different modes. Then, the analysis of the dispersion curves allows the identification of the mechanical parameters. In this project an algorithm capable of identifying the mechanical characteristics based on dispersion curves was developed. For this work, a neural network was implemented, it was trained on finite element simulations of wave propagation in bonded joints. Then, it was tested on experimental data to determine the real characteristic of the joint. The main hypothesis in this work is that the simulated Young's modulus of the adhesive can be used to estimate the quality of the joint. The results obtained in simulations were promising: the estimation of the modulus of the adhesive of a joint was achieved with an error under 0.05 % on the whole test dataset. Then, more promising results were obtained when monitoring a bonded joint during curing. Finally, when inverting acquisitions on five real joints, the estimates allowed to differentiate and classify the samples according to their bonding quality. At first, the network failed to stabilize on correct estimates, then the implementation of a double network allowed to identify the quality of the joints. These joints were made by CNRC which has expertise in the manufacture of bonded joints, and also, the can manufacture joints voluntarily weak. Although those results were promising, it is important to point out the weak aspects of the method. Firstly, only five joints with the same geometry were used in this study. Secondly, when comparing the experimental dispersion curves with the dispersion curves predicted by the inversion method some discrepancies could be observed. Finally, this study shows that it is possible to perform an inversion of bonded joints with convolution neural network based on ultrasonic guided waves to determine their mechanical properties such as the Young's modulus. This study also showed that the method was also able to evaluate more abstract aspect such as overall joint adhesion.

Keywords : Bonded joint, adhesives, characterization, neural networks, convolutions, Lamb waves, Fourier transform

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE.....	3
1.1 Les joints collés.....	3
1.1.1 Descriptions et principales applications.....	3
1.1.2 Analyses des contraintes	4
1.1.3 Fabrication de joint de recouvrement	5
1.1.4 Nécessité de mettre en place une méthode non destructive.....	6
1.2 Ondes Guidées Ultrasonores.....	7
1.2.1 Principes fondamentaux des ondes ultrasonores.....	7
1.2.2 Équations de propagation d'une onde.....	8
1.2.3 Ondes de Lamb	10
1.2.4 Les ondes de Lamb pour inspecter un assemblage collé.	11
1.3 Réseaux de neurones.....	12
1.3.1 Fonctionnement d'un réseau de neurones.....	14
1.3.2 Réseau de neurones convolutifs.....	15
1.3.3 Architecture d'un CNN.....	16
1.3.4 Les architectures de réseaux efficaces	18
1.3.5 Les réseaux de neurones utilisés pour résoudre des problèmes d'inversion d'onde guidées	20
CHAPITRE 2 METHODOLOGIE.....	23
2.1 Descriptif de la méthode	Erreur ! Signet non défini.
2.2 Fabrication de joints collés	23
2.2.1 Réalisation d'une première série de joints.	23
2.2.2 Réalisation de tests sur des joints à recouvrement simple	25
2.2.3 Inspection de nos échantillons	26
2.3 Méthode d'acquisition	29
2.3.1 Description de la méthode d'acquisition.....	29
2.3.2 Acquisitions bruitées.....	33
2.4 Réseaux de neurones : méthode d'inversion.....	35
2.4.1 Explication du processus d'inversion	35
2.4.2 Base de données.....	36
2.4.2.1 Les simulations	36
2.4.2.2 Description des données	38
2.4.3 Description du réseau de neurones	39
2.4.3.1 Type de réseau utilisé.....	39
2.4.3.2 Choix du réseau de neurones	40
2.4.4 Structure des bases de données	41
2.4.5 Variation des hyper paramètres	41
2.4.6 Modèle réseau de neurones à plusieurs sorties.	42

2.4.7	Concentration de l'attention du réseau de neurones sur un aspect de l'image	43
2.4.8	Construction d'un double réseau de neurones	45
CHAPITRE 3	RESULTATS	47
3.1	Résultats préliminaires.....	47
3.1.1	Validation de l'entraînement du réseau sur les données simulées.....	47
3.1.2	Comparaisons des différentes architectures.....	50
3.1.3	Expériences sur des plaques collées durant le durcissement	53
3.2	Résultats sur les joints collés du CNRC.....	54
3.2.1	Données du CNRC.....	54
3.2.2	Résultat avec la méthode 1 ; analyse statistique des acquisitions.....	56
3.2.3	Résultats avec la deuxième méthode : superpositions des acquisitions....	62
3.2.3.1	Analyses des résultats	62
3.2.3.2	Études de l'inversion d'une partie de la FFT2D.....	66
3.2.3.3	Combinaison des deux méthodes, double réseau de neurones ..	69
3.2.3.4	Résultat sur l'échantillons T6	73
CHAPITRE 4	DISCUSSIONS.....	75
4.1	Bilan.....	75
4.2	Hypothèse pour améliorer nos résultats	76
CONCLUSION	81
ANNEXE I	ARCHITECTURE DES RÉSEAUX	83
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES.....		87

LISTE DES TABLEAUX

	Page
Tableau 3.1	Définition des architectures testées.....47
Tableau 3.2	Étude des traitements de surface des échantillons55
Tableau 3.3	Résultat de l'inversion sur la plaque numéros 157
Tableau 3.4	Résultats des moyennes des estimations des joints pour 100 entraînements63
Tableau 3.5	Résultat pour l'inversion d'une partie de la FFT2D66

LISTE DES FIGURES

	Page
Figure 1.1	Force appliquée sur un joint collé.....4
Figure 1.2	Géométrie Joint de recouvrement5
Figure 1.3	Onde de cisaillement longitudinale et transversale.....7
Figure 1.4	Exemple de filtre de convolution.....16
Figure 1.5	Exemple Max-Pooling17
Figure 1.6	Réseaux VGG19
Figure 1.7	Exemple CNN utilisé dans la référence21
Figure 2.1	Dimension des échantillons24
Figure 2.2	Single lap après le découpage.....25
Figure 2.3	Test de nos joints avec la méthode simple joint de recouvrement.....26
Figure 2.4	CT Scan échantillons collés.....27
Figure 2.5	Radiographie Joint collé28
Figure 2.6	Échantillons CNRC.....29
Figure 2.7	Set up expérimental et affichage d'une trace temporelle.....30
Figure 2.8	FFT2D brutes du vibromètre32
Figure 2.9	Données après les réajustements dimensionnels.....33
Figure 2.10	Donnée simulée (sans bruit).....33
Figure 2.11	Effets du recalibrage du laser.....34
Figure 2.12	Résultat d'une sommation de 7 acquisitions du même joint.....35
Figure 2.13	Schémas représentant le modèle utilisé en simulation.....37
Figure 2.14	Simulation courbe de dispersion.....38

Figure 2.15	Répartition des données	39
Figure 2.16	Structure basique de notre réseau de neurone.....	40
Figure 2.17	Architecture Convulsive du réseau LambWaveNet	41
Figure 2.18	Entraînement de réseau	42
Figure 2.19	Schémas réseaux à trois sorties.....	43
Figure 2.20	Affichage de six différentes images dans notre base de données	44
Figure 2.21	Caractérisation des zones plus ou moins importantes.....	45
Figure 2.22	Schématisation réseaux à deux entrées	46
Figure 3.1	Étude de la perte pendant l'entraînement.....	48
Figure 3.2	Répartition des erreurs en fonction du module d'Young.....	49
Figure 3.3	Étude des différentes architectures	51
Figure 3.4	Comparaison des erreurs entre LambWaveNet et VGG.....	52
Figure 3.5	Suivi du durcissement	53
Figure 3.6	Contrainte maximale admissible en fonction du traitement de surface	55
Figure 3.7	Exemple d'acquisition	56
Figure 3.8	FFT 2D mesuré superposé avec la FFT2D mesuré.....	58
Figure 3.9	Dans l'ordre les mesure de 2 à 7 avec leur superposition estimée.....	59
Figure 3.10	Superposition des mesures 2 à 7 avec l'estimation 1.....	61
Figure 3.11	Image de gauche : Acquisition simple. Image de droite : superposition de 7 acquisitions	62
Figure 3.12	Affichages des estimations pour 10 et pour 100 entraînements du réseau de neurones	63
Figure 3.13	Mesure des différents joints avec leurs estimations superposées	65
Figure 3.14	Superposition	67
Figure 3.15	Superposition de la totalité de l'image.....	67

Figure 3.16	Étude avec augmentation du filtrage sur la zone à 50 pixels.....	68
Figure 3.17	Données simulées correspondant à l'estimation du réseau.....	69
Figure 3.18	Estimation numérique du double réseau	70
Figure 3.19	Superposition des estimations.....	71
Figure 3.20	Comparaison des résultats avec ceux du CNRC.....	72
Figure 3.21	Acquisition partie gauche du joint T6, acquisition partie droite.....	73
Figure 3.22	Soustraction des FFT	74
Figure 4.1	Différence entre l'acquisition de la plaque T1 et T2	77
Figure 4.2	Résultat de la superposition de T1	78
Figure 4.3	Modélisation d'un joint collé.....	79

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

ASTM	American Society for Testing and Materials
CNRC	Centre National de Recherches Canada
CNN	Réseau de Neurone Convolutif
DenseNet	Dense Network
FFT2D	Fast Transformée de Fourier à Deux Dimension
FFT	Fast Transformée de Fourier
MAE	Mean Absolute Error
MSE	Mean Squared Error
ResNet	Residual Neural Network
T1	Échantillon collé du CNRC numéro 1
T2	Échantillon collé du CNRC numéro 2
T3	Échantillon collé du CNRC numéro 3
T4	Échantillon collé du CNRC numéro 4
T5	Échantillon collé du CNRC numéro 5
T6	Échantillon collé du CNRC numéro 6
VGG	Visual Geometry Group
1D	Une dimension
2D	Deux dimension
3D	Trois dimension

LISTE DES SYMBOLES ET UNITÉS DE MESURE

c	Vitesse de propagation
λ	Longueur d'onde
f	Fréquence
m	mètre
Pa	Pascal
s	seconde
dB	Décibel
g	gramme
Hz	Hertz
k	Nombre d'onde
ω	Vitesse angulaire
μ	Second degré de Lamé
ϕ	Potentiel scalaire
Ψ	Potentiel vectoriel

INTRODUCTION

L'assemblage par adhésion est de plus en plus envisagé dans l'industrie, en effet, il possède un grand nombre de qualités, comme une bonne résistance mécanique ou la réduction des contraintes locales. Effectivement, lorsque deux pièces sont collées, tous les processus d'assemblage habituels, tels que le perçage, le taraudage, les vissages, sont évités, cela engendre une diminution des coûts. Cependant, si l'utilisation de colle n'est pas systématique, c'est parce qu'il y a un manque de connaissance au niveau du contrôle du joint. Actuellement, il n'existe aucune méthode non destructive qui permet de dire si un joint est correctement collé et à quelle contrainte il peut résister (Adams, 2005).

Dans ce projet je tente de répondre à cette problématique. En vue des travaux qui ont déjà été réalisés sur le sujet, il y a de grandes chances que l'inspection par ultrasons puisse fournir les clés pour définir si un joint est correctement collé ou non. Le principe du projet est d'effectuer des acquisitions ultrasonores. Puis, mettre en place une méthode d'inversion, qui permettra de retrouver les caractéristiques mécaniques de notre joint. Elle sera basée sur des données simulées ayant différentes particularités. En ce sens, un réseau de neurones sera utilisé afin de déterminer quelle simulation correspond le mieux à l'acquisition.

De plus, ces travaux sont en collaboration avec l'entreprise Olympus NDT Canada. Ils ont commencé avant mon arrivée, le 2021-01-01, puisque le postdoctorant Daniel Pereira avait déjà fait des progrès sur une méthode d'inversion utilisant la minimisation d'une fonction coût.

Pour répondre à cette problématique, dans un premier temps une revue de la littérature de notre sujet a été effectuée, explorant des articles scientifiques utilisant les ondes guidées et des méthodes d'apprentissages profonds. Dans un deuxième temps, la méthodologie a été développée. Troisièmement, les résultats ont été exposés et enfin les aspects positifs du projet et les pistes d'amélioration ont été exposés.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Les joints collés

Depuis longtemps, l'homme maîtrise et utilise les adhésifs pour résoudre des problèmes. Un adhésif est défini comme un élément qui, lorsqu'il est appliqué à la surface de matériaux, les assemble et résiste à leur séparation. Les premiers signes d'industrialisation de colle remontent au 19^e siècle, souvent basé sur des colles d'origine animale ou végétale. C'est dans les années 1950 que ces procédés vont exploser, avec l'arrivée des adhésifs synthétiques, dont le premier était le Phenol-formaldehydes. Puis, le développement des adhésifs époxy rend la méthode d'assemblage populaire dans les principaux domaines de l'industrie tels que l'automobile, l'aéronautique et l'électronique (Adams, 2005).

1.1.1 Descriptions et principales applications

Les adhésifs ont pour but de fixer deux matériaux ensemble et de transférer la charge de l'un à l'autre. Ils sont caractérisés par une période de durcissement. Ils rendent cette adhésion possible grâce aux forces de Van der Waals, qui lient les atomes aux molécules entre eux. Ils sont très utilisés, car ils permettent l'assemblage de nombreux matériaux de même nature ou de natures différentes (comme dans les structures composites, qui sont un atout important dans la mécanique actuelle). De plus, les colles permettent une répartition uniforme des contraintes, contrairement à un assemblage plus classique qui utilise la méthode localisée (vis, écrous, rivets). Ainsi, l'absence de trou ou de formage peut être un atout esthétique, utile dans nombre d'industries comme l'automobile. Mais on retrouve aussi l'utilisation de colle pour sa fiabilité et ses bonnes propriétés mécaniques, dans l'aérospatiale (Adams, 2005).

1.1.2 Analyses des contraintes

Les adhésifs ont une bonne résistance aux contraintes mécaniques, ils transmettent la charge d'un substrat à l'autre. Cependant, il est nécessaire d'avoir une méthode capable de quantifier ces performances. Tout d'abord, il faut identifier quels types de contraintes sont présentes dans un assemblage collé. Dans le cas d'un joint en deux dimensions, figure 1.1, trois types de sollicitations apparaissent. Il y a la force axiale, la force de cisaillement et un moment de flexion. La première résulte de l'extension ou de la compression d'un des matériaux, la force de cisaillement correspond à un glissement. Et le moment à un mouvement angulaire d'une des pièces.




Figure 1.1 Force appliquée sur un joint collé

Pour examiner un adhésif à ses différentes sollicitations, un des essais les plus populaires est le test du joint à recouvrement simple. Il consiste à coller une éprouvette de façon similaire à la figure 1.2 et d'effectuer un test de traction en tirant sur chacun de ses côtés. Ce test va principalement faire travailler l'adhésif en cisaillement. Mais les études ont montré que comme l'échantillon n'est pas symétrique, il fait intervenir des composantes de traction et des moments de flexion. En le réalisant, on obtient une image de ces différentes composantes (Benhamena, Djebli, Aminallah, & Aid, 2016). Cet article étudie une méthode par élément fini déterminant les relations entre les contraintes de cisaillement et de pelage qui sont présentes lors du test de joint à recouvrement. C'est pourquoi dans ce projet ce test sera pris en référence et des échantillons de cette même géométrie seront construits. Sans oublier que celui-ci ne mesure

qu'un aspect du collage. Il faudra réaliser d'autres essais pour obtenir plus d'informations sur le joint, telles que la durabilité, la fatigue, la résistance aux impacts, effets des vibrations.




Figure 1.2 Géométrie Joint de recouvrement

1.1.3 Fabrication de joint de recouvrement

La fabrication de joint de recouvrement et d'assemblage collé en général représente un important défi. En effet, chaque assemblage est unique, le processus de collage est très complexe. Il demande une grande expertise pour éviter tous les problèmes qui y sont liés, comme une mauvaise préparation de la surface, une surface contaminée, une dégradation de l'adhésif, une contamination, ou encore un adhésif âgé. Par ailleurs (Dennis Roach, Rackow, & Duvall, 2010), dans cet article, l'auteur a conçu des échantillons collés volontairement faibles. Il a proposé différentes méthodes pour les réaliser, tel qu'ajouté de l'huile sur la surface, ou encore ne pas dégraisser l'adhérent. Ainsi, travailler sur des joints collés nécessite d'être rigoureux. La fabrication de ce type d'assemblage demande une expertise, car rien ne sera prouvé si une qualité de joint n'est pas garantie au préalable.

1.1.4 Nécessité de mettre en place une méthode non destructive

L'industrie est désireuse d'utiliser des joints collés et leurs fabrications doivent être minutieuses. Or, la caractérisation d'un tel assemblage est compliquée. Ainsi, la nécessité de méthode de contrôle non destructive est alors inévitable. En effet, pendant longtemps un joint était garanti en réalisant une copie et en la détruisant, tel que la méthode des joints de recouvrement, les joints de peel ou encore les joints de scarf (Gacoin, Lestriez, Assih, Objois, & Delmas, 2009 ; Grant, Adams, & da Silva, 2009). Or, ces solutions imposent forcément des coûts, mais en aucun cas elles ne garantissent que les assemblages testés sont semblables aux réels, et elles ne répondent pas au critère de maintenance.

Beaucoup de paramètres peuvent dégrader un collage. Il faut alors une méthode capable de vérifier de façon non destructive si un joint est sain ou non. Dans la littérature actuelle, nombre de propositions existent. Des procédés comme la thermographie ont exposé d'excellents résultats dans des géométries complexes (X. Li, Sun, & Tao, 2018; Lizaranzu, Lario, Chiminelli, & Amenabar, 2015). Également, l'inspection optique a été testée sur des éprouvettes collées pour détecter des défauts (Willemann, Fantin, & Albertazzi, 2010). Par ailleurs, beaucoup d'application se tourne vers l'inspection par ultrasons. Ces méthodes ont montré de bonnes performances dans le domaine. En effet, aujourd'hui il est possible de déterminer si un échantillon est collé à 100 % de la surface souhaitée, ou s'il y a présence d'un corps étranger dans l'assemblage (en faisant un C-Scan par ultrasons [Roach et al., 2010]). Le module d'Young du joint peut être estimé pendant toute la durée de séchage, en utilisant les ondes guidées (Fan, Castaings, Lowe, Biateau, & Fromme, 2013 ; Pereira, Le Duff, Painchaud-April, & Belanger, 2022).

