

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
REVUE DE LITTÉRATURE	3
1.1 Introduction aux ultrasons et aux ondes de volumes	3
1.1.1 Les équations	3
1.1.2 Comportement d'un ultrason aux interfaces	6
1.1.3 L'atténuation	8
1.2 La déconvolution	9
1.2.1 La théorie	9
1.2.2 L'application en pratique	11
1.3 Les réseaux de neurones	12
1.3.1 Le modèle du perceptron	12
1.3.2 Le réseau de neurones convolutif	14
1.3.3 Les CNN pour le traitement du signal	17
1.4 Imagerie : Méthode de focalisation en tout point	18
CHAPITRE 2 DECONVOLUTION OF ULTRASONIC SIGNALS USING A CONVOLUTIONAL NEURAL NETWORK	23
2.1 Abstract	23
2.2 Introduction	24
2.3 Material and Methods	27
2.3.1 Finite Element simulated dataset	27
2.3.2 Architecture of the CNN	28
2.3.3 Training the CNN with simulations	31
2.3.4 Experimental setup	35
2.4 Results	36
2.5 Discussion	41
2.6 Conclusion	43
2.7 Acknowledgements	44
CHAPITRE 3 EXEMPLES D'APPLICATION EN IMAGERIE	45
3.1 Introduction	45
3.2 Augmentation de la résolution des images ultrasonores	45
3.3 Vers le contournage d'un défaut	47
3.4 Conclusion sur l'imagerie	50
CONCLUSION ET RECOMMANDATIONS	53
BIBLIOGRAPHIE	55

LISTE DES TABLEAUX

	Page
Tableau 2.1	Results of the CNN deconvolution on the raw experimental A-Scans 37
Tableau 2.2	Results of the CNN deconvolution on the experimental A-Scans with the noise synthetically increased to reach an SNR of 20 dB 39
Tableau 2.3	Results of the CNN deconvolution on the experimental A-Scans with the noise increased to reach an SNR of 5 dB 39
Tableau 2.4	Effect of the threshold value on the deconvolution of the experimental measurements with an SNR of 5 dB 40
Tableau 2.5	Results of the three CNN tested with experimental measurements with different added noise values 40

LISTE DES FIGURES

	Page
Figure 1.1	Propagation d'une onde acoustique de volume 5
Figure 1.2	Représentation de la propagation d'un rayon ultrasonore à travers (a) une interfaces solide/solide et (b) une interface liquide/solide..... 7
Figure 1.3	Schéma d'un perceptron 12
Figure 1.4	Schéma d'un réseau de neurones avec deux couches cachées, quatre entrées et deux sorties 13
Figure 1.5	Le filtre de convolution glisse dans la direction x 16
Figure 1.6	Différentes méthodes d'étiquetage des données pour l'entraînement d'un réseau de neurones 16
Figure 1.7	Illustration d'une acquisition de type FMC 19
Figure 1.8	Plusieurs artéfacts de reconstruction sont visibles sur la TFM, les interfaces simulées sont tracées en rouge 21
Figure 2.1	Schematic of the FE model 28
Figure 2.2	Architecture of the CNN 29
Figure 2.3	Learning curve and loss function as a function of epoch 30
Figure 2.4	A typical A-Scan (s) with its three components : (g) the position of the reflectors, (p) the input signal and (n) the noise 31
Figure 2.5	Preparation of the simulated training batch for the CNN 32
Figure 2.6	FE simulated A-Scan 33
Figure 2.7	Noise extracted from the preliminary experimental measurements, after normalization..... 33
Figure 2.8	Simulated A-Scan used for CNN training after domain adaptation. The expected output corresponds to spikes at the beginning of the signals of interest 34
Figure 2.9	Aluminum block with different FBH depths and the Olympus V125-RM probe 35

Figure 2.10	Five reflections from the backwall of an aluminum block using an Olympus V125-RM probe centered at 2.25 MHz : (a) 5 time traces and (b) the averaged frequency spectrum	36
Figure 2.11	Location of reflectors in a raw A-Scan for an FBH with a depth of 0.69 mm	37
Figure 2.12	Location error in function of the distance to the nearest reflector	38
Figure 2.13	Example of an FBH detected with an SNR of 5 dB. The FBH depth was 0.96 mm	39
Figure 2.14	Comparison of the proposed CNN framework with the least-squares deconvolution. The FBH had a depth of 1.65 mm. (a) Raw experimental A-Scans and (b) SNR reduced to 20 dB	41
Figure 2.15	Examples of (a) misplaced and (b) non-detected reflectors with a 5 dB noise	43
Figure 3.1	À gauche, la sonde multi-élément et le bloc inspecté et à droite, un schéma en coupe du bloc	46
Figure 3.2	Comparaison de deux images obtenues par une TFM : à gauche, la TFM standard et à droite, la TFM obtenues avec les A-Scans pré-traités.....	47
Figure 3.3	Bloc en acier inoxydable percé de trous de côté à contourner	48
Figure 3.4	Schéma de l'arc apparent du point de vue du transducteur	48
Figure 3.5	À gauche, un trou de côté représenté avec la méthode TFM classique, à droite, le même trou représenté avec les signaux pré-traités par le CNN.....	49

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

SNR	Rapport signal sur bruit (<i>Signal-to-Noise Ratio</i>)
SHM	Contrôle de l'intégrité des structures (<i>Structural Health Monitoring</i>)
CNN	Réseau de neurones convolutif (<i>Convolutional Neural Network</i>)
SVM	Machine à vecteur de support (<i>Support Vector Machine</i>)
LSTM	Réseau de neurones convolutionnel (<i>Long Short-Term Memory</i>)
1D	Une dimension
2D	Deux dimensions
3D	Trois dimensions
ToF	Temps de vol (<i>Time of Flight</i>)
PULÉTS	Piezoelectricity, Ultrasound and material Laboratory ÉTS