En outre, aucune méthode actuelle est capable de valider toutes les caractéristiques d'un assemblage collé, surtout il n'est pas possible d'obtenir les propriétés mécaniques que nous donne le test de joint à recouvrement. Il n'existe pas de tests non destructifs pour accéder à ces données. C'est ce qui sera tenté dans la suite du projet, pour cela on s'intéressera plus en détail aux ondes ultrasonores et aux techniques de méthodes non destructives.

1.2 Ondes Guidées Ultrasonores

Tout d'abord, la physique des ondes ultrasonore sera étudiée, pour comprendre le fonctionnement des ondes guidées ultrasonores. Elles ont beaucoup été étudiées, il existe plusieurs ouvrages de référence qui résument très bien la théorie sur ce sujet (Cheeke & David, 2002 ; Rose, 1999)

1.2.1 Principes fondamentaux des ondes ultrasonores

Les ondes ultrasonores sont des ondes mécaniques qui se propagent dans un milieu élastique, c'est-à-dire qu'elle répand une contrainte mécanique dans l'espace. Leurs déplacements ne peuvent se faire dans le vide. Elles sont définies sur une plage de fréquence 20 kHz jusqu'à 1 GHz, les ondes guidées balayent des fréquences aux alentours de 200 kHz et la microscopie acoustique balaye des fréquences de 10 MHz à 400 MHz (C. F. Quate, A. Atalar, & H. K. Wickramasinghe, 1979). Une onde est définie par sa direction, sa fréquence f et sa longueur d'onde λ . La vitesse de propagation est définie par : $c = f \times \lambda$.

Il existe plusieurs types d'ondes. Dans un solide infini, deux types de propagations sont observés. L'onde longitudinale ou onde de compression, elle a la particularité d'avoir une déformation parallèle à l'axe de propagation. L'onde transversale ou onde de cisaillement a une perturbation perpendiculaire à l'axe de propagation. Ces dernières se distinguent par leur ace de polarisation.




Figure 1.3 Onde de cisaillement longitudinale et transversale

1.2.2 Équations de propagation d'une onde

Dans ce chapitre, les principales équations régissant la propagation des ondes sont énoncées. Les ondes sont étudiées depuis très longtemps et des équations bien définies régissent leurs comportements. Tout d'abord, l'équation d'Alembert régit le déplacement d'une onde à une dimension.

$$\frac{\partial^2 u}{\partial x^2} = \frac{1}{c^2} \frac{\partial^2 u}{\partial t^2} \quad (1.1)$$

Cette équation possède une solution qui peut s'écrire :

$$u = Af\left(x - \frac{t}{c}\right) + Bg\left(x + \frac{t}{c}\right) \quad (1.2)$$

Où f représente un signal se propageant dans la direction (Ox) dans le sens négatif et g dans le sens positif.

Les équations à une dimension sont une approche simple pour comprendre et manipuler les ondes. Dans le cadre d'une perturbation sinusoïdale, on a :

$$u(x, t) = A \cos(\omega t - kx) \quad (1.3)$$

Avec la vitesse angulaire ω et le nombre d'onde k . Ensuite, on a le cas d'une propagation dans un solide en trois dimensions :

$$\rho \frac{\partial^2 \vec{u}}{\partial t^2} = (c_{11} - c_{44}) \vec{\nabla} (\vec{\nabla} \cdot \vec{u}) + c_{44} \vec{\nabla}^2 \vec{u} \quad (1.4)$$

Avec, c_{11} et c_{44} qui découle directement de la matrice de rigidité du solide. Ces arguments s'expriment en fonction des coefficients de Lamé λ et μ .

$$c_{11} = \lambda + 2\mu \quad (1.5)$$

$$c_{44} = \mu \quad (1.6)$$

Par ailleurs, l'équation de mouvement peut s'écrire également :

$$\vec{u} = \vec{\nabla} \phi + \vec{\nabla} \times \vec{\Psi} \quad (1.7)$$

Ainsi, le déplacement est décomposé comme un scalaire ϕ et un vecteur $\vec{\Psi}$. En utilisant l'identité de Helmholtz et en soustrayant l'équation de mouvement, on obtient :

$$\rho \frac{\partial^2 \phi}{\partial t^2} = c_{11} \nabla^2 \phi \quad (1.8)$$

$$\rho \frac{\partial^2 \vec{\Psi}}{\partial t^2} = c_{44} \nabla^2 \vec{\Psi} \quad (1.9)$$

Ici, la première équation peut être considéré comme régissant le comportement des ondes longitudinales et la seconde comme celui des ondes transverses.

De plus on remarque,

$$\vec{u}_L = \nabla \phi, \quad \vec{\nabla} \times \vec{u}_L \equiv 0 \quad (1.10)$$

$$\vec{u}_T = \vec{\nabla} \times \vec{\Psi}, \quad \vec{\nabla} \times \vec{u}_T \equiv 0 \quad (1.11)$$

L'égalité de l'équation (1.10) montre une invariance de volume, ce qui est cohérent avec une onde longitudinale. Et l'équation (1.11) correspond à une invariance au niveau de la rotation, ce qui s'identifie effectivement avec une onde transverse.

Et donc finalement on arrive à découpler notre système et on obtient :

$$\frac{\partial^2 \vec{u}_L}{\partial t^2} = V_L^2 \nabla^2 \vec{u}_L, \quad \frac{\partial^2 \vec{u}_T}{\partial t^2} = V_T^2 \nabla^2 \vec{u}_T \quad (1.12)$$

1.2.3 Ondes de Lamb

Les ondes de Lamb sont un cas particulier des ondes de volume. C'est lorsque l'épaisseur n'est pas infinie. On considère une épaisseur égale à b et que le ratio λ/b n'est pas nulle. Elles sont contenues dans le plan de propagation de l'onde. Elles sont induites par les ondes longitudinales et les ondes transverses verticales. Les modes de propagations sont classés en deux familles relatives aux symétries du champ de déplacement dans l'épaisseur de la plaque. On distingue les modes symétriques S_n et les antisymétriques A_n où n définit l'ordre du mode. Les vitesses d'incidence sont définies comme ceci :

$$k^2 = k_x^2 + k_y^2 + k_z^2 = \frac{\omega^2}{V_S^2} \quad (1.13)$$

$$k^2 = k_x^2 + k_y^2 + k_z^2 = \frac{\omega^2}{V_S^2} \quad (1.14)$$

Et on obtient les équations de Rayleigh-Lamb :

$$\frac{\tan\left(k_{ls}\frac{b}{2}\right)}{\tan\left(k_{tl}\frac{b}{2}\right)} = -\frac{4\beta^2 k_{tl} k_{ts}}{(k_{ts}^2 - \beta^2)^2} \quad (1.15)$$

$$\frac{\tan\left(k_{ts}\frac{b}{2}\right)}{\tan\left(k_{tl}\frac{b}{2}\right)} = -\frac{(k_{ts}^2 - \beta^2)^2}{4\beta^2 k_{tl} k_{ts}} \quad (1.16)$$

Avec β étant le nombre d'onde selon l'axe de propagation, k_{tl} selon le mode longitudinal et k_{ts} selon la composante de cisaillement.

Dans le cas particulier de mode symétrique S_0 et antisymétrique A_0 on a :

$$\frac{\tan\left(k_{ls}\frac{b}{2}\right)}{\tan\left(k_{tl}\frac{b}{2}\right)} = 0 \quad (1.17)$$

$$\frac{\tan\left(k_{ts}\frac{b}{2}\right)}{\tan\left(k_{tl}\frac{b}{2}\right)} = -\infty \quad (1.18)$$

Le système d'équation n'a pas de solution analytique, ainsi, il est nécessaire d'utiliser un solveur pour visualiser les différents modes des ondes Lamb, tel que Disperse ou Civa (Pavlakovic, Lowe, Alleyne, & Cawley, 1997).

1.2.4 Les ondes de Lamb pour inspecter un assemblage collé.

Il est important de rappeler que ce projet est d'abord une collaboration avec un étudiant en postdoctorat, Daniel Pereira, qui avait préalablement travaillé le sujet et avait d'ailleurs rédigé deux articles. Le premier (Pereira & Belanger, 2019) étudie l'inversion d'une éprouvette collée utilisant une fonction de cout, basé sur des simulations obtenues avec une méthode semi-analytique. Le second (Pereira et al., 2022) traite toujours de l'inversion d'un joint collé en employant les ondes guidées. L'article énonce que l'adhésion entre l'adhérent et la colle a une influence sur les modes des courbes de dispersion. Il aimerait que la méthode d'inversion soit capable de quantifier les caractéristiques mécaniques de façon systématique et sans connaissances prédéfinies sur l'échantillon. Il va permettre le suivi du durcissement d'une résine époxy. Pour cela, le module de cisaillement est estimé à partir des courbes de dispersion acquis sur l'échantillon. Elles sont comparées à des FFT théoriques et une fonction de cout réalise l'inversion et permet l'identification du module de cisaillement. Ainsi, les auteurs peuvent suivre le durcissement d'une éprouvette collé au cours du temps.

Une autre application est la quantification du niveau d'adhésion. Dans l'article (Gauthier, El-Kettani, Galy, Predoic, & Leduc, 2020), différents échantillons collés sont fabriqués avec une qualité différente. À l'aide des ondes guidées Lamb, l'inversion est réalisée pour déterminer quel joint est le mieux collé. Pour ce faire, trois préparations de collage différentes sont adoptées : la première, un simple dégraissage, la deuxième, un dégraissage suivi d'un traitement de salinisation (qui consiste à tremper dans l'acide la plaque d'aluminium du joint, pour créer plus d'adhérence). Et la dernière, une opération de dégraissage suivie par l'ajout

d'un démoulant industriel, qui a pour but de réduire considérablement l'adhésion. Ensuite, des acquisitions de courbes de dispersion sont effectuées en utilisant la même méthode que dans ce projet, c'est-à-dire l'utilisation d'une sonde piézoélectrique en émission et en réception un vibromètre laser. Ensuite, des FFT obtenus sont comparés avec d'autres simulés. Les signaux simulés sont superposés avec les expérimentaux. Des différences dans les courbes de dispersion sont observées, et les auteurs réussissent à quantifier les joints. Ainsi, cette étude apporte qu'il est possible de visualiser des différences de qualité de collage avec notre méthode d'acquisition, et qu'il est possible de superposer un modèle théorique venant vérifier cela.

L'article (Wojtczak & Rucka, 2021) traite en particulier l'analyse du temps de séchage d'un joint collé. L'intérêt pour cet article est qu'il a beaucoup de similitudes avec ce travail. En premiers lieux, ils étudient le temps de cuisson d'un époxy, dans un système 3 couches, à savoir deux couches d'acier avec une couche d'adhésif. Les auteurs vont également utiliser une méthode qui nous concerne beaucoup, l'acquisition de courbes de dispersion des plaques collées à l'aide d'onde guidée Lamb. Pour cette acquisition, un dispositif expérimental identique au nôtre avec un vibromètre laser sera mis en place. D'excellents résultats sont obtenus, ils réussissent à suivre le séchage de l'époxy, et estimer une valeur de module d'Young avec une erreur inférieure à 10 % à la valeur finale estimée pour cette colle. Ils ont réussi à avoir une très bonne superposition de leurs courbes de dispersion estimées avec celles analytiques même sur les modes S_0 et A_0 . Ils ont d'ailleurs également remarqué que ces modes sont les plus impactés visuellement pour un changement du module d'Young de l'adhésif.

Maintenant qu'il a été prouvé que les ondes ultrasonores permettent d'obtenir l'information sur la qualité d'un joint collé, il faut s'intéresser à la méthode d'inversion, ce qui implique des réseaux de neurones.

1.3 Réseaux de neurones

On souhaite résoudre un problème d'inversion en utilisant un réseau de neurones. Cependant, il faut d'abord définir son fonctionnement et comment il pourrait permettre d'accomplir cette

inversion. Tout d'abord, les réseaux de neurones artificiels sont inspirés de ce qui est observé chez l'homme. Les premiers travaux sur les neurones artificiels ont été réalisés par Frank Rosenblatt en 1953, il était le premier à utiliser des réseaux totalement connectés. Le réseau est un algorithme d'apprentissage, il apprend à reproduire des exemples étiquetés via l'algorithme de rétropropagation de gradient (Rumelhart, McClelland, & PDP Research Group, 1988). Par exemple, en reconnaissance faciale, le réseau va s'entraîner à reconnaître les visages d'une personne dans une base de données, pour être capable de la reconnaître sur une nouvelle image. De la même manière, on souhaite entraîner un réseau à reconnaître un certain module d'Young pour une mesure simulée, pour que sur une donnée expérimentale il soit capable de l'estimer.

Apprentissage machine :

Ce qui est communément appelé l'apprentissage machine sont les algorithmes ayant la capacité d'apprendre ou de s'améliorer à la réalisation d'une tâche, tout en restant autonome. Un tel algorithme a pour but de renvoyer la sortie souhaitée, noté Y , pour un attribut donné X . Il existe plusieurs types d'apprentissages, mais on s'intéressera principalement sur l'apprentissage automatique supervisé. Ce type d'apprentissage est composé d'attributs X (les données à caractériser) et chaque attribut a une étiquette Y , représentant la cible du réseau. Ainsi, le programme va adapter ses paramètres W en associant les attributs X avec leurs cibles Y , de sorte qu'il soit capable de deviner la cible d'un nouvel individu. Pour cela, il se basera sur une fonction de perte $L(W, X, Y)$. Et de la rétropropagation de gradient qui a pour but de diminuer la fonction de perte.

Apprentissage profond :

L'apprentissage profond est une branche de l'apprentissage machine, les algorithmes ont comme particularité d'être « profonds » c'est-à-dire de contenir plusieurs couches cachées, une très grande complexité de paramètres W . Cela leur permet d'apprendre plusieurs fonctionnalités avec un certain degré d'abstraction. Ces dernières années ont été très prolifiques pour l'apprentissage profond, avec l'émergence de nouvelles techniques qui ont permis de grandes avancées dans des domaines comme la reconnaissance faciale ou la détection d'objets, notamment grâce à l'apparition des GPU qui ont permis l'implémentation

de plus grandes architectures. En effet, l'apprentissage profond permet de détecter des liens et de corrélérer des éléments dans un type d'attribut brut (tel qu'une image, caractérisée par un ensemble de pixels), sans qu'il y ait la moindre extraction de données en amont. L'avantage de l'apprentissage automatique, c'est qu'au lieu de coder à la main et d'implémenter des règles précises et nécessaires à la résolution du problème souhaité, l'algorithme va définir seul ses règles.

1.3.1 Fonctionnement d'un réseau de neurones

Comme expliqué précédemment, le réseau a en entrée un attribut. Il est composé de différentes couches, et celle-ci par des poids. La première couche cartographie l'entrée du réseau, et les suivantes viennent cartographier les précédentes et ainsi de suite. Ensuite, l'apprentissage peut être défini comme le processus modifiant les poids des couches, de telle façon qu'à la sortie du réseau, la bonne cible est prédite. Pour faire cette adaptation de poids, il faut définir une fonction de coût. Celle-ci va avoir pour but de comparer la cible de l'attribut avec la sortie du réseau. Une erreur de prédiction est obtenue entre la cible et la valeur estimée. Cette erreur est utilisée comme compte-rendu du réseau pour ajuster ses poids. Ceci est le travail de l'algorithme de « back propagation ».

Réseau de neurones convolutifs :

Les réseaux de neurones convolutifs (CNN) sont une technique d'apprentissage profond inspiré du cortex visuel. Les premières apparitions de neurones convolutifs sont apparues avec Yann LeCun en 1989, qui a développé des neurones avec un partage de poids (LeCun, Denker, & Solla, 1989). Ils contiennent des cellules qui s'activent à la présence d'éléments particuliers dans le champ visuel, par exemple, certaines d'entre elles sont destinées à détecter la présence de coins, d'autres de diagonales, etc. Ainsi, les CNN sont basées sur cette technique d'identification de régions spécifiques.

Un réseau de neurones est composé toujours d'une entrée, d'une sortie et de couches cachées. Les CNN sont souvent liés aux problèmes utilisant des images. Dans une telle architecture,

contrairement à un réseau habituel, les neurones ne sont pas totalement connectés, ce qui dans le cadre de grandes images demanderait trop de mémoire. Et la complexité du calcul serait trop importante. C'est pourquoi nous devons recourir à des couches convolutives.

1.3.2 Réseau de neurones convolutifs

Couche convolutive :

La couche convolutive est la majeure partie d'un réseau convolutif. Le but de cette couche est d'effectuer une opération de convolution entre l'image d'entrée $A(i,j)$ et un filtre qui lui est propre $K(x,y)$. Ainsi, les paramètres d'une couche convolutive sont un set de filtres chacun différent.

Opération de convolution :

D'un point de vue mathématique une opération de convolution peut s'écrire :

$$(f * g)(n) = \sum_m f(m)g(n - m) \quad (1.22)$$

Où f et g sont deux fonctions valables sur un ensemble n . Pour le cas d'une image A de paramètre (i, j) et d'un filtre K à deux dimensions, l'équation de convolution entre A et K est:

$$F(i, j) = (A * K)(i, j) = \sum_m \sum_n A(m, n)K(i - m, j - n) \quad (1.23)$$

Pour mieux visualiser, la figure 1.4 présente cette convolution entre un filtre est un tableau de pixel.

100	100	100	100	100	*	=	100	100	100	100	100
100	100	100	100	100			100	100	50	100	100
100	100	150	100	100			100	50	350	50	100
100	100	100	100	100			100	100	50	100	100
100	100	100	100	100			100	100	100	100	100

Figure 1.4 Exemple de filtre de convolution

Le neurone convolutif possède plusieurs couches, et donc l'information se propage d'une couche t à une $t + 1$ via l'opération de convolution : $I(i, j, t) = I(i, j, t - 1) * F(i, j, t)$. Où $I(i, j, t)$ correspond à l'activation du multicanal au pixel (i, j) et à la couche t , et $F(i, j, t)$ correspond au filtre.

Le rôle d'une couche de convolution est de réaliser cette opération. Elle a divers buts, de détecter des formes trouvées sur une région locale, communes à l'ensemble de la base de données et de cartographier leurs apparences. Lors de l'apprentissage, les poids des filtres sont modifiés afin de détecter ces formes. Généralement, les filtres des premières couches convolutives détectent les caractéristiques globales d'une image, les lignes, les coins, etc. Puis, les filtres suivants servent à détecter des structures plus complexes et personnelles à une image.

1.3.3 Architecture d'un CNN

Pooling :

Les CNN sont souvent composées de couches Pooling. Elles sont insérées entre deux couches convolutives. Leur objectif est de réduire la taille des images. Cela va engendrer une simplification du nombre de paramètres de la couche suivante. La diminution de dimension est un opérateur fixe. Il existe plusieurs types de pooling. Par exemple, le Max pooling va garder uniquement la valeur de pixel la plus élevée d'une région de pixel donnée.




Figure 1.5 Exemple Max-Pooling

Fonction Relu :

Un élément important d'un réseau de neurones est la présence de fonction d'activation. La fonction principalement utilisée est la fonction Relu. On utilise ces fonctions après une couche convolutive. La fonction Relu est définie par $f(x) = \max(0, x)$. Le but d'une fonction d'activation est de convertir le degré d'activation d'un neurone en un signal de sortie.

Fonction de perte:

Comme dit précédemment, pour réaliser un entraînement il est nécessaire de comparer la sortie du réseau de neurones avec la valeur théorique réelle correspondante. Pour cela, une fonction de coût doit être utilisée. Pour notre problème, plusieurs types de pertes peuvent être utilisés. Mais la plupart donne un score, une erreur en faisant la différence entre la sortie et la cible souhaitée.

Par exemple la fonction Mean Square Error, qui a pour équation.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (1.24)$$

On vient simplement faire la moyenne de la différence au carré. Ou encore la fonction Mean absolute error :

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i|^2 \quad (1.25)$$

Toutes ces fonctions ont pour but de diminuer lorsque l'écart entre la sortie du réseau et la valeur cible diminue.

Optimisateur et Adam :

Une fois que l'erreur à diminuer est obtenue, les poids sont optimisés de façon à réduire cette erreur. Pour cela, le concept de la descente de gradient est utilisé. Cette méthode consiste à modifier le poids des couches du réseau en utilisant le gradient d'erreur calculé. L'équation qui régit le nouveau poids d'un neurone est :

$$w = w - \mu \times \nabla E(w) \quad (1.26)$$

Où w est le poids, μ le ratio d'apprentissage et ∇E le gradient d'erreur. Ainsi, dans notre réseau c'est un optimisateur qui va actualiser les poids du réseau en se basant sur cette équation. Les optimisateurs les plus connus sont Adam, RMSProp ou AdaGrad (P. Kingma & Ba, 2015).

Maintenant que tous les éléments qui régissent un entraînement sont acquis, l'intérêt peut être porté au type de réseaux et aux architectures à mettre en place dans le cadre de ce projet.

1.3.4 Les architectures de réseaux efficaces

Dans la littérature, différents types de réseaux de neurones sont étudiés et efficaces. C'est-à-dire quels agencements de structure convolutive sont les plus utilisés. Cela peut faire varier le nombre de couches, le nombre de filtres, la dimension des filtres, etc. Les réseaux les plus connus sont les réseaux avec beaucoup de couches convolutives, des réseaux très profonds. Les architectures populaires sont par exemple VGGNet, ResNet ou encore DenseNet. Si on

prend l'exemple de VGGNet, qui est un assemblage de 13 couches convolutives et de cinq Max Pooling, ce qui correspond à des millions de poids à optimiser.




Figure 1.6 Réseaux VGG
Tirée de Ferguson (2017, p. 10)

Ce réseau de neurones est très populaire, car il permet de réaliser des tâches extrêmement compliquées (par exemple de la reconnaissance faciale). En effet, ce réseau a des performances surpassant toutes les autres méthodes dans ce milieu.

Cependant, ce type de réseaux est tellement profond qu'il est souvent nécessaire de les utiliser avec des poids préentraînés. C'est-à-dire que les poids sont déjà entraînés sur une base de données. Ainsi, ils sont au préalable capable de reconnaître certains types de formes. Si nous ne faisons pas cela, entraîner de zéro un tel réseau demanderait énormément de temps ; mais également une base de données très conséquente. C'est pour cela que pour des problèmes plus « simples », comme la reconnaissance d'empreinte, ou encore la reconnaissance de caractère, des architectures plus petites sont parfois plus efficaces (Wani, Bhat, Afzal, & Khan, 2020). Intéressons-nous maintenant aux articles dans la littérature utilisant des réseaux de neurones sur des courbes de dispersion d'ondes guidées.

1.3.5 Les réseaux de neurones utilisés pour résoudre des problèmes d'inversion d'onde guidées

Un article très intéressant dans le cadre de notre projet est : (Y. Li, Xu, Li, Xu, & Ta, 2021). Le but de cet article est de déterminer l'épaisseur et la masse volumique de la partie corticale de l'os. L'application est totalement différente de ce qui est fait dans ce projet. Mais les CNNs se généralisent pour solutionner diverses tâches sur des données spécifiques. Or, les chercheurs utilisent les ondes guidées et un réseau de neurones pour estimer leurs paramètres. Ils ont également un problème d'inversion à réaliser ; dans leur cas, la caractérisation de l'os. Donc pour résumer leurs études est l'inversion des caractéristiques mécaniques de l'os, en utilisant une méthode par réseaux de neurones et des acquisitions d'ondes guidées Lamb, ce qui peut se retranscrire pour notre étude. Mais contrairement à nous, ils vont envoyer le signal temporel au réseau de neurones. Ainsi, ce qui est intéressant dans cet article est de comprendre comment ils ont mis en place leurs réseaux de neurones pour résoudre un problème d'inversion d'onde guidée. Tout d'abord, l'architecture de leurs réseaux de neurones est particulière, elle comporte trois entrées pour trois sorties (l'estimation de trois paramètres). Là où c'est inhabituel, est qu'il a trois entrées, en effet, nous avons un seul type de données : les simulations d'onde guidée. Le but de ces trois entrées est qu'elles ne font pas toutes la même chose, par exemple, la première entrée va détecter des détails plus grandes échelles avec une dimension de filtre convolutifs de (12,20,120). Alors que la troisième entrée se focalise sur l'obtention de caractéristiques à moyenne échelle (6,10,120).

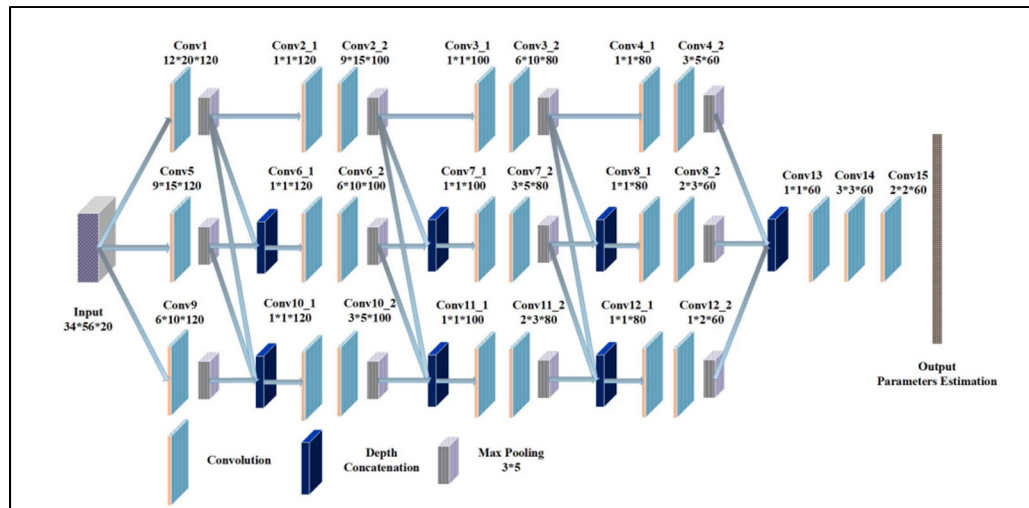


Figure 1.7 Exemple CNN utilisé dans la référence
Tirée de Li (2021, p. 6)

Un aspect intéressant dans l'approche par CNN est qu'il entraîne uniquement leur réseau de neurones sur des données simulées. Et ils testent des données expérimentales. Enfin, les résultats qu'ils obtiennent sont très intéressants. L'inversion est validée, puisqu'ils visualisent une erreur d'environ 2,66 % sur l'estimation de l'épaisseur de la partie corticale de l'os. La superposition entre les courbes de dispersion théorique et celles estimées par le réseau de neurones est très bonne. Ils ont de meilleurs résultats avec un réseau à 3 entrées qu'un réseau simple.

L'avantage d'un CNN par rapport à d'autres méthodes d'inversion. C'est qu'après l'entraînement le temps de calcul pour estimer une nouvelle valeur est très faible. En effet, il n'y a pas besoin d'effectuer de nouveaux réglages. Maintenant, que nous avons tous les éléments entre les mains pour répondre à notre problème. Nous pouvons énoncer notre méthode de résolution.

CHAPITRE 2

METHODOLOGIE

2.1 Objectifs et hypothèses

Le but de ce projet est : à partir d'un échantillon collé, être capable de déterminer s'il est correctement collé ou non. Lorsqu'un joint est mal collé, cela va entraîner une diminution de sa contrainte admissible. Or, des simulations ont été effectuées, modélisant des joints parfaits. Dans la suite de ce projet, il est considéré l'hypothèse suivante ; les perturbations réelles engendrées par une mauvaise qualité de joint seront incluses, dans le cadre d'un modèle parfait, dans les variations du module d'élasticité. Et donc, il serait possible d'estimer la qualité en étudiant les variations du module d'Young.

Ainsi, pour répondre à la problématique, le module d'Young d'un assemblage collé doit être déterminé. Pour atteindre cet objectif, on réalise plusieurs sous objectifs. Le premier est de fabriquer des échantillons collés. Le deuxième est de réaliser des acquisitions d'onde Lamb sur nos assemblages collés. Le troisième est de mettre en place un réseau de neurone capable de réaliser l'inversion du module d'Young en se basant sur des assemblages collés. Enfin, une fois toutes ses étapes validées on pourra comparer l'évolution du module d'Young en fonction de la qualité du joint et répondre à notre problématique.

2.2 Fabrication de joints collés

2.2.1 Réalisation d'une première série de joints.

Un enjeu crucial de notre projet est de fabriquer des joints collés. Manipuler de la colle entraîne une procédure très stricte et difficile à reproduire. De l'adhésif Sikadur 330 a été fourni par l'entreprise Sika, qui exerce dans le bâtiment, avec une spécialisation dans l'époxy. Ensuite,

la géométrie définie pour les éprouvettes est celle décrite à la figure 2.1. Cette géométrie a été choisie pour permettre la réalisation de test de joint de recouvrement.




Figure 2.1 Dimension des échantillons

En effet, les joints doivent répondre à deux conditions, la première est de permettre l'acquisition de signaux ultrasonore, rendue possible grâce à la zone collée qui correspond à un rectangle de 2×20 cm. Cet espace convient parfaitement à l'obtention des courbes de dispersion de l'assemblage. Puis, la deuxième contrainte était de pouvoir réaliser des tests mécaniques de joint de recouvrement à partir des échantillons. Cela est permis avec cette géométrie. Car après la phase d'acquisition, les éprouvettes peuvent être coupées afin de créer des joints de recouvrement de 2 cm de large. Cette géométrie est en accord avec la norme ASTM D1002.




Figure 2.2 Single lap après le découpage

2.2.2 Réalisation de tests sur des joints à recouvrement simple

À la suite de premiers résultats non concluants, nous avons voulu tester nos échantillons créés, avec la méthode destructive des simples joints de recouvrement. Comme expliqué précédemment, cette méthode est utilisée pour obtenir partiellement le module de cisaillement d'un joint collé. Une presse de traction vient tirer de chaque côté de l'éprouvette.




Figure 2.3 Test de nos joints avec la méthode simple joint de recouvrement

Quatre échantillons provenant d'un même joint collé ont été découpés pour passer le test, les essais sont visibles à la figure 2.3. Les maximums de rupture sont différents pour les 3 échantillons. Ce qui veut dire que pour une même acquisition nous aurons localement des écarts au niveau de la qualité de collage. Cela viendrait fausser les estimations de module d'Young. De plus, pour les quatre mesures, les éprouvettes n'ont pas un module de cisaillement identique. Effectivement, pour cet essai le module de cisaillement est représenté par la pente de la droite de la partie élastique du test de traction. Or, pour l'échantillon 2, il y a une pente beaucoup plus faible que les autres. Ce qui signifie qu'il y a un module d'Young plus faible que sur les autres éprouvettes. Mais, comme ils proviennent tous du même assemblage, cela vient bien souligner un problème dans notre façon de concevoir des échantillons. Ce test de recouvrement amène à nous questionner sur la qualité des joints inspectés.

2.2.3 Inspection de nos échantillons

Des phénomènes étranges ont été observés lors des tests de joint de recouvrement, suite à cela on a voulu inspecter les éprouvettes. Plusieurs tests sur différentes éprouvettes provenant de

différents joints collés ont été réalisés. Il se trouve que dans la majeure partie des cas notre époxy possédait des bulles. Un CT Scan à la figure 2.4 montre le résultat.





Figure 2.4 CT Scan échantillons collés

La résine époxy est représentée en rose sur l'image, entre les deux plaques et la présence de bulle en noir est évidente, ce qui correspondent à des bulles d'air. Après analyse de la méthode de collage, la supposition est que lors du mélange des deux composants de la résine époxy, des bulles apparaissent.

Par ailleurs, lors de la réalisation d'une radiographie par rayon X d'un autre échantillon (figure 2.5). On observe une zone plus claire sur la radiographie de côté, cela correspond à une bulle d'air, celle-ci se retrouve sur la vue de face. Une grande zone d'air est visible dans toute la largeur du joint. Ce genre de défaut a clairement un impact non négligeable sur un test de joint de recouvrement et aussi sur des mesures ultrasonores.



à gauche : vue de face, à droite : vue de côté

Figure 2.5 Radiographie Joint collé

Ces différentes visualisations montrent que des difficultés sont présentes pour la réalisation de joints propres sans impuretés, et que cela pourrait impacter les futurs résultats.

Finalement, le laboratoire CNRC de Saguenay a été contacté en raison de sa spécialisation dans l'aluminium, et surtout dans le collage. Des chercheurs ont collaboré sur ce projet pour fabriquer des échantillons respectant la norme de la figure 2.1. Ainsi, six échantillons de plaques d'aluminium collées avec diverses contraintes maximales admissibles nous ont été fournis. De plus, ils ont fourni ces échantillons sans donner d'indications. L'étude est donc réalisée à « l'aveugle », pour éviter tout phénomène de biais.




Figure 2.6 Échantillons CNRC

2.3 Méthode d'acquisition

2.3.1 Description de la méthode d'acquisition

La réalisation d'acquisition se fera en utilisant une installation avec un transducteur piézoélectrique et un vibromètre laser. La sonde est alimentée par un générateur et est mise en position sur l'assemblage. Cette sonde va envoyer des ultrasons dans le joint. Le vibromètre laser a pour but de détecter les oscillations de la plaque due aux ultrasons. Il récupère des traces temporelles pour chaque point du laser. De plus, un système de vis sans fin procure une mobilité sur un axe horizontal, en activant cette vis, l'assemblage collé est translaté et permet l'obtention d'un nouveau point avec le laser. En combinant ces systèmes, l'acquisition de plusieurs traces temporelles peut être réalisée. De plus, la sonde peut émettre sur une large plage de fréquences. Et donc en faisant varier la fréquence d'excitation et la distance, toutes les conditions sont réunies pour construire une transformée de Fourier bidimensionnelle

(FFT2D) de notre joint. La FFT2D permet de séparer les ondes se propageant en fonction de leur fréquence et de leur nombre d'onde. Ces données seront exploitées dans ce projet.