LISTE DES SYMBOLES ET UNITÉS DE MESURE

E	Module d'Young
ρ	Masse volumique
ν	Coefficient de Poisson
λ	Longueur d'onde
s	Seconde
m	Mètre
mm	Millimètre
Hz	Hertz
dB	Décibel
α	Coefficient d'atténuation acoustique

INTRODUCTION

Le contrôle non destructif (CND) vise à inspecter une pièce ou une structure en respectant son intégrité. Une multitude de moyens ont été développés dans ce but : du simple contrôle visuel à des techniques plus sophistiquées utilisant les rayons X, les courants de Foucault ou les ultrasons. Toutes ces méthodes sont complémentaires et le choix de l'une ou de l'autre repose sur un compromis sur la nature du défaut qu'on s'attend à observer : une fissure ou une inclusion, sur sa localisation : en surface ou dans le volume, sur son orientation, sur le matériau et la géométrie de la pièce à inspecter, sur le contexte de la mesure, etc. On utilise le CND principalement là où la rupture d'une pièce pourra avoir des conséquences graves et coûteuses. Les industries de l'énergie, surtout fossile et nucléaire, et aussi l'aéronautique sont très demandeuses de ces procédés. Le recours au CND autorise une maintenance préventive permettant d'économiser beaucoup en optimisant le remplacement de pièces dispendieuses.

Le contrôle ultrasonore est maintenant une méthode d'inspection non destructive et non invasive bien maîtrisée. Il est encore la technique de CND la plus employée dans l'industrie en raison de sa simplicité conceptuelle, sa très large gamme d'utilisation. Cependant, les instruments de mesures sont par définitions imparfaits : ils ont une bande-passante réduite, ils résonnent à certaines fréquences et créent alors du bruit. La géométrie de la pièce ou la technique de reconstruction peuvent provoquer des artefacts non désirés et inutiles pour ce que l'on veut observer. Il est toujours tentant d'améliorer la qualité d'une mesure sans agir sur le capteur ou le système d'acquisition dont le remplacement est souvent coûteux. Ainsi le traitement du signal ou de l'image offre une méthode efficace et économique pour supprimer des données non pertinentes ou erronées. Par exemple, il est très commun de réduire l'effet du bruit par l'application d'un filtre passe-bas sur le signal.

Un aspect important du CND est la formation des contrôleurs, des inspecteurs et leur certification. Les fournisseurs de matériels de contrôles non destructifs, nombreux au Québec,

cherchent à rendre leur produit toujours plus facile d'utilisation en fournissant via l'interface les données les plus pertinentes et essaient de fournir aux techniciens le plus d'assistance possible en temps réels.

Le contrôle ultrasonore possède une limite de résolution axiale égale à une demi longueur d'onde. Il serait en théorie possible de la dépasser en utilisant l'opération de déconvolution. Si en simulation, la méthode donne de bons résultats, en pratique, elle est beaucoup moins efficace. D'où l'idée de changer de méthode en utilisant des réseaux de neurones. La généralisation de l'utilisation des réseaux de neurones depuis une dizaine d'années vise à aider et à assister l'Homme dans la prise de décision. Les résultats sont très encourageants et les algorithmes atteignent les performances humaines dans certains cas.

L'idée de cette étude est de développer un moyen économique pour entrainer un réseau de neurones apte à localiser de manière fiable des réflecteurs très proches de la surface placés dans un bloc d'aluminium. Le premier chapitre rappellera les connaissances nécessaires en ultrasons et présentera rapidement les notions d'apprentissage machine utilisée pour cette étude. Le second chapitre sera constitué d'un article, soumis au journal *Ultrasonics*, décrivant une méthode de traitement du signal utilisant des réseaux de neurones convolutifs et les résultats expérimentaux obtenus.

REVUE DE LITTÉRATURE

1.1 Introduction aux ultrasons et aux ondes de volumes

Une onde ultrasonore est un phénomène de propagation d'une perturbation mécanique dans un milieu matériel à une fréquence supérieure à 20 kHz, ce qui signifie qu'elle est hors du spectre audible par l'humain. L'étude des ultrasons constitue maintenant un domaine de la physique et a déjà été largement détaillé dans le cadre du contrôle non destructif par Sapriel (1994); Cheeke (2002) ou Shull (2002).

1.1.1 Les équations

Les liaisons entre les particules dans un solide sont modélisables par un système masse-ressort (Cheeke, 2002). C'est à partir de cette hypothèse que d'Alembert, en combinant les lois de Hooke et de Newton, mit en place l'équation d'onde au 18^{ème} siècle dans un milieu unidimensionnel, isotrope et homogène, l'équation de propagation :

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

où u est le déplacement de la particule et c la vitesse de propagation de la perturbation dans le milieu. x est la position et t le temps. La solution générale de cette équation pour une onde se propageant dans un milieu matériel :

$$u(x,t) = f(x - c \cdot t) + g(x + c \cdot t) \quad (1.2)$$

avec f et g deux fonctions arbitraires. Le premier terme correspond à une propagation dans le sens des x positifs et le second à une propagation dans le sens des x négatifs. Dans le cas où l'excitation provoquant la perturbation est sinusoïdale et où la propagation est dans le sens des x positifs, l'équation devient :

$$u(x,t) = A \cos \left(\omega \left(t - \frac{x}{c} \right) \right) \quad (1.3)$$

où A est l'amplitude initiale de l'onde, ω sa pulsation et c sa vitesse de propagation à la pulsation ω . Cette équation est élargie en 3D juste après par Euler pour une onde plane dans un solide isotropique (Shull, 2002). Dans ce cas l'équation de propagation est :

$$\rho \frac{\partial^2 u_i}{\partial t^2} = \frac{\partial T_{ij}}{\partial x_j} \quad (1.4)$$

où T_{ij} est le tenseur des contraintes définis par la loi de Hook généralisée :