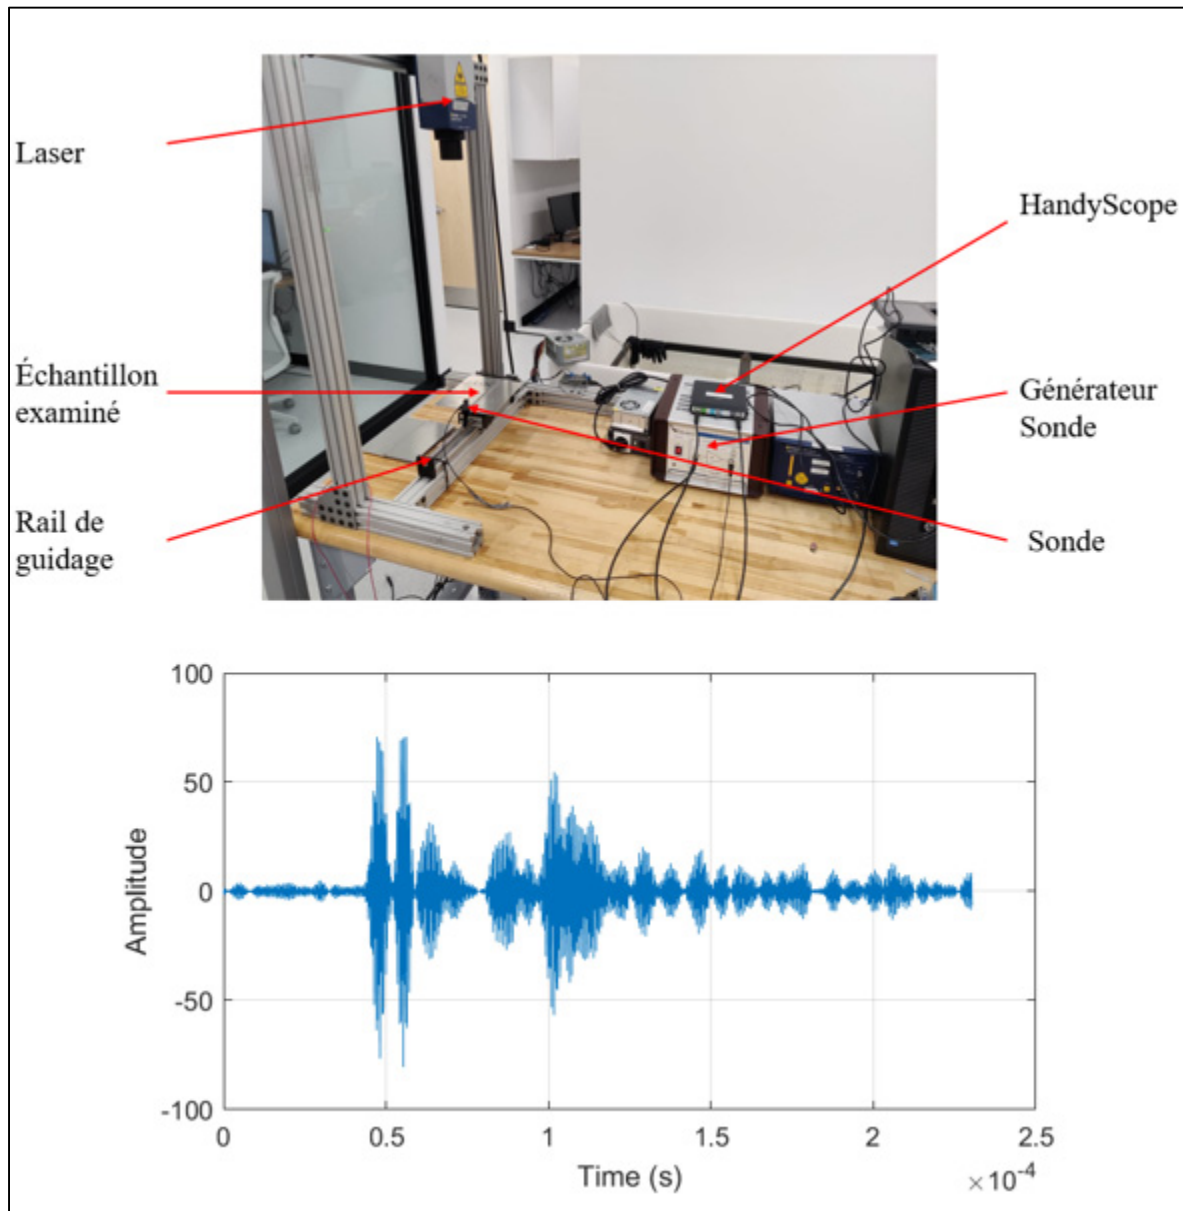


Figure 2.7 Set up expérimental et affichage d'une trace temporelle

FFT2D :

À ce stade, on doit expliquer ce qu'est une FFT2D. Puisqu'il s'agit de la donnée principale que nous allons utiliser au cours de ce projet.

Dans le chapitre précédent, il est énoncé que les ondes Lamb se propagent par mode d'onde. Ses modes sont présents à n'importe quelle fréquence. Lors de l'acquisition ultrasonore, la sonde envoie un signal balayant une large bande de fréquence. Les signaux reçus par notre vibromètre laser sont des signaux temporels, différents en fonction de l'espacement du laser et la sonde, le but est d'introduire la composante spatiale. Finalement, il faut plusieurs traces temporelles chacune dépendant du temps et de l'espace.

Visualiser les modes d'activations de nos ondes Lamb est très difficile sur un signal (temps, distance). La méthode de fourrier va permettre de convertir les données du système temps/espace à un système fréquence/nombre d'onde. Évoquant que toute fonction périodique peut s'écrire comme la somme de sinus et de cosinus (séries de Fourier). Aussi, toutes fonctions finies et continues (comme une image), peut s'écrire comme une intégrale de sinus et cosinus (transformé de Fourier). Par exemple, la transformée de Fourier d'une fonction continue s'exprimera : (W. T. Cochran et al., 1967).

$$\mathcal{F}[f(x, y)] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \exp[-j2\pi(ux + vy)] dx dy \quad (1.21)$$

Donc, cette transformation permet une meilleure visualisation des données, exemple à la figure 2.8, ou nous distinguons clairement les modes contrairement à la figure 2.7.

Les premières mesures peuvent être effectuées. Comme exposé à la figure 2.8, une acquisition de 300 kHz à 3 MHz et sur une bande de 10 cm a été réalisée. C'est ce type de FFT2D que le système d'acquisition renvoie. Cette figure ne correspond pas tout à fait à une FFT2D classique (exemple : figure 2.9). En effet, il y a un repli au niveau des abscisses. On doit alors effectuer du post-traitement pour rendre notre image équivalente à celle de la base de données.

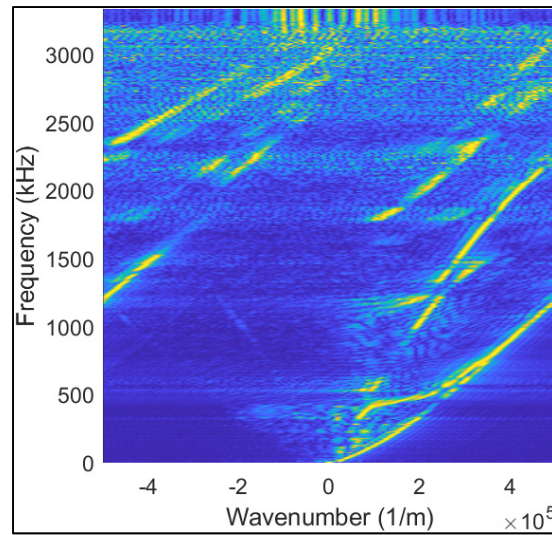


Figure 2.8 FFT2D brutes du vibromètre

Pour s'identifier à la base de données, les acquisitions doivent être adaptées. Toutes les données négatives de l'axe horizontal doivent être placées à la suite des données positives. Ceci sert à éliminer le phénomène de repliement.

Pour la suite de cette étude, on considère les FFT2D comme un tableau avec un certain nombre de lignes et de colonnes, qui se comporte comme une image, chaque case du tableau correspond donc à un pixel. Les acquisitions subissent une réduction du nombre de pixels pour avoir les mêmes dimensions que les données expérimentales, pour pouvoir être implémentées ensemble dans le réseau de neurones. Il faut aussi s'assurer que les moyennes des pixels sont du même ordre de grandeur entre les deux images.

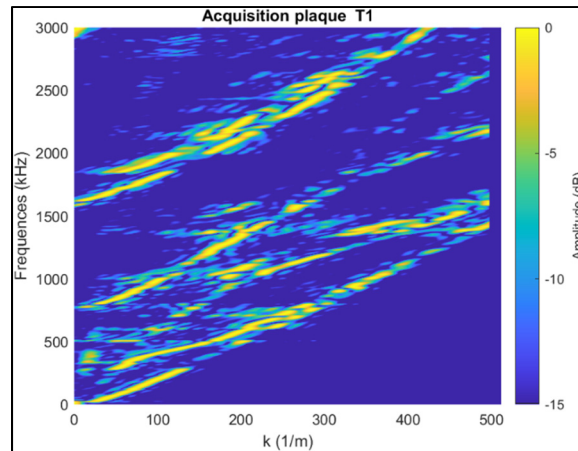


Figure 2.9 Données après les réajustements dimensionnels

2.3.2 Acquisitions bruitées

La figure 2.9 exprime le problème lié aux bruits sur les acquisitions. En opposition, la figure 2.10 qui montre une FFT2D simulée, qui ne contient aucun bruit. Il est donc nécessaire de se rapprocher au mieux de cette qualité pour les acquisitions. Sinon, il est facile d'imaginer que le réseau de neurones va avoir des difficultés à estimer ses nouvelles données.




Figure 2.10 Donnée simulée (sans bruit)

Pour réduire le bruit, il faut déjà éliminer au maximum les bruits évitables. C'est-à-dire, tous les bruits qui sont provoqués par une mauvaise exécution du protocole d'acquisition. La figure

2.11 met en lumière cet élément. Un recalibrage du laser (alignement + focal) permet d'améliorer nettement le signal.




Figure 2.11 Effets du recalibrage du laser

Ceci étant dit, le signal obtenu reste tout de même insatisfaisant. Les différents modes sont distinguables, mais contrairement aux données simulées, ces lignes ne sont pas continues et une part conséquente du bruit est toujours visible. Différentes techniques de filtrage ont été essayées, mais il a été impossible d'obtenir de meilleurs résultats. Une technique consiste à réduire directement le bruit sur les FFT2D, en mettant en place un seuil en décibel qui éteignait un pixel si celui-ci ne le dépassait pas. Mais le filtrage était trop brutal et supprimait autant de bruit que de données importantes. Une autre méthode consistait à isoler des zones sur les A-Scan, et ne garder que les traces temporelles utiles, en éliminant les échos de la plaque d'aluminium. Cette méthode n'a pas montré de réelles différences.

Il y a donc eu deux solutions envisagées et mises en place pour parer ce problème de bruit dans les acquisitions. Premièrement, la solution la plus simple consiste à garder et tester les acquisitions les plus propres qui ont été obtenues. L'autre option a été de faire plusieurs mesures d'un même joint et de les sommer, exemple figure 2.12. Cette technique permet de réduire le bruit présent et d'intensifier les courbes de dispersion.




Figure 2.12 Résultat d'une sommation de sept acquisitions du même joint

2.4 Réseaux de neurones : méthode d'inversion

Le but est de réaliser une inversion, c'est-à-dire être capable, à partir d'une acquisition d'ultrasons de retourner la valeur du module de Young de notre assemblage.

Comme évoqué dans la revue de littérature, beaucoup de méthodes existent pour réaliser ce type de tâches. Précédemment, sur ce même projet une approche avec une fonction de coût a été implémentée, mais les résultats n'étaient pas satisfaisants. Ainsi, mon rôle dans ce projet était principalement de mettre en place une nouvelle méthode plus fiable. Donc, je me suis tourné vers l'apprentissage profond qui est de plus en plus utilisé dans des applications d'ondes guidées. Les réseaux de neurones ont suscité mon intérêt, et plus précisément, les réseaux de neurones convolutifs. Effectivement, les courbes de dispersion sous forme de FFT2D s'apparentent à des images. Or, les réseaux de neurones convolutifs sont très performants dans la détection d'image ou dans la classification d'image. C'est pour cette raison que cette méthode sera tentée pour réaliser l'inversion.

2.4.1 Explication du processus d'inversion

Les réseaux de neurones convolutifs sont la solution envisagée, nous devons maintenant énoncer le problème qu'il faut résoudre. On veut que pour une certaine image (FFT2D), le

réseau renvoie une valeur numérique, un module d'Young. Il s'agit donc d'un cas de régression, avec en entrée des images et en sortie des nombres.

La capacité d'inversion du réseau de neurones repose sur la qualité de son entraînement. En effet, il doit être entraîné pour identifier des aspects de l'image représentant le module d'Young. Par la suite, il devra être capable de déterminer un module pour une nouvelle image. Pour cela, il sera entraîné sur des simulations d'assemblages collés. Ces données garantissent avec certitude que le module d'Young affiché correspond à celui de la FFT2D.

2.4.2 Base de données

Comme énoncé précédemment, pour que le réseau de neurones puisse estimer le module d'Young correctement, il doit être entraîné et pour cela il a besoin de données.

2.4.2.1 Les simulations

Pour créer la base de données, il faut obtenir des données simulées. Pour les avoir, une simulation du problème doit être créée. Une simulation éléments finis sur le code Pogo FEA d'un joint a été réalisé par le postdoctorant Daniel Pereira. Pour l'adapter à ce projet, il suffit de modifier la géométrie. Les courbes de dispersion théorique pour des plaques collées de 2 mm d'épaisseur avec une épaisseur d'adhésif variable peuvent être facilement obtenues.

La méthode par éléments finis utilisée par Daniel Pereira pour générer des courbes de dispersion a pour géométrie trois couches, toutes assumées comme isotropes et homogènes, basées sur ces modèles d'échantillons. Plus précisément, des plaques d'aluminium de 1 mm d'épaisseur et une couche d'adhésif de 0.25 mm.




Figure 2.13 Schémas représentant le modèle utilisé en simulation
Tirée de Pereira (2022, p. 4)

Comme paramètres géométriques, il y a uniquement l'épaisseur de l'adhésif et l'épaisseur de l'aluminium. Les plaques d'aluminium ont les caractéristiques d'un matériau isotrope, et comme paramètre le module d'Young, le coefficient de poisson et la densité. Il en est de même pour l'adhésif. De plus, sur la figure 2.13, des régions d'absorption ont été ajoutées, elles sont nécessaires pour assimiler la structure à une région infinie.

La structure des éléments utilisés est des carrés de 0.05 mm de côté pour permettre d'avoir au moins 15 éléments par nombre d'onde. Les simulations sont effectuées avec un pas temporel de $1e-8$ secondes. Pour la simulation du signal, l'auteur utilise un cycle de Hann centré à 1MHz et 1N pour une force d'amplitude. Le déplacement est synthétisé par 160 récepteurs séparés par 0.5 mm le long d'une ligne de la plaque d'aluminium. Enfin, la FFT2D peut être utilisée. En comparant avec les acquisitions sur une simple plaque d'aluminium des modes thématiques peuvent être retrouvés, comme les modes symétriques et antisymétriques d'une onde de Lamb.

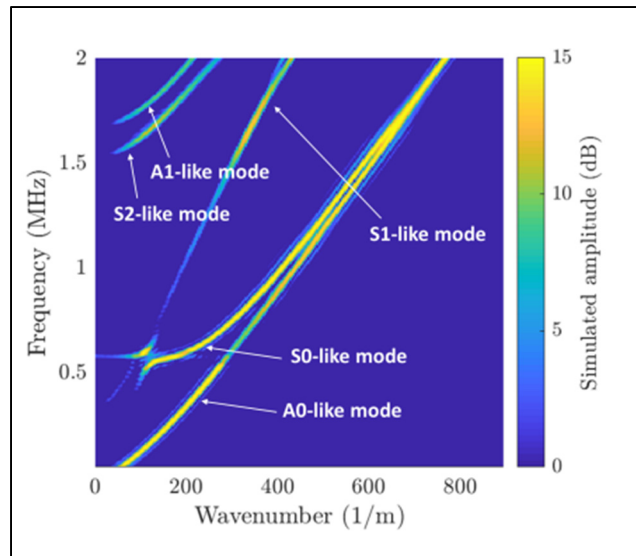


Figure 2.14 Simulation courbe de dispersion
Tirée de Pereira (2022, p. 4)

2.4.2.2 Description des données

Les simulations prennent comme paramètre l'épaisseur de chaque élément (plaques et adhésif), le module d'Young et le coefficient de poisson. Pour créer la base de données, il faut faire varier ses paramètres pour obtenir un nombre d'acquisitions suffisant. Le paramètre inconnu que l'on essaye de caractériser dans ce projet est l'adhésif. Ainsi, il est normal de faire varier les paramètres mécaniques de l'adhésif plutôt que ceux des plaques. De plus, comme l'étude est réalisée uniquement sur un même type de plaque, qui a les mêmes dimensions, tous les paramètres dépendant du type de la plaque peuvent être fixés. Comme ce sont des plaques d'aluminium de 2 mm d'épaisseur, le module d'Young sera fixé à 69 GPa, l'épaisseur égale à 2 mm et le coefficient de poisson égal à 0.34. Il reste donc à définir sur quelle plage de valeur il faut faire varier les paramètres de l'adhésif. Il a été défini que : l'épaisseur de colle varie de 0.22 mm à 0.34 mm avec un pas de 0.02, le coefficient de poisson 0.25 à 0.49 avec un pas de 0.01, enfin, un module d'Young qui varie de 0 jusqu'à 3 GPa avec un pas de 0.05 GPa et de 3 GPa jusqu'à 7 GPa avec un pas de 0.5. Un pas plus faible pour les valeurs inférieures à 3 GPa a été choisi, car il faut plus de précisions dans ce domaine.

En fin de compte, une base de données composée de plus de 6 000 simulations est obtenue. Ce qui est amplement suffisant pour que le réseau converge.




Figure 2.15 Répartition des données en fonction du module d'Young

2.4.3 Description du réseau de neurones

Pour la suite de la démarche, il faut mettre en place un système d'inversion par réseau de neurones, ainsi, il faut définir quelle architecture utiliser.

2.4.3.1 Type de réseau utilisé

Dans la littérature, beaucoup de réseaux différents existent pour résoudre des problèmes identiques au nôtre. Les réseaux de neurones convolutifs sont souvent décomposés en deux parties, la partie convolution, qui a pour but de tester et sélectionner différentes zones de l'image. La partie classification, qui a le rôle de classifier et d'estimer l'image. Ainsi, pour notre problème de régression, nous allons utiliser un neurone dit Dense, totalement connecté, qui va avoir pour but de synthétiser l'inversion.

Une fois l'architecture globale du réseau obtenu, la structure de chaque partie doit être définie, c'est-à-dire, choisir le nombre de neurones convolutifs, la taille du noyau, etc.




Figure 2.16 Structure basique de notre réseau de neurone

Si l'on se réfère à la littérature, il existe de très profonds réseaux de neurones, tels que DenseNet, VVG, Resnet. Ils sont très connus, très efficaces, mais, souvent utilisés pour des applications très complexes, telles que, la reconnaissance faciale, ou la détection d'objet. Cela étant, notre problème n'est pas aussi complexe à résoudre (l'image qu'il doit analyser est beaucoup plus simple qu'une image d'une caméra de surveillance par exemple). Les aspects globaux d'une image tels que la pente, les droites et les distances entre deux droites doivent être identifiés. Pour cela, un plus petit réseau de neurones est mis en place.

2.4.3.2 Choix du réseau de neurones

Pour choisir l'architecture finale du réseau, les performances de plusieurs architectures seront comparées. Comme évoqué dans la partie précédente, un petit réseau est implémenté pour ce projet, on le nommera par la suite LambWaveNet et il sera mis en compétition face aux réseaux populaires tels que Resnet, DenseNet, et VGG.




Figure 2.17 Architecture Convolutionnelle du réseau LambWaveNet

Avec cette architecture on espère pouvoir tirer les informations utiles pour notre problème de régression.

2.4.4 Structure des bases de données

Le réseau de neurones a beaucoup de paramètres, essayer de l'optimiser peut devenir très compliqué. Pour réaliser l'entraînement correctement, la base de données a besoin d'être décomposée en trois sous bases. Une sera la base d'entraînement, qui a pour but seulement d'entraîner le réseau de neurones. Ensuite, il y a la base de test, celle qui permet de tester le réseau de neurones. Enfin, il y a la base de données de validation, celle-ci va servir pendant l'entraînement. À chaque fin de pas d'entraînement, le réseau sera testé sur la base de validation, afin de contrôler si le réseau continue bien de converger. Il ne va pas adapter ses poids sur cette base de données, mais il va se tester sur celle-ci pendant l'entraînement. Cette base est très utile pour vérifier si le réseau ne fait pas de surentraînement. Ainsi, avec cette structure de données le réseau peut être entraîné, observé et testé. Pour ce qui est du nombre de données pour chaque base, il a été choisi d'avoir 60 % de la base de données totale pour l'entraînement, 20 % pour le test et 20 % pour la validation.

2.4.5 Variation des hyper paramètres

Maintenant qu'il y a les données suffisantes pour entraîner et tester le réseau, des hyperparamètres doivent être définis pour commencer l'entraînement. Les hyper paramètres sont le nombre d'epochs et le batch size. Un epoch correspond à un balayage de la base de données d'entraînement par le réseau, à la fin de chaque pas il y a l'étape de back propagation.

Le batch size correspond à la dimension des échantillons de la base de données étudiée par le réseau à chaque epoch. Un entraînement peut être lancé.




Figure 2.18 Entraînement de réseau

La valeur de la perte en fonction du nombre d'epoch est visualisé figure 2.18, pour un entraînement classique. Ce type de courbe sera analysé dans le prochain chapitre.

2.4.6 Modèle réseau de neurones à plusieurs sorties.

Dans ce projet, il sera intéressant de modifier le réseau de neurones pour le programmer à estimer non seulement, le module d'Young, mais aussi les autres paramètres qui définissent les courbes de dispersion. C'est-à-dire, le coefficient de poisson, et l'épaisseur de la colle. Pour ce faire, les données d'entrée du réseau doivent être modifiées. Ainsi, pour une image donnée lors de l'entraînement, il faut indiquer la valeur de tous les paramètres. Ensuite, la sortie de

notre réseau de neurones sera modifiée en remplaçant la dernière couche par une couche dense à trois sorties, pour qu'il réalise trois régressions.




Figure 2.19 Schémas réseaux à trois sorties

De plus, une fois ce changement effectué, il permet de construire une fonction, qui à partir des estimations pourra nous renvoyer l'image qui correspond au mieux aux estimations. Une superposition des deux images pourra attester de leur correspondance ou pas.

2.4.7 Concentration de l'attention du réseau de neurones sur un aspect de l'image

Dans la suite de ce projet, la structure du réseau de neurones sera légèrement modifiée pour tenter d'améliorer les résultats. Lors de la visualisation de plusieurs images de la base de données, il apparaît clairement des zones d'intérêt, en effet, si six images sont affichées aléatoirement dans notre base de données. Voici le résultat.




Figure 2.20 Affichage de six différentes images dans notre base de données

En observant ces courbes de dispersion, de réelles différences sont observables. On observe plus de variations des courbes dans certaines zones. On peut définir ces zones comme des zones de fort intérêt. Ainsi, l'influence de l'inversion a été testée sur un réseau guidé sur une zone

précise que l'on suppose intéressante et riche en information. Deux zones remarquables apparaissent matérialisées figure 2.21.

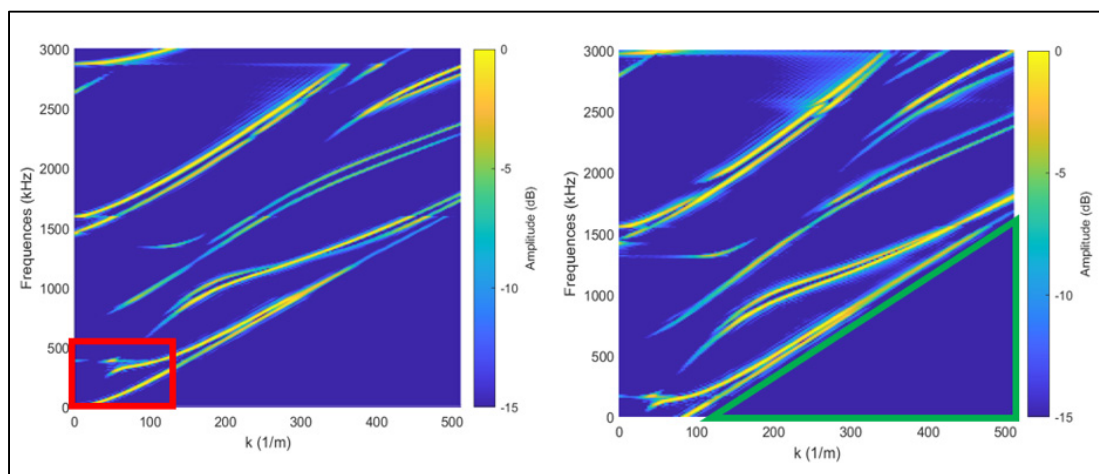


Figure 2.21 Caractérisation des zones plus ou moins importantes

On a remarqué que la zone rouge est riche en enseignement, au contraire de la zone verte qui est vide d'intérêt, c'est pourquoi, l'influence de l'inversion sera testée en guidant le réseau de neurones sur la zone rouge.

2.4.8 Construction d'un double réseau de neurones

Dans la continuité du paragraphe précédent, une fois que le réseau aura focalisé son attention sur une partie de l'image, il serait intéressant de combiner les deux méthodes vues jusqu'ici. Ce qui reviendrait à mettre deux réseaux de neurones en parallèle, avec l'un qui focaliserait son attention sur une partie isolée de l'image et l'autre qui viendrait garder sa convolution sur l'ensemble de l'image. Ainsi, en combinant les deux, on espère tirer profit du meilleur des deux méthodes. C'est-à-dire, venir chercher une caractéristique précise sur une partie de l'image et assurer l'aspect plus global de la reconnaissance.

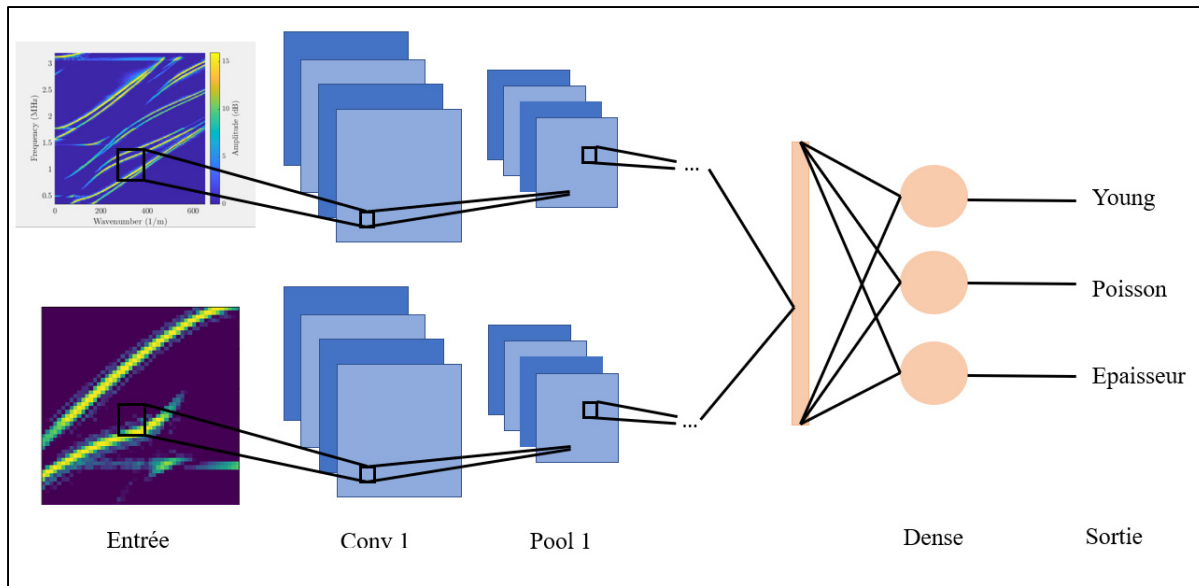


Figure 2.22 Schématisation réseaux à deux entrées

Ainsi, le réseau aura deux parties convolutives et chacune reprendra les dimensions des parties respectives, vu précédemment.

CHAPITRE 3

RESULTATS

À la suite de la méthode, des résultats ont été obtenus. Dans un premier temps, on abordera les résultats préliminaires plutôt encourageants, puis on exposera les résultats sur les assemblages du CNRC qui sont très intéressants. Enfin, on tentera de les interpréter et de les améliorer.

3.1 Résultats préliminaires

Les performances des différentes architectures, VGG, DenseNet, Resnet et LambWaveNet sont détaillées dans la suite, afin de définir une architecture finale pour continuer le projet.

3.1.1 Validation de l'entraînement du réseau sur les données simulées

La première étape pour valider le modèle est de réaliser l'entraînement du réseau avec la base de données définie pour cette tâche, puis de le réviser avec la base test. Au vu des résultats, il sera déterminé si le réseau est assez performant. Pour cela, plusieurs critères ont été définis. Premièrement, l'erreur totale MSE sur la base test doit être inférieure à 0.05 GPa et l'écart type à 0.5 GPa. Également, le réseau doit éviter le plus possible d'avoir des valeurs aberrantes.

Tableau 3.1 Définition des architectures testées

	1	2	3	4
Nom des architectures testé	LambWaveNet	VGG16	DenseNet8	Resnet50

L'entraînement du réseau LambWaveNet a pour avantage d'être le plus rapide. Les algorithmes sont exécutés sur un serveur de calcul qui dispose de plusieurs cartes graphiques

NVIDIA P6000 (24 GB). Le réseau met en moyenne 1 min pour s'optimiser sur 6000 images avec un nombre d'Epoch de 15 et un Batch-size de 100.

Les premiers entraînements peuvent être observés figure 3.1. Pour les interpréter, il faut visualiser une métrique en particulier, ici la fonction de perte. C'est la valeur que le réseau de neurones souhaite faire diminuer. Dans ce cas, il s'agit de la fonction MSE (Mean Square Error).




Figure 3.1 Étude de la perte pendant l'entraînement

Une première observation montre que les entraînements convergent vers une valeur de 0,02 GPa (figure 3.1). Cela signifie que l'optimisation des poids diminue le score de la fonction de perte jusqu'à une valeur limite et donc que la régression est terminée. Le réseau tend vers une valeur de 0,02 GPa ce qui correspond au score MSE sur la totalité de la base de données d'entraînement, ce nombre convient, car il est inférieur à 0,05 GPa qui est notre critère, cependant pour valider l'entraînement, ce critère doit être accepté sur la base de données test.

Sur la figure 3.1, la perte MSE présente en ordonnées, correspond à l'erreur carrée relative moyenne. En abscisse le nombre d'Epoch est affiché. Cette figure permet de visualiser l'entraînement, mais aussi la validation. Celle-ci converge en même temps que l'entraînement, ce qui indique un fonctionnement normal. Également, à partir du 16e Epoch le réseau ne

semble plus s'améliorer, c'est pourquoi pour la suite des études les entraînements se feront en 15 Epochs.

Le réseau de neurones est ensuite testé sur la base de données test. Celle-ci est riche de 1 200 images. Dans un premier temps, une estimation de ces images par notre réseau est réalisée, puis elle est comparée à la valeur réelle de la simulation. Une erreur relative moyenne de 0,09 GPa pour l'ensemble de la base est observée, ce processus a été répété 10 fois et chaque fois la valeur est inférieure à 0,1 GPa. Cette erreur relative est satisfaisante, car si le réseau arrive à estimer un assemblage réel avec une telle précision il permettra l'application de la méthode et l'on aura beaucoup d'espoir de visualiser des différences au niveau de la qualité du collage.

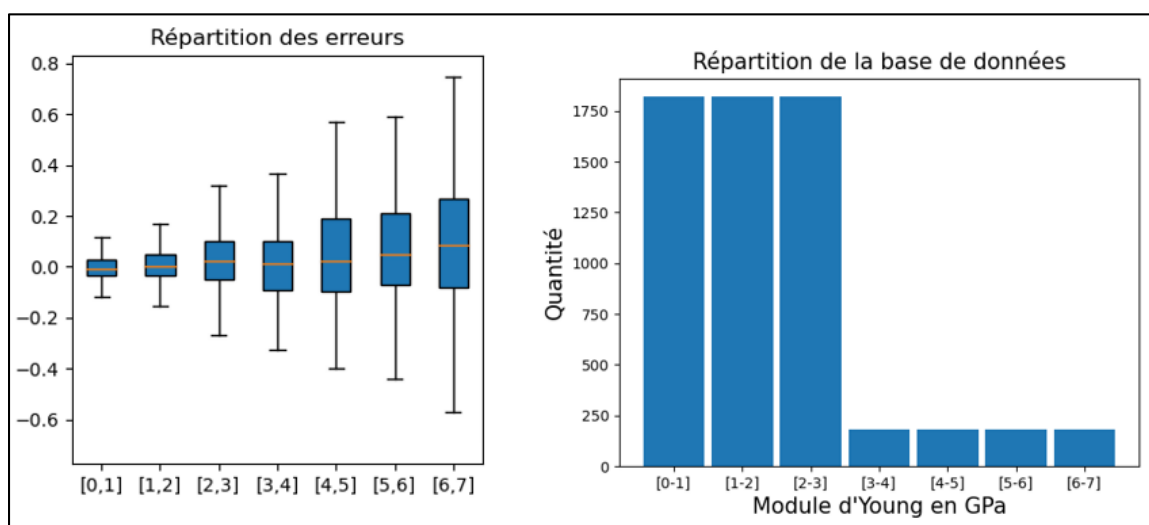


Figure 3.2 Répartition des erreurs en fonction du module d'Young

Ce score a été analysé plus en détail (figure 3.2). Il est intéressant d'apprendre si le réseau fait une erreur constante sur toutes les valeurs de module d'Young ou s'il a plus de difficulté à estimer certaines. En ce sens, l'erreur d'estimation a été affichée en fonction du module d'Young. Pour cela, les différentes simulations ont été regroupées par groupe, à savoir, les simulations ayant un module inférieur à 1 GPa, celles entre 1 et 2 GPa, 2 et 3 GPa et ainsi de suite. En observant les résultats (figure 3.2), on observe des écarts plus importants pour les modules d'Young plus élevés mais si on rapporte ces résultats aux erreurs relatives on obtient

des écarts homogènes. Ainsi, le fait qu'il y ait moins de données au niveau des modules d'Young plus élevés ne semble pas impacter la capacité du réseau à fournir une estimation correcte.

Finalement, ses résultats sont largement satisfaisants. Car l'erreur totale est inférieure à 0,1 GPa, de plus, il est supposé que la colle a un module moindre à 3 GPa, alors le réseau peut être encore plus précis. La figure 3.2 montre tout de même que certaines valeurs estimées peuvent être importantes avec des écarts de 0,8 GPa et donc bien supérieurs au critère de 0,5 GPa. Mais dans l'expérience, ses erreurs seront gommées en effectuant des moyennes sur plusieurs inversions et plusieurs acquisitions avant de déterminer un module.

3.1.2 Comparaisons des différentes architectures

Le réseau construit pour ce projet semble avoir de très bonnes performances et répond totalement aux attentes. Par ailleurs, Il est intéressant de le comparer aux réseaux présents dans la littérature pour l'évaluer. Comme évoqué plus tôt, ces réseaux ont de très lourdes architectures. Celles-ci sont déjà implémentées dans la bibliothèque Keras de python. Sachant qu'ils ont beaucoup de variables à affiner au cours de l'entraînement, il est souvent préconisé de les utiliser avec des poids préentraînés. Dans cette étude, les réseaux ont des poids préentraînés sur la base de données ImageNet (c'est une base de données comportant plus de 10 000 images, principalement d'animaux ou d'objets). Le but de ce préentraînement est de permettre au poids de détecter des symboles clés dans l'image. Certes, un réseau aussi profond entraîné entièrement sur une base de données similaire à la nôtre donnerait peut-être de meilleurs résultats. Mais cela demanderait beaucoup plus de données et de temps.

La démarche suivante est appliquée; importer les réseaux de neurone préentraîné, retirer son classificateur, le remplacer par un adéquat au projet, qui permet de réaliser la régression. De cette façon, les différentes architectures peuvent être évaluées (figure 3.3), afficher les courbes d'entraînement, ainsi qu'un graphique permettant d'étudier la moyenne des erreurs que le réseau commet sur la base de données teste. Voici les résultats obtenus.

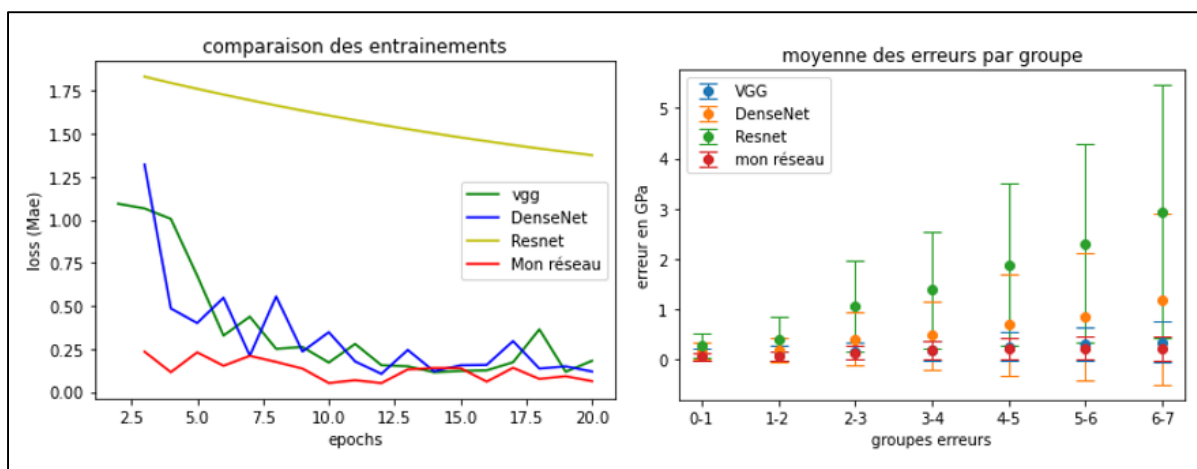


Figure 3.3 Étude des différentes architectures

À gauche : Convergence de l'entraînement. À droite : Étude des erreurs sur la base test.