$$T_{ij} = c_{ijkl} S_{kl} \quad (1.5)$$

avec c_{ijkl} le tenseur d'élasticité et S_{kl} le tenseur des déformations. Dans la mesure où le matériel est isotrope, on peut écrire :

$$\rho \frac{\partial^2 u_i}{\partial t^2} = \frac{\partial}{\partial x_j} \left[(c_{11} - c_{44}) \frac{\partial u_j}{\partial x_i} \right] + c_{44} \frac{\partial u_i^2}{\partial x_j^2} \quad (1.6)$$

c_{11} et c_{44} sont des éléments de la diagonale de la matrice d'élasticité du matériau isotrope. En passant à une notation vectorielle, on peut distinguer deux termes à droite :

$$\rho \frac{\partial^2 \vec{u}}{\partial t^2} = (c_{11} - c_{44}) \partial \vec{\nabla} \left(\vec{\nabla} \cdot \vec{u} \right) + c_{44} \Delta \vec{u} \quad (1.7)$$

On peut reconnaître dans les deux termes, les opérateurs rotationnel et divergent. La décomposition de Helmholtz permet de découpler le vecteur \vec{u} avec un champ scalaire Φ et un champ vectoriel $\vec{\Psi}$:

$$\vec{u} = \vec{\nabla} \Phi + \nabla \times \vec{\Psi} = \vec{u}_L + \vec{u}_T \quad (1.8)$$

où \vec{u}_L est la composante de \vec{u} normale au plan de propagation et \vec{u}_T est la composante dans le plan de propagation. On peut en déduire deux équations indépendantes :

$$\begin{cases} c_{11} \Delta \Phi - \rho \frac{\partial^2 \Phi}{\partial t^2} = 0 \\ c_{44} \Delta \Psi - \rho \frac{\partial^2 \Psi}{\partial t^2} = 0 \end{cases} \quad (1.9)$$

La première concerne le mouvement des particules normal au plan de propagation et la seconde le mouvement dans le plan de propagation. On peut remarquer que ces deux modes ne se propagent pas à la même vitesse.

Ainsi on peut distinguer deux modes de propagation d'un ultrason, schématisés dans la figure 1.1. \vec{u} est le vecteur déplacement des particules et \vec{k} est le vecteur d'onde colinéaire à la direction de propagation de l'ultrason. Une onde longitudinale provoque un déplacement des particules dans la même direction que le trajet de l'onde et une onde transversale provoque un déplacement des particules normal à la direction de propagation des particules. Les ondes transversales ne peuvent se propager que dans un solide ou dans un fluide extrêmement visqueux moyennant une forte atténuation.

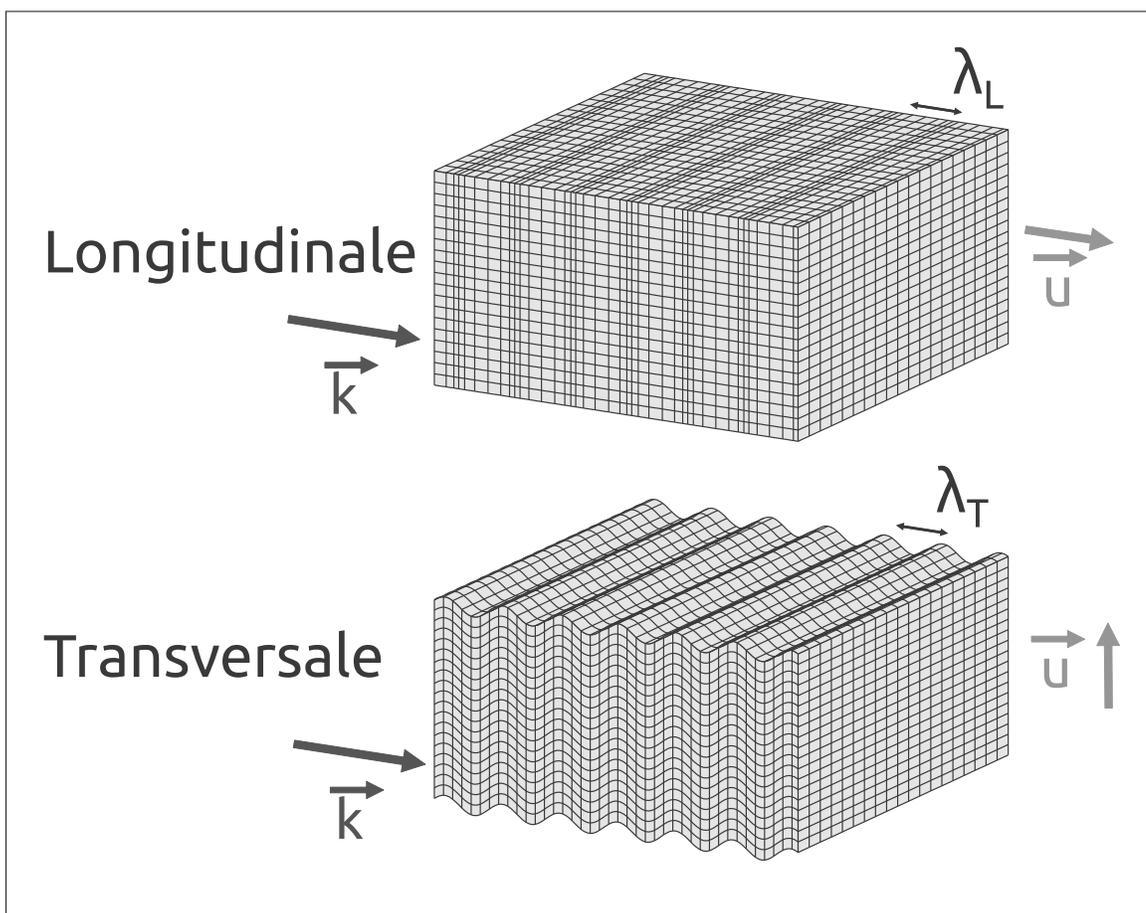


Figure 1.1 Propagation d'une onde acoustique de volume

La différence de comportement des ondes longitudinales et transversales fait qu'elles ne progressent pas à la même vitesse dans les solides. Elles sont définies par les caractéristiques du matériau dans lequel l'ultrason se propage.

$$\begin{cases} c_L = \sqrt{\frac{c_{11}}{\rho}} = \sqrt{\frac{E(1-\nu)}{\rho(1+\nu)(1-2\nu)}} \\ c_T = \sqrt{\frac{c_{44}}{\rho}} = \sqrt{\frac{E}{2\rho(1+\nu)}} \end{cases} \quad (1.10)$$

c_L et c_T sont respectivement les vitesses des parties longitudinale puis transversale de l'onde.

1.1.2 Comportement d'un ultrason aux interfaces

Quand une onde ultrasonore rencontre une interface entre deux milieux isotropes, une partie de l'énergie est réfléchiée et le reste est transmis suivant la loi de Snell-Descartes.

$$\frac{\sin \theta_i}{c_i} = \frac{\sin \theta_{iL}}{c_{iL}} = \frac{\sin \theta_{iT}}{c_{iT}} \quad (1.11)$$

où θ_i , θ_{iL} et θ_{iT} sont respectivement les angles de l'onde incidente, de l'onde transmise longitudinale et de l'onde transmise transversale. c_i , c_{iL} et c_{iT} sont leurs vitesses respectives. Il faut noter que dans un milieu peu visqueux, les ondes transversales s'atténuent fortement et peuvent suivre un régime purement dissipatif. Par conséquent, elles n'ont pas vitesses et l'équation de Snell-Descartes ne s'appliquent pas.

Une multitude de cas différents sont envisageable : des interfaces solide/solide, solide/liquide, etc. Deux d'entre eux sont présentés dans la figure 1.2. Dans le premier cas, l'interface est solide/solide. Dans le second cas, le milieu de l'onde incidente étant liquide, il n'y a pas d'onde réfléchiée transversale.

Il est possible de déterminer la part d'énergie transmise T et réfléchiée R en fonction de l'impédance acoustique de chaque matériau. L'impédance acoustique Z est fonction de la vitesse de

son c dans le milieu et de la masse volumique ρ du matériau :

$$Z = \rho \cdot c \quad (1.12)$$

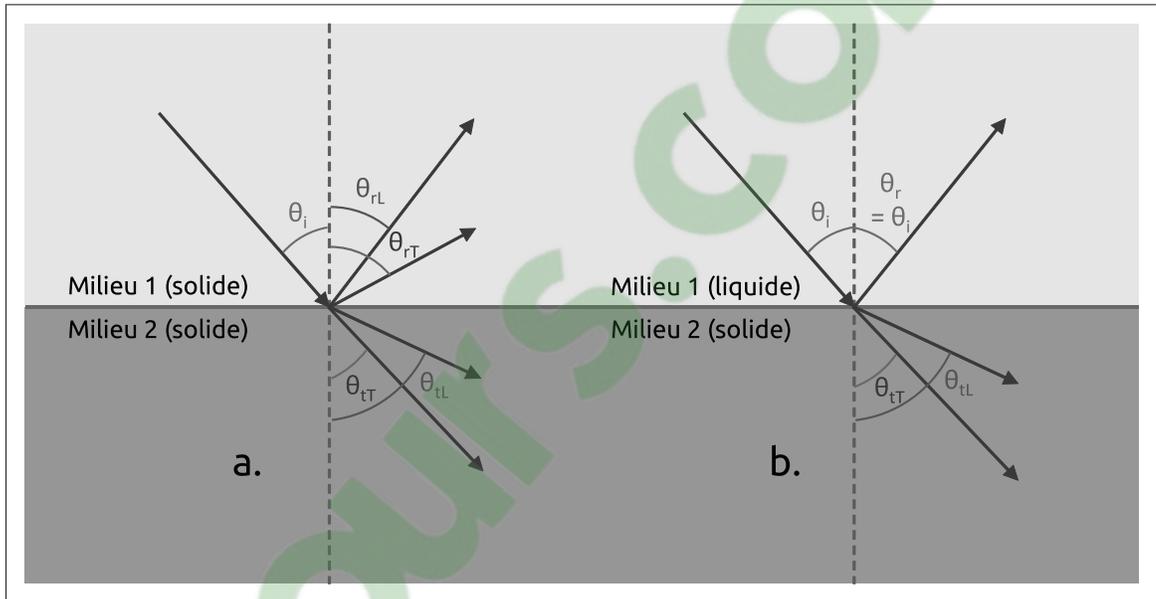


Figure 1.2 Représentation de la propagation d'un rayon ultrasonore à travers (a) une interfaces solide/solide et (b) une interface liquide/solide

Dans le cas d'une onde ayant une incidence normale à une interface entre le milieu 1 et le milieu 2, on peut facilement calculer la part d'énergie transmise et d'énergie réfléchi :

$$R = \frac{Z_2 - Z_1}{Z_2 + Z_1} \quad T = \sqrt{1 - R^2} \quad (1.13)$$

Un transducteur capte le déplacement des particule à la surface de la pièce et le transforme en courant électrique qui sera envoyé à un système d'acquisition. Avec les délais entre l'émission et la réception, on peut déduire la position des réflecteurs et avec la phase des signaux on peut connaître la nature des interfaces rencontrées.

1.1.3 L'atténuation

L'atténuation d'une onde ultrasonore se manifeste par la diminution de l'énergie qu'elle transporte au cours de sa propagation à travers un matériau. Elle suit une loi définie par :

$$I(x) = I_0 e^{-\alpha x} \quad (1.14)$$

où I_0 est l'intensité initiale de l'onde, $I(x)$ l'intensité à la distance x et α le coefficient d'atténuation. L'atténuation est causée par une multitude de facteurs, Cheeke (2002) propose deux catégories d'atténuation : l'une est intrinsèque et est appelée absorption (effets thermiques ou excitations élémentaires), l'autre est externe et est causée par les imperfections du matériau (joints de grains, impuretés, fissures, etc.).