Après de rapides analyses, ResNet 50 peut être écarté. Il n'arrive pas à converger, on remarque que sa courbe d'entraînement n'atteint pas de seuil, cela induirait qu'il a besoin de beaucoup plus d'Epoch pour tendre vers une valeur finale. Cela peut être dû au fait que le réseau ResNet a une particularité par rapport aux autres architectures. Il possède des connexions résiduelles, ce qui signifie que la sortie des couches précédentes est reliée à la sortie des nouvelles couches. Ce principe permet l'utilisation de réseau très profond. Mais dans notre cas, cela semble limiter la diminution du gradient et donc freine la convergence. On a donc choisi de ne pas garder ce modèle pour son temps de convergence.

Ensuite, en regardant plus dans le détail, on remarque que DenseNet à un entraînement assez proche des deux autres, mais reste à un niveau d'erreur supérieur. Malgré tout, une moyenne globale des erreurs sur la totalité de la base de données tests est de 0,37 GPa, cela est acceptable par les critères émis pour cette étude, mais les deux autres font mieux.

Il reste donc l'architecture VGG et le réseau LambWaveNet. Regardons les résultats de plus près.




Figure 3.4 Comparaison des erreurs entre LambWaveNet et VGG

Pour ce qui est de l'entraînement, cela n'a pas de majeures d'importance, puisque les deux convergent très rapidement vers des valeurs de MSE très faibles, aux alentours de 0,1 pour LambWaveNet et 0,15 pour VGG. Ensuite, il est intéressant d'observer les erreurs commises par les deux architectures. LambWaveNet reste le plus performant, VGG a plus de difficultés avec des modules d'Young élevés. Cela peut s'expliquer par le fait que : comme nous avons moins de données pour ces valeurs et que LambWaveNet possède une plus petite architecture, alors, il aurait besoin de moins de données pour atteindre des résultats satisfaisants. Contrairement à VGG, qui avec ses millions de variables a plus de mal lorsqu'il manque de données. Cette différence se reflète également sur les résultats globaux. LambWaveNet a une erreur moyenne égale à 0,09 GPa alors que VGG obtient 0,15.

C'est pour ces raisons que l'étude a continué avec mon architecture. En outre de ces bons résultats, il est important d'ajouter que le réseau s'entraîne beaucoup plus rapidement que les modèles profonds cités ci-dessus. Également, le réseau est plus petit et donc plus compréhensible, on peut se permettre de modifier des paramètres pour étudier leurs influences. Alors que VGG a beaucoup de variables, ce qui ne permet pas d'interpréter l'aspect physique d'une image passant dans le réseau.

3.1.3 Expériences sur des plaques collées durant le durcissement

Après avoir validé le modèle, on peut se concentrer sur les données expérimentales. Comme évoqué dans la méthodologie, le réseau a d'abord été testé sur des joints que l'on a fabriqués. Un résultat charnière de ce projet a été l'étude d'un échantillon collée au cours de la phase de durcissement. Deux plaques d'aluminium ont été assemblées avec un époxy trouvé dans le commerce, une fois la colle appliquée, des mesures ultrasonores ont été réalisées toutes les heures. Puis, en parallèle l'inversion de ces différentes mesures est effectuée et voici les résultats.




Figure 3.5 Suivi du durcissement

L'effet du séchage sur l'échantillon collé est visualisé à la figure 3.5. Effectivement, on observe que plus le temps passe, plus le module élastique augmente, et donc plus les plaques sont fixées. Un tel graphique laisse supposer que l'inversion fonctionne, car l'algorithme renvoie ce à quoi l'on s'attendait. Une autre remarque peut porter sur l'estimation finale qu'obtient le joint. Une fois durcie, la colle aurait une valeur de 3,5 GPa ce qui correspond au module de ce type d'époxy (tout de même non fournis par le manufacturier). Cette expérience se réfère à l'étude similaire effectuée par Daniel Pereira dans son article (Pereira & Belanger, 2019).

3.2 Résultats sur les joints collés du CNRC

L'acquisition d'assemblages collés auprès du CNRC permet d'appliquer la méthode sur des échantillons de qualités différentes. Ceux-ci sont réalisés avec des plaques d'aluminium de 2 mm alors qu'auparavant les travaux étaient menés sur des plaques de 1 mm. Cela a entraîné des perturbations pour l'acquisition des données. Il a été vu dans la méthodologie que suite à des problèmes de FFT2D bruitées deux solutions de résolutions ont été proposées.

On peut également évoquer que très rapidement pendant nos expériences un des échantillons s'est brisé. Ainsi, au lieu de travailler sur six, seulement des résultats sur cinq joints seront présentés. Les échantillons sont nommés par leurs numéros, on aura l'assemblage T1, T2..., T6.

3.2.1 Données du CNRC

Il faut rappeler que les tests sur les joints du CNRC ont été réalisés à l'aveugle. On n'avait aucune connaissance de leurs résistances mécaniques. Cependant, dans ce paragraphe il est présenté les spécificités des joints et leurs résistances, que le CNRC peut certifier.

Tout d'abord, l'adhésif que les chercheurs ont utilisé est un époxy Loctite 9 460 qui a un module d'Young de 2,76 GPa. Il a servi à assembler tous les joints. Chaque joint a subi un traitement de surface particulier, énoncé dans le tableau 4. Ces traitements ont pour but de faire varier le niveau d'adhésion et donc d'obtenir des assemblages plus ou moins résistants. Ils nous ont également fourni un graphe de la contrainte maximale admissible en fonction des différentes méthodes (figure 3.6).

Tableau 3.2 Étude des traitements de surface des échantillons

Joint	Traitement de surface
T1	Un dégraissage à l'acétone.
T2	Aucun traitement de surfaces.
T3	Aucun dégraissage. Une fine couche d'huile a été déposée, puis essuyé avec un mouchoir.
T4	Aucun dégraissage. Une fine couche de silicone a été déposée sur le substrat.
T5	Aucun dégraissage. Des perles de verres ont été ajoutée à la zone collée.
T6	Aucun dégraissage. La moitié de la surface collée a été traitée au plasma.




Figure 3.6 Contrainte maximale admissible en fonction du traitement de surface

On rappelle que dans l'étude seulement 5 joints seront analysés, car l'échantillon T4 s'est brisé après une simple manipulation. Il était l'assemblage dénonçant la plus faible résistance. Ainsi, avec les échantillons restants, les joints 1 et 6 devraient avoir des modules d'Young similaires, les joints 2 et 5 seraient légèrement plus faibles. Et en dernier, le joint 3.

3.2.2 Résultat avec la méthode 1 ; analyse statistique des acquisitions

Une fois que le réseau de neurones est entraîné, l'étape d'inversion peut commencer. Il suffit de donner en entrée une image expérimentale au réseau et celui-ci renvoie le module d'Young estimé. Ainsi, les acquisitions évoquées dans la méthodologie sont utilisées comme image d'entrée, qui rappelons-le, semblaient contenir beaucoup de bruit (figure 3.7).




Figure 3.7 Exemple d'acquisition

Analysons les résultats. Pour les cinq joints, sept acquisitions sont réalisées, une estimation de chacune est produite par le réseau. Ces estimations peuvent être répétées, car chaque entraînement est différent. Pour limiter l'incertitude liée à un unique entraînement, le réseau est entraîné 10 fois et systématiquement toutes les mesures sont testées. Il y aura donc 10 estimations par mesure, et 70 par joint. Ce qui amène à compiler les résultats. Si autant de mesures sont faites, c'est pour valider la répétabilité de la méthode sur la plaque en entier et pour limiter les effets d'une évaluation aberrante. Voici le bilan de l'inversion de T1. La

moyenne sur 10 entraînements est affichée pour les sept acquisitions réalisées sur un échantillon.

Tableau 3.3 résultat de l'inversion sur la plaque numéros 1

Acquisitions	1	2	3	4	5	6	7
Moyenne de l'estimation, Module d'Young (GPa)	1.86	1.59	2.38	2.69	2.84	2.43	2.03
Écart type en (GPa)	0.32	0.46	0.55	0.40	0.52	0.56	0.38

La dispersion des résultats pour le joint T1 est très grande. Par exemple, les estimations moyennes varient de 1,59 GPa pour la mesure 2, à 2,84 GPa pour la mesure 5. De plus, ces prédictions sont le résultat de la moyenne de 10 entraînements. La dispersion est donc encore plus grande si l'on regarde uniquement chaque estimation. En effet, l'écart type sur la mesure 5 est de 0,52 GPa. Ces 7 mesures ont un écart type qui varie de 0,3 GPa à 0,6 GPa. Ce qui signifie que les estimations moyennes, en plus d'être surprenante, ne sont pas précises. Ces résultats ne sont pas satisfaisants. Ils montrent que le réseau a des difficultés à prédire ce qu'on lui envoie. Et le bilan ne répond pas aux critères mis en place.

Ensuite, pour tout de même analyser ces résultats nous avons voulu comparer les courbes de dispersion expérimentales avec celles estimées. Prenons par exemple la mesure 1 de la plaque T1, superposons l'acquisition réelle, avec la FFT2D ayant pour valeur simulé la moyenne des 10 inversions. C'est-à-dire, isolons dans la base de données simulée une FFT2D ayant pour module d'Young 1,86 GPa et superposons-la avec l'acquisition.

L'image de la figure 3.8 montre cette superposition. Les courbes de dispersion simulées correspondant à l'estimation sont représentées en rouge, et les courbes expérimentales sont en jaune. Sur cette figure, la FFT2D prédite est plutôt proche de la FFT2D réelle. Il s'agit

uniquement d'une analyse à l'œil, néanmoins il est intéressant d'observer si la superposition est bonne ou non.




Figure 3.8 FFT 2D mesuré superposé
avec la FFT 2D estimé

En effet, en répétant ce principe sur les autres mesures avec leurs propres estimations, la figure 3.9 est obtenue.

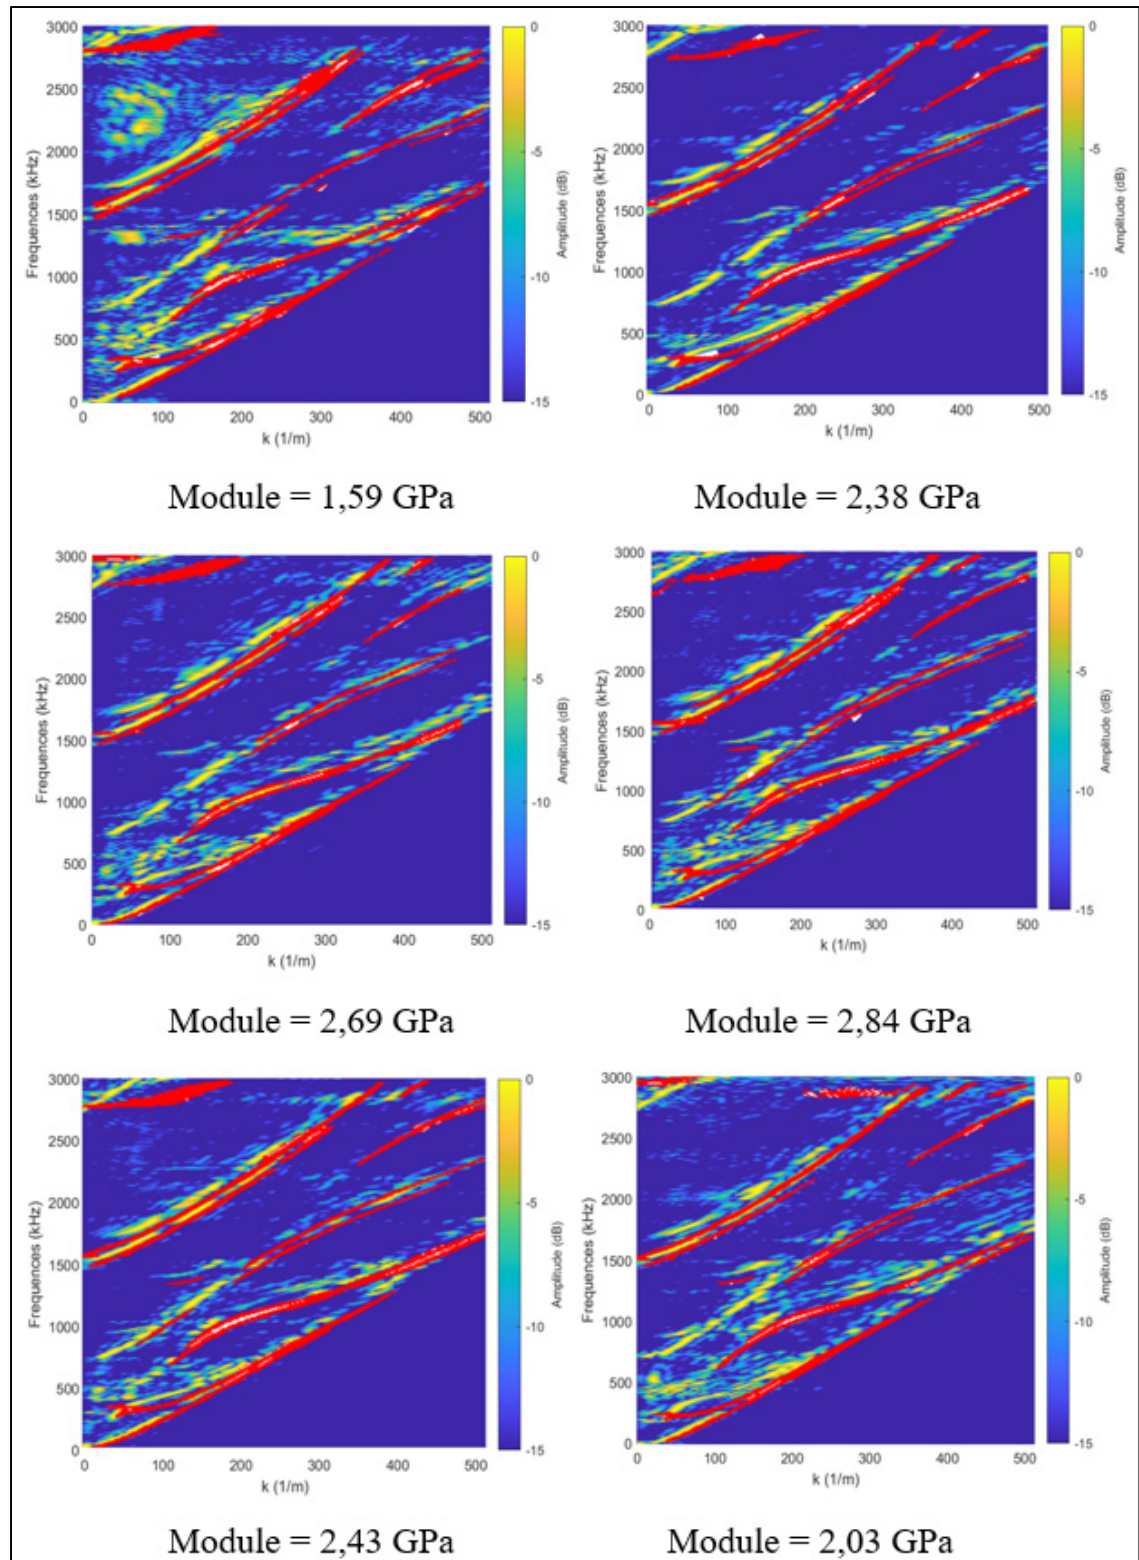


Figure 3.9 Dans l'ordre les mesure de 2 à 7 avec leur superposition estimée

En analysant toutes ses images, on remarque que la superposition est plutôt mauvaise pour les mesures 2 à 7. La première estimation est 'meilleure'. C'est encore plus flagrant si l'on se focalise sur la partie en bas à gauche de l'image, correspondant aux basses fréquences.

Ainsi, supposons que réellement l'inversion de la plaque T1 coïncide à l'estimation de la mesure 1. La superposition entre cette prédiction et les autres acquisitions de cette plaque peut être réalisée. Ainsi, sur la figure 3.10, on visualise l'estimation 1, un module de 1.86 GPa, superposé avec les mesures 2 à 7.




Figure 3.10 Superposition des mesures 2 à 7 avec l'estimation 1

En comparant les superpositions obtenues avec l'estimation de la mesure 1 sur les acquisitions, on peut visualiser qu'elles sont bien meilleures qu'avec leurs propres prédictions. En conclusion, cette méthode ne permet pas de réaliser une inversion stable. En effet, sur les 7

acquisitions, seule une estimation donne des résultats corrects. L'hypothèse est que le bruit résiduel empêche le réseau de neurones de converger vers la bonne estimation.

3.2.3 Résultats avec la deuxième méthode : superpositions des acquisitions

Pour la suite, les estimations seront réalisées à partir de la somme des acquisitions. En effet, dans la méthodologie il est remarqué que cette technique réduit le bruit des images. La méthode de superposition d'acquisitions détaillée dans le chapitre précédent permet d'avoir un signal plus propre, ou les courbes de dispersion sont facilement reconnaissables. Le principe est présenté dans la figure 3.11.




Figure 3.11 Image de gauche : Acquisition simple. Image de droite : superposition de 7 acquisitions

3.2.3.1 Analyses des résultats

De la même manière que dans partie précédente, plusieurs entraînements sont exécutés et la moyenne des estimations est faite pour déterminer la valeur du module d'Young. La différence est que cette fois si au lieu de sept acquisitions par joint, il y en a qu'une. Les résultats sont affichés pour les cinq joints.




Figure 3.12 Affichages des estimations pour 10 et pour 100 entrainements du réseau de neurones

Tableau 3.4 Résultats des moyennes des estimations des joints pour 100 entrainements

Joints	T1	T2	T3	T5	T6
Module d'Young estimé (GPa)	1.92	1.93	1.91	2.31	1.85
Écart type en GPa	0.52	0.49	0.45	0.55	0.39

Le réseau a de réelles difficultés à prédire la valeur du module d'Young d'une plaque collée. Si seulement peu d'inversions sont exécutées, il y a des interprétations non correctes, par exemple sur la figure 3.12, des différences entre les joints sont observées, alors que si 100 inversions sont lancées, les résultats sont beaucoup plus aléatoires et presque identiques. Et donc aucune conclusion ne peut être tirée sur une quelconque différence énoncée par le réseau.

Cependant, on peut tout de même essayer de superposer les valeurs estimées avec les valeurs réelles. Pour ce faire, on va chercher dans la base de données des simulations correspondant respectivement aux valeurs de module estimé par le réseau.

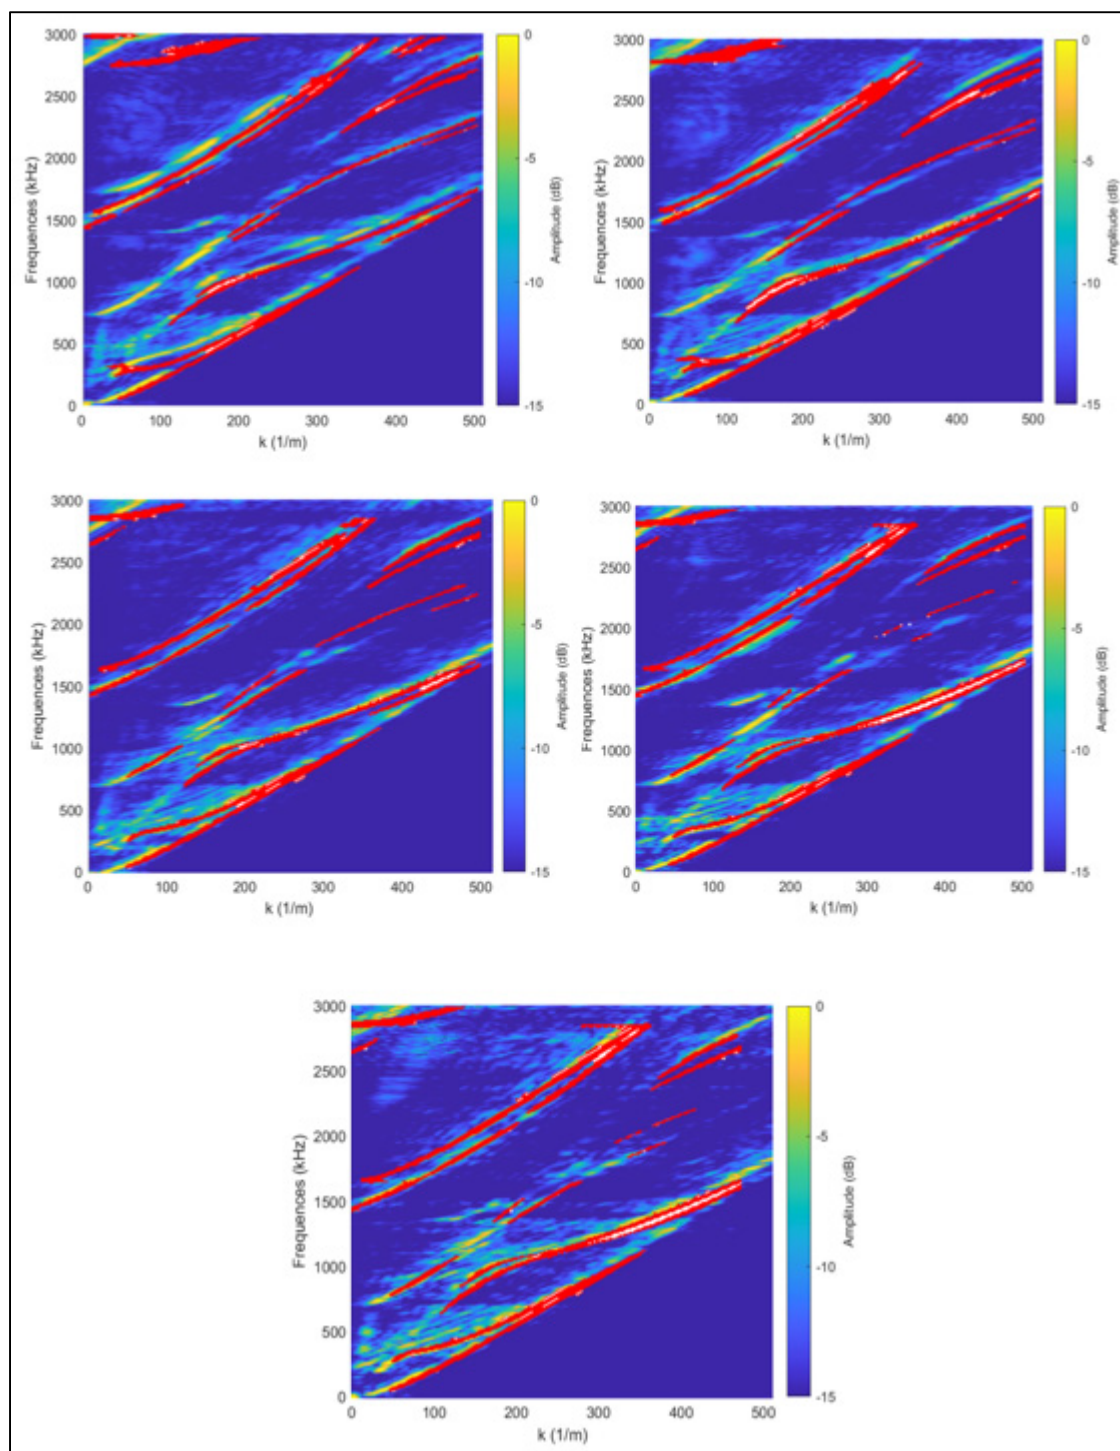


Figure 3.13 Mesure des différents joints avec leurs estimations superposées

La superposition des valeurs estimées semble meilleure que pour l'étude précédente, cela reste tout de même une évaluation à l'œil. Il y a des FFT2D qui se superposent plutôt bien comme la 3 ou la 4. Contrairement à la 6 où subsistent des problèmes, cela est peut-être induit par la procédure de fabrication particulière à ce joint, on testera plus tard sur celui-ci une autre méthode.

Finalement, à ce stade de l'étude les FFT2D ne sont pas différenciables, on ne peut pas affirmer quel joint est correctement collé ou non. C'est pourquoi, les travaux vont être poussés en étudiant qu'une partie de l'image, la partie en bas à gauche, qui a retenu notre attention lors de la superposition à l'œil. Il serait donc intéressant que le réseau de neurones porte également plus d'importance à cette zone.

3.2.3.2 Études de l'inversion d'une partie de la FFT2D

L'effet d'une focalisation du réseau de neurones sur une zone précise de l'image est analysé dans cette partie. En suivant la méthodologie associée, les données et notre réseau sont adaptés pour permettre la focalisation sur un carré de 50 pixels de large.

Une fois ces changements effectués, l'estimation du module d'Young peut être réalisée. Ces résultats sont présentés dans le tableau 3. Il est également affiché la superposition de l'estimation avec l'acquisition du joint T1 pour une zone de 50 pixels sur la figure 3.14. Et enfin, cette même superposition est affichée pour l'image entière.

Tableau 3.5 Résultat pour l'inversion d'une partie de la FFT2D

Joints	T1	T2	T3	T5	T6
Module	2.29	2.06	1.16	2.04	2.10




Figure 3.14 Superposition
de la zone étudiée




Figure 3.15 Superposition de la totalité de l'image

L'analyse de ses résultats est intéressante. Tout d'abord, les valeurs obtenues pour le module d'Young sont supérieures à celles des méthodes précédentes. On peut par exemple noter une différence entre le joint T3 et les autres. Mais à ce stade, l'attention est focalisée sur les superpositions et peu d'importance est accordée aux valeurs estimées. Lors de la visualisation de la superposition, on s'aperçoit que sur la plaque T1, la superposition ne correspond pas.

Ainsi, même lorsque le système d'inversion est simplifié, le réseau n'arrive toujours pas à converger vers une valeur qui visuellement semble correcte. Même lorsque l'on observe la superposition de cette valeur estimée avec l'image dans sa totalité.

En conclusion, même sur une petite zone de l'image les résidus de bruit sont encore trop conséquents et le réseau n'arrive toujours pas identifier une courbe de dispersion correspondante. On a donc voulu tester autre chose. Encore dans le cadre du réseau de neurones avec une entrée 50×50 pixels. Un filtrage très important sur l'acquisition a été réalisé. Le résultat est affiché dans la première partie de la figure 3.16. Le filtrage n'était pas aussi important auparavant, car beaucoup trop d'informations étaient perdues sur le reste de l'image. Mais, ici, cela semble intéressant, car la zone importante réagit bien avec un tel filtrage. On teste de nouveau la démarche sur ces données filtrées. On peut observer le résultat de l'estimation avec la partie droite de la figure 3.16.




Figure 3.16 Étude avec augmentation
du filtrage sur la zone à 50 pixels

L'estimation du réseau semble très proche de l'acquisition. Pourtant, un autre problème apparaît. Cette estimation, même si elle est très ressemblante, elle ne convient pas. Car, elle correspond à un module d'Young de 7 GPa. Cela parait au premier abord improbable. De plus, quand la totalité de la simulation est visualisée, le problème est évident. La figure 3.17 montre

que certes la partie de 50×50 pixels semble très bien correspondre. Mais le reste des courbes de dispersion n'ont rien à voir avec les acquisitions vu précédemment.




Figure 3.17 Données simulées correspondant à l'estimation du réseau

À la suite de l'analyse de ses résultats, une dernière méthode s'offre à nous. On a remarqué des améliorations du point de vue de la visualisation, lorsque le filtrage sur l'image de 50×50 a été effectué. Ainsi, une combinaison des deux méthodes vues précédemment va être tentée, dans le même réseau de neurones. C'est-à-dire, on va créer un réseau capable de pouvoir faire ce qu'il faisait au début, avoir une image ressemblante dans son ensemble. En ajoutant comme contrainte d'être précis dans une zone de l'acquisition.

3.2.3.3 Combinaison des deux méthodes, double réseau de neurones

Pour réaliser la combinaison des deux méthodes vues jusque-là, l'utilisation d'un double réseau de neurones sera mise en place. Pour l'entrée, les acquisitions globales de la méthode 2 (superposition d'acquisitions) sont conservées et pour les images de 50×50 pixels, les données filtrées présentées dans le paragraphe précédent sont utilisées. Pour visualiser les résultats, une

superposition des courbes simulés estimées avec les acquisition est affiché à la figure 3.19. L'étude de l'estimation du module d'Young est affichée à la figure 3.18.




Figure 3.18 Estimation numérique du double réseau




Figure 3.19 Superposition des estimations

Le but de cette approche était de pouvoir faire correspondre les courbes simulées avec les courbes expérimentales. La figure 3.19 montre des superpositions de qualité identique à celle vu précédemment. C'est-à-dire, la FFT2D estimée ne se superpose pas totalement à l'acquisition, surtout dans la zone de 50×50 pixels qui a été isolé. En premier abord, le double

réseau ne remplit pas ses fonctions, il permet d’avoir un aspect global de la FFT2D estimée correcte, mais la partie focalisée de l’image n’a pas une bonne superposition.

Cependant, l’observation des résultats numériques est très intéressante. Effectivement, on visualise que le réseau arrive à différencier clairement les différents échantillons. De plus, lorsque le nombre d’entraînements augmente, les estimations s’affinent et l’écart type réduit, contrairement aux résultats observés à la partie 3.2.3. Ainsi, les résultats observés par ce réseau restent tout de même imprécis, car les estimations peuvent varier, d’un entraînement à l’autre, de plus de 1 GPa pour le même joint. Mais le point important à retenir est que le réseau visualise des différences dans l’estimation des modules d’Young des joints. Et ces différences sont corrélées à la qualité de collage de chaque échantillon (Figure 3.20).




Figure 3.20 Comparaison des résultats avec ceux du CNRC

Comme évoqué dans la partie 3.2.1, les joints du CNRC ont subis des traitements de surface différents, qui leurs permettent d’avoir différentes contrainte maximum admissible (figure de droite). Les échantillons T1 et T6 ont la meilleure résistance à la rupture, d’après la documentation fournie par le CNRC. Or, pour notre réseau ils ont une estimation de module d’Young supérieur aux autres. De même, pour le joint T3, qui a le plus faible module d’Young et également une résistance moindre. Ainsi, ces résultats semblent prouver et valider l’hypothèse du projet. Elle stipule que dans le cadre de simulation parfaite, la variation du

module d'Young est corrélée à la variation de la contrainte maximale admissible et donc de la qualité du joint.

Cependant, il est nécessaire de rester modéré, puisque le réseau émet de bons résultats numériques, mais l'analyse de la superposition n'est pas correcte. Ainsi, ces résultats seront discutés dans le chapitre suivant. Avant cela, des tests supplémentaires ont été menés sur l'échantillon T6.

3.2.3.4 Résultat sur l'échantillons T6

L'assemblage T6, par sa conception est très intéressant dans l'étude de la qualité du joint. Effectivement, il a subi un traitement de surface particulier, la moitié de la surface collée n'est pas traitée et devrait se comporter comme le joint T2. Mais l'autre moitié a subi un traitement laser, qui permet une excellente adhésion entre la plaque d'aluminium et l'époxy. Ainsi, ce joint est en réalité composé de deux parties avec une première qui a une très bonne résistance et l'autre plutôt moyenne. La somme de ces deux joints équivaut environ à la qualité de T1, que l'on considère comme la référence (tableau 4). On a souhaité faire une mesure ultrasonore des deux moitiés respectives de l'assemblage, de sorte à isoler chaque traitement. Afin de savoir si on obtiendrait des résultats différents en réalisant l'inversion sur la moitié de l'assemblage uniquement. Les acquisitions sont représentées à la figure 3.21.




Figure 3.21 Acquisition partie gauche du joint T6, acquisition partie droite




Figure 3.22 Soustraction des FFT

Sur ces deux acquisitions, peu des différences sont décelées. La soustraction des deux FFT2D montre qu'il en réside, mais elles sont difficilement interprétables et semblent s'identifier à du bruit. Cependant, nous avons testé le réseau de neurones de la partie 3.2.2.1 et nous obtenons des résultats intéressants puisque l'une des acquisitions est sans exception supérieure à l'autre. Après chaque entraînement, nous obtenons un écart d'au moins 0,5 GPa entre les deux acquisitions. Toutefois, le réseau a toujours des problèmes de convergence, et nous n'avons pas de valeurs stables de module d'Young. La superposition avec une valeur théorique ne donne toujours pas satisfaction. Mais nous constatons quand même des résultats cohérents d'un point de vue numérique.

Finalement, nos résultats numériques sont bons, mais il est difficile d'apporter de réelle preuve que l'inversion fonctionne en tout temps. De plus, les superpositions faites avec les estimations ne sont jamais satisfaisantes. Ainsi, le prochain chapitre tirera le bilan de ce projet et évoquera des pistes d'amélioration du modèle.

CHAPITRE 4

DISCUSSIONS

L'analyse montre de solides résultats, beaucoup de choses fonctionnent, mais il reste des zones d'ombre avec les superpositions. On doit se poser plusieurs questions. Est-ce que la méthode d'inversion fonctionne réellement et est-il possible que les résultats acquis soient dus au hasard ? Pourquoi n'obtient-on pas des superpositions acceptables alors que le rendu numérique est cohérent ? Peut-on se fier à ses valeurs ? C'est à ces questions que l'on va tenter de répondre dans ce chapitre. Il faut tout d'abord essayer de cerner le problème en énonçant ce qui a fonctionné ou non. Puis, émettre des hypothèses concernant les aspects négatifs du projet. Enfin, suggérer des pistes pour réussir à prouver l'inversion de joint collé.

4.1 Bilan

Revenons sur ce qui a bien fonctionné dans le projet. Tout d'abord, la mise en place d'un réseau de neurones pour l'inversion de courbes de dispersion simulées semble tout à fait fonctionner. Différentes architectures ont été comparées et si la base de données est conséquente alors le réseau peut estimer une nouvelle simulation avec une erreur très faible. De plus, le suivi de durcissement d'un assemblage collé est également cohérent. Un graphe de l'évolution du module en fonction du temps a été obtenu et est en accord avec les résultats trouvés dans la littérature. Le réseau semble trouver le module d'Young d'une colle.

Ensuite, l'étape importante du projet est l'étude de joints de qualités différentes. Dans un premier temps, le réseau n'était pas capable de déterminer le plus résistant, mais avec plusieurs modifications de la structure, il a donné des prédictions répondant aux attentes. L'estimation du module d'un joint de bonne fabrication est supérieure à celle d'un assemblage faible. On rappelle notre hypothèse de base : il est possible de différencier la qualité d'un joint en utilisant les courbes de dispersion. Cette différence va se caractériser par un changement du module d'Young, dans le cadre d'une simulation parfaite où l'adhésif est considéré comme un solide homogène et isotrope. En vue des résultats de nos expériences, cette hypothèse est encore

acceptable et prometteuse. On est conscient que celle-ci n'est pas parfaite. Pour prouver scientifiquement le fonctionnement de l'inversion par réseau de neurones, cette hypothèse devra être modifiée ou alors le modèle devra subir des changements afin d'éviter l'énonciation de celle-ci.

Mais, ce qui pose problème est que lorsqu'on souhaite superposer l'estimation avec l'acquisition réelle. Les courbes de dispersion ne se superposent jamais correctement, la validation du modèle est remise en cause par cet aspect.

4.2 Hypothèse pour améliorer nos résultats

Dans un premier temps, l'hypothèse de base peut être remise en cause. Avec un premier débat, qui est : est-ce que physiquement il est possible de visualiser un changement de qualité de joint en observant seulement les courbes de dispersion ? En effet, même si cette hypothèse semble correcte en vue de nos derniers résultats, on pourrait se demander si d'autres preuves existent. Car, lorsque le module d'Young d'un échantillon varie, des différences dans les estimations sont observées, quand la colle sèche par exemple. Mais, peut-on réellement visualiser des variations de contrainte admissible dans les courbes de dispersion ? Pour répondre à cette question, on peut soustraire deux courbes de dispersions. À la figure 4.1, la FFT2D T1 est retranchée à T2. Il en découle que le résultat est proche, mais qu'il y a tout de même un changement puisque les acquisitions ne se superposent pas. Des différences entre toutes les courbes obtenues sont observées. Il semblerait donc que les FFT2D ne soient pas identiques entre chaque échantillon. C'est pour cette raison que l'hypothèse a été énoncée à la base.