La fréquence peut aussi fortement augmenter l'atténuation. Les travaux répertoriés dans le livre de Cheeke (2002) permettent d'établir que le rapport $\frac{\alpha}{f^2}$ est constant dans un milieu isotrope. Autrement dit, l'atténuation est proportionnelle au carré de la fréquence du signal.

L'atténuation ne gênerait pas en l'absence de bruit. Il suffirait de la compenser en ajoutant un gain. Dans la pratique, du bruit apparaît à tous les niveaux de la mesure. Les imperfections du matériau, mises en cause dans l'atténuation externe, provoquent de la diffraction. Ces faibles figures de réflexions gênent par leur nombre l'observation des défauts recherchés. Bien que ce phénomène ne soit pas réellement aléatoire (Shull, 2002), on parlera de bruit de structure ou de bruit cohérent. Dans beaucoup de cas, on cherchera à le supprimer (Goyal & Pabla (2016); Bloxham *et al.* (2016)), mais des études sont faites pour l'utiliser afin d'obtenir des informations sur les grains eux-mêmes telles que leur taille ou leur orientation (Brizuela *et al.*, 2016). Le système d'acquisition peut lui aussi provoquer des perturbations électroniques. L'énergie de l'onde ultrasonore durant sa propagation faiblit alors que celle réfléchi par chaque imperfection augmente. Ce bruit est généralement modélisable par un bruit Gaussien (Gallager, 2008), ce qui rend son filtrage aisé.

Le signal brut est alors moins lisible. On va alors parler de SNR ou de rapport signal sur bruit, souvent exprimé en déciBel. Plus il est élevé, plus le signal est lisible, plus il est bas, plus le bruit est prépondérant.

1.2 La déconvolution

La fonction de déconvolution est une opération utilisée en traitement du signal et de l'image pour reconstruire un motif déformé ou flouté par un phénomène connu.

1.2.1 La théorie

Le produit de convolution de deux fonctions f et g définies sur \mathbb{R} , noté « $f * g$ » est une fonction bilinéaire et commutative définie par :

$$f * g(t) = \int_{-\infty}^{+\infty} f(t-x)g(x)dx \quad (1.15)$$

La déconvolution est une opération visant à annuler les résultats de la convolution. Ainsi, le problème est de déterminer une fonction f grâce à une équation de la forme :

$$f * g(t) = h(t) \quad (1.16)$$

où h et g sont connues, t appartenant à l'intervalle de définition de f , g et h . Une propriété intéressante du produit de convolution est d'être équivalent à un produit dans le domaine fréquentiel. Ainsi, l'équation précédente devient après une transformée de Fourier :

$$F(\omega) \times G(\omega) = H(\omega) \quad (1.17)$$

où F , G et H sont respectivement les transformées de Fourier de f , g et h . Assez simplement, on trouve :

$$F(\omega) = \frac{H(\omega)}{G(\omega)} \quad (1.18)$$

Il ne reste plus qu'à opérer une transformée de Fourier inverse pour obtenir la fonction f . Cette méthode sommaire de déconvolution est appelée *déconvolution de Fourier*. Crump (1975) avait démontré les limitations de cette méthode en géophysique en pointant notamment les phénomènes modifiant la forme des paquets se propageant dans des milieux. Ainsi, la fonction g n'est en général que partiellement connue. Deux limitations apparaissent alors à la déconvolution. Tout d'abord le bruit et ensuite la nécessité de connaître a priori la forme des échos reflétés à chaque interface.

Si un bruit ε dont on ne connaît pas les caractéristiques est ajouté au signal h :

$$h_B(t) = f * g(t) + \varepsilon(t) \quad (1.19)$$

Passer cette équation dans le domaine fréquentiel est impossible car l'addition temporelle n'y a pas d'équivalent. Des méthodes de filtrage ont été développées pour supprimer ce bruit. Elles ont été répertoriées par Cicero (2009a) dans la revue de littérature de sa thèse. On peut retenir en particulier le filtre de Weiner donnant de bons résultats sur des simulations. L'intégration de ce filtre dans l'opération de déconvolution permet de réaliser une *déconvolution de Weiner* peu coûteuse en temps. Celle-ci se révèle extrêmement efficace pour les mesures contenant un fort bruit électronique (Bickel & Martinez, 1983). Cependant, les résultats sont plus décevants dans les situations où le bruit est cohérent. En effet, ce bruit est souvent compris dans la bande-passante du signal étudié ce qui rend son filtrage compliqué sans détériorer le signal sain.

Pour contourner la seconde limite concernant la connaissance préalable du signal, des algorithmes de *déconvolution aveugle* ont été développés (Guarneri *et al.*, 2017). Ils présentent l'intérêt de ne nécessiter que des connaissances faibles sur les motifs de réflexions. Ils utilisent des algorithmes d'auto-corrélation et de corrélation croisée pour retrouver les signaux intéressants.

1.2.2 L'application en pratique

La déconvolution en traitement du signal acoustique a d'abord été développée pour la géophysique et la sismologie. L'objectif dans ce domaine est de réduire la trace temporelle du signal pour annuler l'effet convolutif de la réflectivité (Guerchaoui *et al.*, 1989) et donc d'augmenter la résolution de la mesure. L'opération devait aussi supprimer les réverbérations non voulues dans le sol et de réduire le bruit. Les contraintes expérimentales dans la prospection sismique sont faibles : il est possible d'utiliser des impulsions à très large bande, avec des puissances presque illimitées (dynamitage), ou au contraire des pulsations sur des bandes très étroites (camion vibreur). Cette souplesse rend l'utilisation de la déconvolution faisable car les réponses fréquentielles des obstacles rencontrés sous la terre sont bien connues et très utiles dans la mise en place des algorithmes de déconvolution.

L'analyse des échographies médicales avec les opérations de déconvolution montrent que la résolution peut effectivement être améliorée (Loupas *et al.*, 1989). Cependant, l'apparition de nombreux artefacts font que cette technique reste peu employée. Contrairement à la géophysique, il existe beaucoup de réglementation dans l'émission d'un signal ultrasonore dans un corps humain : les puissances sont limitées, des plages de fréquences sont interdites en raison du risque de cavitation (Izadifar *et al.*, 2017). De plus, les ondes se propageant dans les tissus sont gênées par les nombreuses interfaces et l'hétérogénéité des milieux traversés ce qui complique l'utilisation d'un modèle de réflexion unique.

Cicero *et al.* (2009b) a mis en évidence une faiblesse de la déconvolution pour les CND et en particulier en SHM. En effet, les résultats prometteurs en simulation ne le sont plus en pratique. D'autres articles mettent en évidence ce problème (Perrot, 1993). Les filtres comme celui de Wiener sont très performants quand il s'agit de supprimer un bruit blanc mais le sont beaucoup moins pour supprimer un bruit cohérent comme celui de structure.

L'analyse des A-Scans par des méthodes de convolution peut aussi servir à identifier des défauts (Kim *et al.*, 2004). On suppose que les réflecteurs : porosité, fissure, inclusion, etc renverront

un écho propre à leur nature. Cette méthode est très semblable aux recherches menées dix ans plus tard mais avec l'apprentissage machine développé dans la partie suivante.

1.3 Les réseaux de neurones

Les réseaux de neurones portent sur une technique d'apprentissage machine conceptualisée il y a presque soixante-dix ans sans trop de succès car alors trop gourmande en calcul. Les progrès en informatique, en électronique et en optimisation n'ont permis que très récemment leur utilisation récente à grande échelle.

1.3.1 Le modèle du perceptron

Le perceptron est l'élément de base d'un réseau de neurones. Son modèle a été développé à partir des années 1950 par F. Rosenblatt en imitant très grossièrement un neurone biologique (Rosenblatt, 1958). C'est un opérateur comportant plusieurs entrées et une unique sortie, toutes binaires. Pour calculer la sortie, chaque entrée i est pondérée par un poids w_i . Le poids est une valeur réelle qui est censée donner plus ou moins d'importance à une entrée.

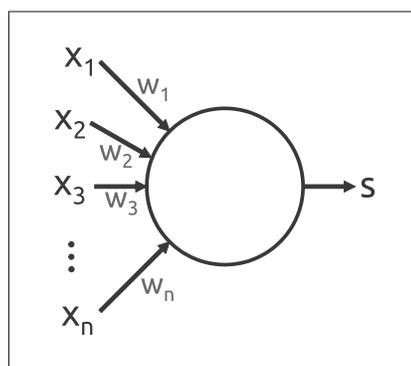


Figure 1.3 Schéma d'un perceptron

On associe au perceptron un seuil t au-dessous duquel la sortie s sera fautive et au-dessus, vraie. Étant donné que le perceptron sépare un espace en deux avec un hyperplan, t peut être assimilé à la distance entre l'origine de l'espace et la frontière.

Ainsi la sortie du perceptron est donnée par la formule :

$$s = \begin{cases} 0 & \text{si } \sum_{j=1}^n w_j x_j < t \\ 1 & \text{si } \sum_{j=1}^n w_j x_j \geq t \end{cases} \quad (1.20)$$

Afin de trouver une frontière plus sophistiquée entre deux domaines, il est possible de combiner plusieurs perceptrons en parallèle ou en série pour constituer ce qu'on appelle un réseau de neurones comme on peut le voir sur la figure 1.4. On appelle couche cachée, les couches qui ne sont ni en entrée, ni en sortie. L'augmentation du nombre de couches et de leur taille alourdit l'apprentissage ce qui rend l'utilisation de cette architecture « complètement connectée » marginale et valable seulement dans des cas très particuliers.

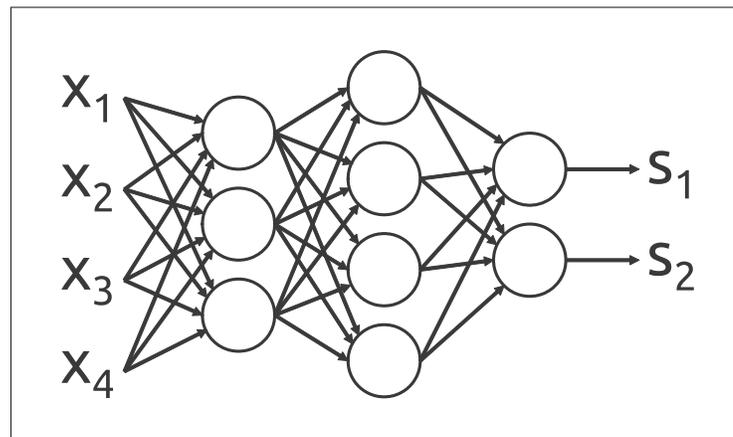


Figure 1.4 Schéma d'un réseau de neurones avec deux couches cachées, quatre entrées et deux sorties

L'apprentissage d'un réseau de neurones est un processus itératif consistant à mettre à jour les poids w_i dans le but de diminuer la distance entre la sortie s et la sortie désirée r . Cette minimisation de la fonction de coût sur chaque neurone est appelée « descente du gradient ».