Figure 4.1 Différence entre l'acquisition de la plaque T1 et T2

Observer que les courbes de dispersions ne sont pas identiques ne signifie pas que le réseau aura les moyens d'analyser ses différences. On arrive donc à un point critique de notre raisonnement. En effet, la principale hypothèse concernant la mauvaise superposition est en lien avec la base de données. Effectivement, le réseau n'arrive pas à faire corrélérer les simulations avec les mesures, peut-être car dans sa base de données, il n'a pas de FFT2D identique à l'acquisition. Par contre, il trouverait l'image la plus ressemblante. Et celle-ci, même si elle ne se superpose pas, remplit son travail puisque l'estimation numérique est bonne. Ainsi, peut-être que ce problème n'en est pas un, et que vouloir obtenir une FFT2D qui se superpose totalement est impossible, car on compare simulation et expérience.

En ce sens, on peut remettre en question dans notre étude, la volonté de toujours vouloir faire une focalisation sur la zone a base fréquence.




Figure 4.2 Résultat de la superposition de T1

En effet, on s'est énormément focalisé sur cette zone, elle semblait importante, car beaucoup de variations étaient visualisées. Elles ont été interprétées comme de l'information. Peut-être que le réseau n'a pas besoin de se focaliser sur cette partie pour déterminer qu'un assemblage est correctement collé. Peut-être qu'il privilégie d'autres modes.

Or, si le réseau n'a pas besoin de cette zone pour converger. On doit se remettre en question sur la réussite de ce projet. Car il faut rappeler que les résultats les plus cohérents ont été obtenus en combinant deux réseaux, dont l'un avait pour rôle de se focaliser sur les basses fréquences. Ainsi, si cette zone n'était pas indispensable, pourquoi le modèle fonctionnerait-il lorsqu'il se concentre sur celle-ci ? Cette question met en lumière un point d'ombre du projet, auquel nous n'avons pas encore toutes les réponses. On peut supposer que ce réseau trouve quand même de l'information nécessaire dans cette partie de l'image, même si la superposition n'est pas bonne. Ou alors, peut-être que cette restriction a évité au réseau de se focaliser sur

une autre zone qui permettrait la résolution de l'inversion du module d'Young, mais peut-être pas celle de la qualité du joint.

Une piste pour combler ses doutes est de travailler sur le modèle. En effet, un problème des simulations est qu'elle ne prend pas en compte l'interface de joint. Lorsque le réseau se focalise uniquement sur une zone précise, il n'arrive pas à retrouver des résultats de superpositions cohérents. Comme si, dans la base de données il n'y a pas le signal qui correspond parfaitement à notre FFT2D. Ainsi, l'idée pour tenter d'améliorer le modèle serait de créer une nouvelle base de données. En modélisant justement l'interface du joint, ces simulations produiraient des courbes de dispersion plus complexes. La superposition serait possible. Un modèle équivalent à l'article (Vlasie, de Barros, Rousseau, & Champaney, 2006) pourrait être implémenté.




Figure 4.3 Modélisation d'un joint collé
Tirée de Vlasie (2006, p. 4)

La figure 4.3 met en avant une autre façon de simuler un joint collé, en ajoutant de fines couches entre les surfaces adhésives/adhérent. C'est sur ces couches que se feront les variations d'élasticité, actuellement réalisée sur l'adhésif. Cette méthode serait très intéressante à mettre en place et permettrait peut-être la résolution de notre problème.

Un autre point important à souligner est le niveau de bruit dans les échantillons. Il fut difficile d'obtenir des acquisitions propres. L'utilisation de ruban réfléchissant a été testée sans amélioration. La recalibration du matériel n'a pas été concluante. Peut-être a-t-on fait des acquisitions sur une bande d'adhésive trop étroite (seulement 2 cm de zone collés). La volonté de réaliser ce type d'assemblage était de garantir la faisabilité des tests destructifs de joint à recouvrement pour vérifier nos résultats. Mais, cette fine bande d'adhésif est sans doute une

cause importante de bruit dans les signaux. Peut-être, il faudrait tester des acquisitions sur des joints avec une plus grande surface collée, pour éviter les effets de bords.

Un autre point à souligner est l'utilisation de superposition pour valider nos résultats. Cette approche semble pertinente et corrèle les difficultés rencontrées par le réseau de neurones. Mais tout au long de ce projet des analyses à « l'œil » ont été effectués. Cela est intéressant mais peu scientifique. Il faudrait mettre en place un outil qui permettrait de calculer précisément la qualité de superposition. L'utilisation de méthode comme le calcul de distance de Hausdorff ou l'algorithme SSIM serait une plus-value à ce projet et permettrait d'avoir une meilleure vision sur les qualités de superpositions et donc sur l'analyse que l'on tire des entraînements.

Finalement, dans l'optique d'élargir et d'améliorer la méthode, qu'il faudrait procéder l'inversion sur d'autres échantillons. Mettre en place des joints qui n'ont pas tous la même norme géométrique. Pour l'instant, de bons résultats ont été observés sur des assemblages avec des plaques d'aluminium de 2 mm d'épaisseurs. Ils ont été obtenus, car le réseau a été programmé sur des FFT2D simulées, pour des plaques d'une telle épaisseur. Ainsi, on pourrait imaginer un entraînement plus ambitieux venant faire varier différents paramètres géométriques et ensuite visualiser si le réseau est toujours capable de réaliser l'inversion de ces différents types de géométries.

CONCLUSION

Le bilan de ce projet est très encourageant, premièrement, la méthode mise en place, les réseaux de neurones convolutifs ont été capable de réaliser ce qui a été fait précédemment sur le sujet, déterminer le module d'Young d'un assemblage simulé. Également, le suivi du durcissement d'une résine époxy a été réalisé. Puis, les difficultés ont été surmontées, en mettant en place une méthode à double réseau capable d'estimer sur cinq joints de qualités différentes, s'ils sont correctement collés ou non. Ainsi, cette méthode a montré de bons résultats, mais il reste des étapes avant la valider totalement.

Premièrement, des difficultés avec l'acquisition du signal ont été observées, différentes méthodes ont été testées pour nous affranchir de ce problème, le plus efficace a été la superposition d'acquisitions, qui a réduit considérablement le bruit. Mais on ne peut pas affirmer que le problème du bruit dans nos éprouvettes est résolu. Deuxièmement, des problèmes au niveau de la superposition des acquisitions et des estimations sont visibles, ainsi, une piste pour régler cela serait de concevoir d'une façon différente les simulations des échantillons collés. Peut-être en ajoutant des couches intermédiaires entre chaque interface, et faire varier l'élasticité de celle-ci. Cette méthode pourrait améliorer l'identification de la qualité du joint. Enfin, il serait nécessaire de valider cette méthode sur d'autres types de joints, avec des colles différentes et des géométries différentes.

ANNEXE I

ARCHITECTURE DES RÉSEAUX

VGG :




Figure-A I-1 Architecture du réseaux VGG

DenseNet :

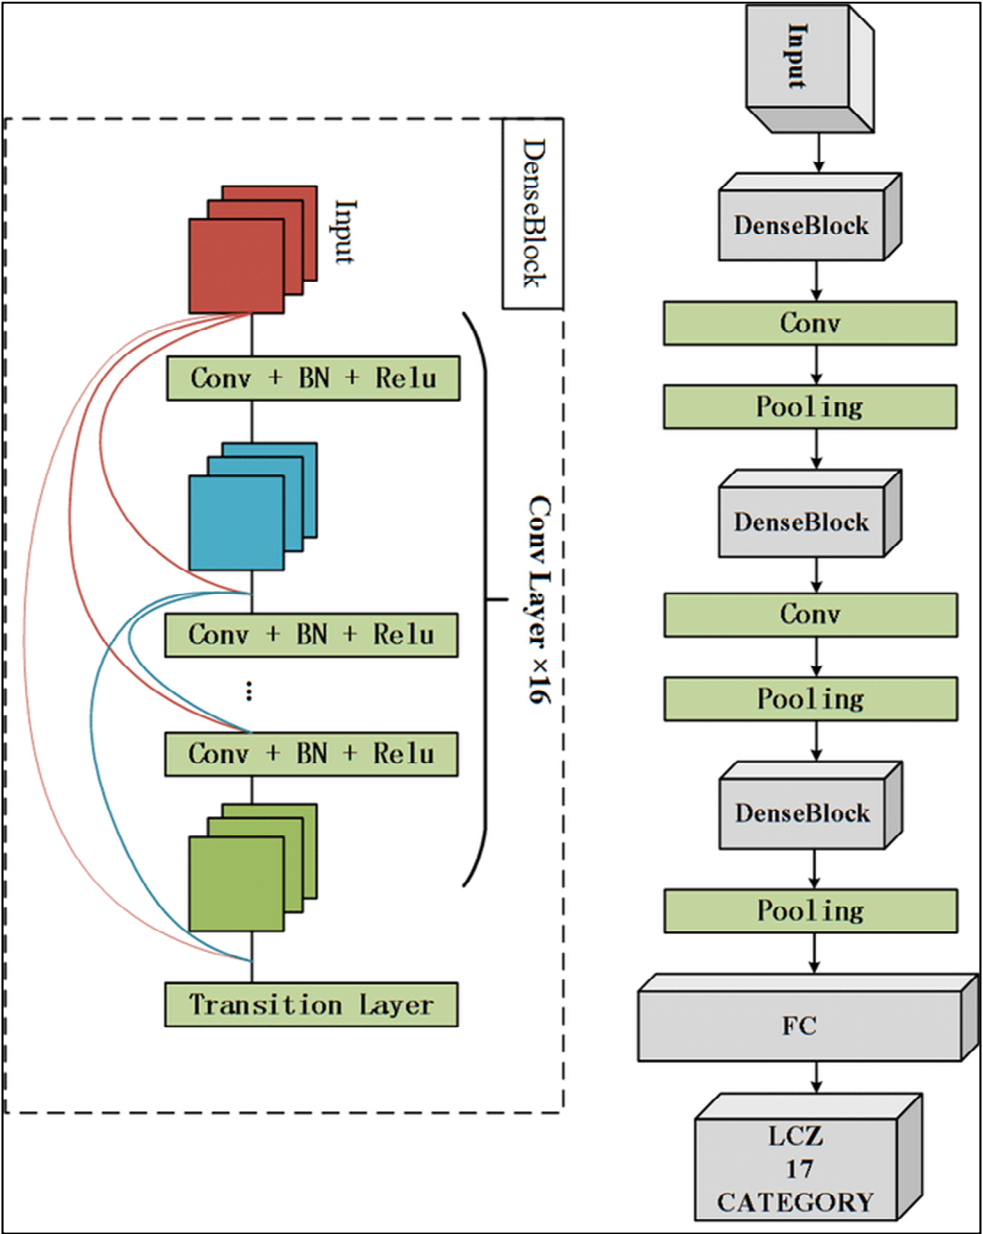


Figure-A I-2 Architecture du réseau DenseNet

ResNet :

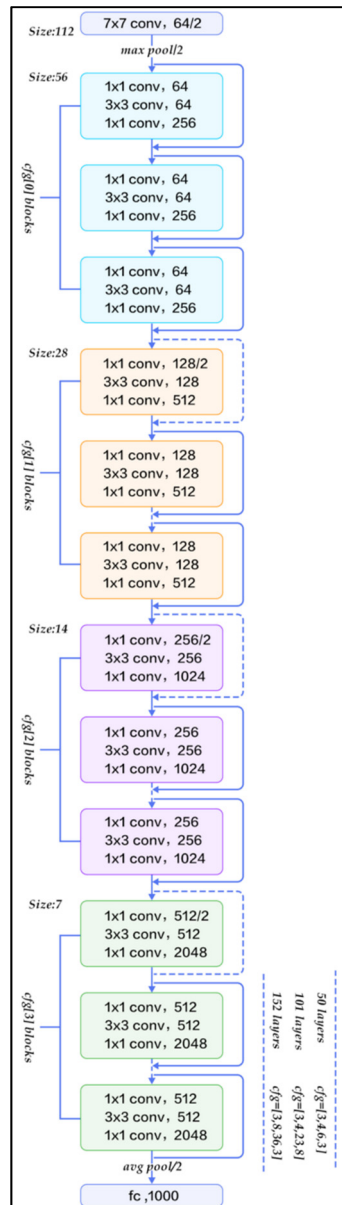


Figure-A I-3 Architecture du réseau DenseNet

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Adams, R. D. (2005). *Adhesive Bonding - Science, Technology and Applications* (CRC Press). Cambridge : CRC Press.
- Benhamena, A., Djebli, A., Aminallah, L., & Aid, A. (2016). Three-dimensional finite element analysis of fracture behaviour of adhesively bonded single lap-joints. *University of Mascara, Algeria*. doi : 10.5755/j01.mech.22.5.12879
- C. F. Quate, A. Atalar, & H. K. Wickramasinghe. (1979). Acoustic microscopy with mechanical scanning—A review. *Proceedings of the IEEE*, 67(8), 1092-1114. doi: /10.1109/PROC.1979.11406
- Cheeke, N., & David, J. (2002). *Fundamentals and applications of ultrasonic waves* (CRC Press). Boca Raton : CRC Press.
- Fan, Z., Castaings, M., Lowe, M. J. S., Biateau, C., & Fromme, P. (2013). Feature-guided waves for monitoring adhesive shear modulus in bonded stiffeners. *NDT & E International*, 54, 96-102. doi: /10.1016/j.ndteint.2012.12.006
- Ferguson, M., Ak, R., Lee, Y.-T. T., & Law, K. H. (2017). Automatic localization of casting defects with convolutional neural networks. *2017 IEEE International Conference on Big Data (Big Data)* (pp. 1726-1735). Boston, MA : IEEE. doi: /10.1109/BigData.2017.8258115
- Gacoin, A., Lestriez, P., Assih, J., Objois, A., & Delmas, Y. (2009). Comparison between experimental and numerical study of the adhesively bonded scarf joint and double scarf joint: Influence of internal singularity created by geometry of the double scarf joint on the damage evolution. *International Journal of Adhesion and Adhesives*, 29(5), 572-579. doi: /10.1016/j.ijadhadh.2009.01.006
- Gauthier, C., El-Kettani, M.-C., Galy, J., Predoic, M., & Leduc, D. (2020). Structural adhesive bonding characterization using guided Lamb waves and the vertical modes. *International Journal of Adhesion and Adhesives*, 98, doi: /10.1016/j.ijadhadh.2019.102467

- Grant, L. D. R., Adams, R. D., & da Silva, L. F. M. (2009). Experimental and Numerical Analysis of T-peel Joints for the Automotive Industry. *Journal of Adhesion Science and Technology*, 23(2), 317-338. doi: /10.1163/156856108X383529
- Li, X., Sun, J., & Tao, N. (2018). An Effective Method to Inspect Adhesive Quality of Wind Turbine Blades Using Transmission Thermography. *J Nondestruct Eval*, 37. doi: /10.1007/s10921-018-0473-5
- Li, Y., Xu, K., Li, Y., Xu, F., & Ta, D. (2021). Deep Learning Analysis of Ultrasonic Guided Waves for Cortical Bone Characterization. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*. doi: 10.1109/TUFFC.2020.3025546
- Lizaranzu, M., Lario, A., Chiminelli, A., & Amenabar, I. (2015). Non-destructive testing of composite materials by means of active thermography-based tools. *Infrared Physics & Technology*, 71, 113-120. doi: /10.1016/j.infrared.2015.02.006
- P. Kingma, D., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *Published as a conference paper at the 3rd International Conference for Learning Representations*. doi : /10.48550/arXiv.1412.6980
- Pavlakovic, B., Lowe, M., Alleyne, D., & Cawley, P. (1997). Disperse: A General Purpose Program for Creating Dispersion Curves. *Dans D. O. Thompson & D. E. Chimenti (Éds), Review of Progress in Quantitative Nondestructive Evaluation: Volume 16A* (pp. 185-192). Boston, MA : Springer US. doi:/10.1007/978-1-4615-5947-4_24
- Pereira, D., & Belanger, P. (2019). Inverse characterization of adhesive shear modulus in bonded stiffeners using ultrasonic guided waves. *AIP Conference Proceedings*. doi: /10.1063/1.5099772
- Pereira, D., Le Duff, A., Painchaud-April, G., & Belanger, P. (2022). Simulation-Based Inversion for the Characterization of Adhesively Bonded Joints Using Ultrasonic Guided Waves. *IEEE 2nd Workshop on Advances in Information*. doi: 10.1109/TUFFC.2022.3175773
- Roach, D., Rackow, K., & Duvall, R. (2010). Innovative Use of Adhesive Interface Characteristics to Non-Destructively Quantify the Strength of Bonded Joints, *sandia national laboratories* 16. Repéré à <https://www.osti.gov/biblio/1019079>

- Rose, J. (1999). Ultrasonic waves in solid media. Cambridge : *Cambridge University Press*. doi: 10.1017/CBO9781107273610
- Vlasie, V., de Barros, S., Rousseau, M., & Champaney, L. (2006). Ultrasonic rheological model of cohesive and adhesive zones in aluminum joints: validation by mechanical tests. *Archive of Applied Mechanics*, 75(4), 220-234. doi: /10.1007/s00419-005-0401-x
- W. T. Cochran, J. W. Cooley, D. L. Favin, H. D. Helms, R. A. Kaenel, W. W. Lang, ... P. D. Welch. (1967). What is the fast Fourier transform? *Proceedings of the IEEE*, 55(10), 1664-1674. doi: /10.1109/PROC.1967.5957
- Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2020). *Advances in deep learning*. Singapore : (s.n.). Repéré à 10.1007/978-981-13-6794-6
- Willemann, D. P., Fantin, A., & Albertazzi, A. (2010). Defect assessment of bonded joints of composite tubes using shearography, *speckle 2010*. doi: /10.1117/12.870680
- Wojtczak, E., & Rucka, M. (2021). Monitoring the curing process of epoxy adhesive using ultrasound and Lamb wave dispersion curves. *Mechanical Systems and Signal Processing*, 151. doi: /10.1016/j.ymssp.2020.1