La « rétropropagation » permet de mettre successivement à jour les poids dans les couches de neurones. Il existe plusieurs définitions de la fonction de coût, on peut trouver celle-ci par exemple qui est vraie pour un ensemble ayant N points d'apprentissage :

$$J(w) = \frac{1}{2N} \sum_{i=1}^N \left(r^{(i)} - \sum_{j=1}^n w_j x_j^{(i)} \right)^2 \quad (1.21)$$

Où r est égale à -1 ou 1 selon le domaine auquel y appartient dans l'espace. L'enjeu est de diminuer la fonction J .

$$\frac{\partial J}{\partial t} = \frac{\partial J}{\partial w} \frac{\partial w}{\partial t} \quad (1.22)$$

Où t est l'incrément d'une étape de calcul. Il existe une solution à cette équation, qu'on appelle descente du gradient. En faisant évoluer les poids w avec cette méthode, la fonction J ne peut que converger vers un minimum au moins local.

$$w_{t+1} = w_t - \alpha \frac{1}{N} \sum_{i=1}^N y_j^i \left(r^{(i)} - \sum_{j=1}^n y_j^{(i)} w_{tj}^{(i)} \right) \quad (1.23)$$

On voit que la complexité de cette mise à jour est en N , c'est-à-dire qu'elle est proportionnelle à la taille de la base de données d'apprentissage. Une descente de gradient stochastique, beaucoup plus économique en calcul a été développée et est maintenant très largement répandue dans le domaine de l'apprentissage machine moyennant des modifications propres au domaine d'application. La descente de gradient stochastique est plus rapide car les poids ne sont plus mis à jour après l'évaluation de l'ensemble des données d'apprentissage mais après chaque itération. En revanche, la probabilité de trouver un minimum global au problème diminue fortement.

1.3.2 Le réseau de neurones convolutif

À partir des années 1990, sont apparues (LeCun *et al.*, 1989) les premières architectures de réseau de neurones convolutifs (CNN pour Convolutional Neural Network, en anglais). Son utilisation a explosé vers 2014 grâce à l'apparition d'une nouvelle génération de cartes graphiques.

Plutôt que de calculer tous les poids dans un réseau de neurones, ce qui est globalement complexe et bien souvent peu pertinent, seuls quelques poids sont pris en compte et appliqué de la même manière sur tout le vecteur de forme. Cette méthode se veut proche de ce qui se passe dans le cortex visuel des animaux et c'est donc pour cela qu'on retrouve surtout les CNN dans l'imagerie et la vision ordinateur.

On pourrait rapprocher cette méthode avec les filtres d'imagerie tel que celui de Sobel utilisé pour la détection de contour en traitement d'image. La différence tient dans l'algorithme plus sophistiqué qui permet de mettre à jour les pondérations du filtre à chaque itération.

Le CNN vise à traiter par un filtre une zone réduite du vecteur de forme pour en extraire les informations pertinentes. En faisant glisser, le noyau de la couche convolutionnelle, souvent appelé kernel, on analyse le vecteur de forme de la même manière en tout point. La place d'un groupe d'éléments remarquable dans la matrice d'entrée n'influe donc pas sur l'analyse de l'entrée.

Comme pour les réseaux de neurones classique, l'entraînement nécessite un lot conséquent de données. En théorie, plus il y en aura, meilleure sera la qualité de l'apprentissage.

Il existe plusieurs méthodes d'apprentissage. On parle d'apprentissage supervisé lorsque toutes les données d'entraînement sont entièrement étiquetées. L'étiquetage des données est souvent une étape manuelle, longue et fastidieuse et donc coûteuse. C'est pourquoi des algorithmes d'apprentissage semi-supervisé ou renforcé (Weston *et al.*, 2012), voire faiblement supervisé (Durand, 2017) ont été développés. Dans le premier cas, les données sont partiellement (parfois entre 0.1% et 15%) classifiées. Dans le second cas, les classes présentes sur un échantillon sont données mais pas localisées. Dans le dernier cas, aucune étiquette n'est fournie au réseau de neurone et il devra automatiquement retrouver, via des techniques de regroupement (clustering) pour regrouper les points d'une classe ensemble.

L'apprentissage par un réseau de neurones sur des données simulées peut être suffisamment fin pour perdre en efficacité car il sera capable de distinguer le domaine des simulations du

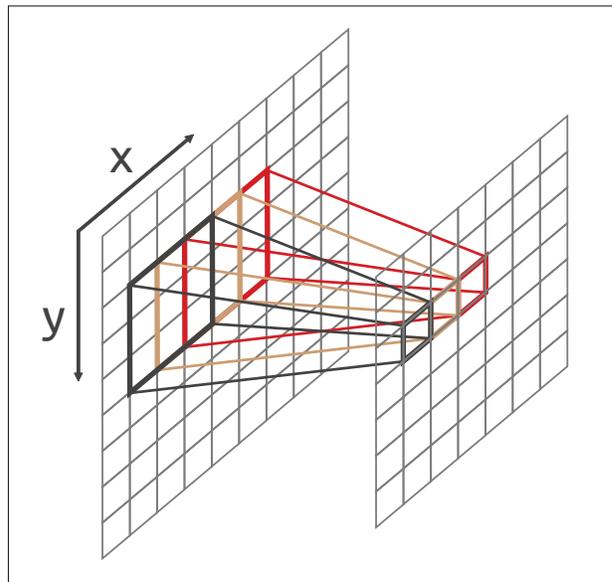


Figure 1.5 Le filtre de convolution glisse dans la direction x

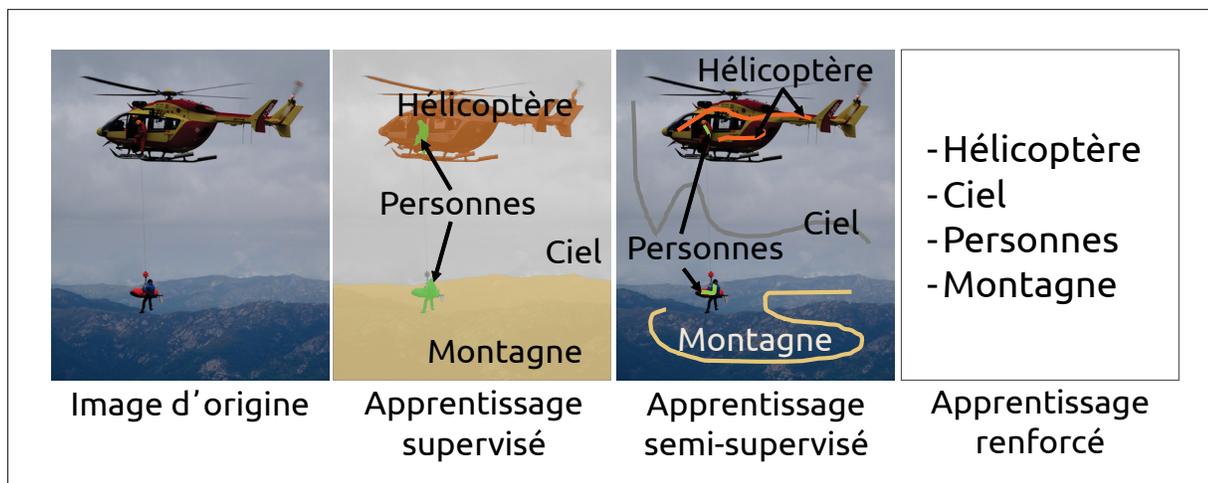


Figure 1.6 Différentes méthodes d'étiquetage des données pour l'entraînement d'un réseau de neurones

domaine des mesures expérimentales. Sachant que les données expérimentales sont souvent plus coûteuses et plus complexes à annoter que les données simulées, le transfert de domaine est un enjeu majeur de l'apprentissage machine. En général, le transfert de domaine consiste en un double entraînement : celui du réseau de neurones et celui d'un auto-encodeur.

Dans le cas où peu de données expérimentales sont disponibles et la simulation reste peu réaliste ou complexe, il existe une méthode pour augmenter la taille du lot d'apprentissage : l'augmentation de donnée. Cela consiste en partir des données existantes et de déformer l'image, augmenter la translation ou l'illumination sur certaines zones, la rotation ou la modification de taille de l'image. Certaines transformations sont plus pertinentes ou réalistes que d'autres selon les cas. Dans le domaine ultrasonore, des translations d'un défaut sur un B-Scan ainsi que l'illumination de ce défaut pour en simuler une augmentation de taille ont déjà été utilisés par Virkkunen *et al.* (2019) pour augmenter la taille d'un set de données.

1.3.3 Les CNN pour le traitement du signal

La plupart des réseaux de neurones à couche de convolution ont été développés pour traiter l'image. Leur utilisation pour le traitement du signal reste plus rare. Plusieurs méthodes sont possibles. Parfois un pré-traitement comme par exemple une transformée en ondelettes (Virupakshappa *et al.*, 2018) va être opérée pour guider le réseau vers un type d'analyse. La transformée en ondelettes se fait à plusieurs ordres, ainsi le vecteur d'entrée est composé de huit vecteurs concaténés. Un réseau de neurones à deux dimensions est donc utilisé. Cette méthode présente deux intérêts. Le premier avantage est que cela permet de guider le réseau de neurones vers ce qu'on pense être remarquable et important pour obtenir de bons résultats. Le second est que cela permet d'approfondir le vecteur de forme pour avoir plus de données en entrée. Il pourrait y avoir une dernière raison pour augmenter la taille des données dans les deux dimensions : cela permet de se rapprocher des architectures utilisées pour le traitement de l'image.

Une autre méthode proposée par Munir *et al.* (2019) consiste à simplement éliminer une dimension. Dans cet article, le nombre d'entraînement est insuffisant. Les techniques standards d'« augmentation de données » très efficaces en 2D sont plus limitées en 1D. La seule modification retenue ici est un décalage temporel et éventuellement un bruit.

Il faut noter que le choix, dans ce projet, a été porté sur les CNN. D'autres types d'algorithmes d'apprentissage machine existent tels que les machines à support de vecteur plus connues sous l'acronyme anglais SVM pour Support Vector Machine ou les réseaux récurrents à mémoire court et long terme, connus sous le nom LSTM (Hochreiter & Schmidhuber, 1997). Ils sont plus adaptés au traitement du signal temporel dans but de faire ressortir une tendance et de prévoir un résultat comme par exemple la fréquentation d'un transport en commun ou le cours d'un matériau. Ainsi leur utilisation paraît moins pertinente dans le cas présent qui nécessite un outil de reconnaissance de motif et non de prévision.

1.4 Imagerie : Méthode de focalisation en tout point

Avec l'étude et l'analyse d'un A-Scan seul, une unique donnée peut-être extraite : la distance entre l'émetteur et l'interface qui a provoqué un écho. D'autres tendances comme la taille de cette interface, son orientation ou sa nature peuvent être interprétées à partir des connaissances a priori qu'on a sur la pièce. L'idée de l'imagerie est de combiner une multitude de A-Scans issues de capteurs ultrasonores situés à des places différentes pour produire une image représentant l'intérieur de la pièce pour mieux visualiser les paramètres des réflecteurs (position, taille, orientation, etc.).

Actuellement, la méthode la plus utilisée en imagerie ultrasonore dans l'industrie est la Focalisation en Tout Point (FTP), plus souvent appelée TFM pour *Total Focusing Method*. Elle est très liée à une méthode d'acquisition, la FMC (pour *Full Matrix Capture*) (Schmerr Jr, 2014).

La FMC consiste en l'utilisation d'une sonde multiélément (souvent appelée *phased array*) comptant classiquement entre 16 et 256 éléments piézoélectriques. Chaque élément du transducteur émet successivement alors que tous les éléments reçoivent les signaux ultrasonores comme dans la figure 1.7. Ainsi chaque acquisition prise isolément est un A-Scan et la concaténation de toutes les mesures est un B-Scan. Pour un transducteur comptant n éléments, une FMC donnera un B-Scan de n^2 A-Scans. Présentement, c'est surtout le débit de données générées et à analyser qui limite les capacités du couple FMC/TFM.

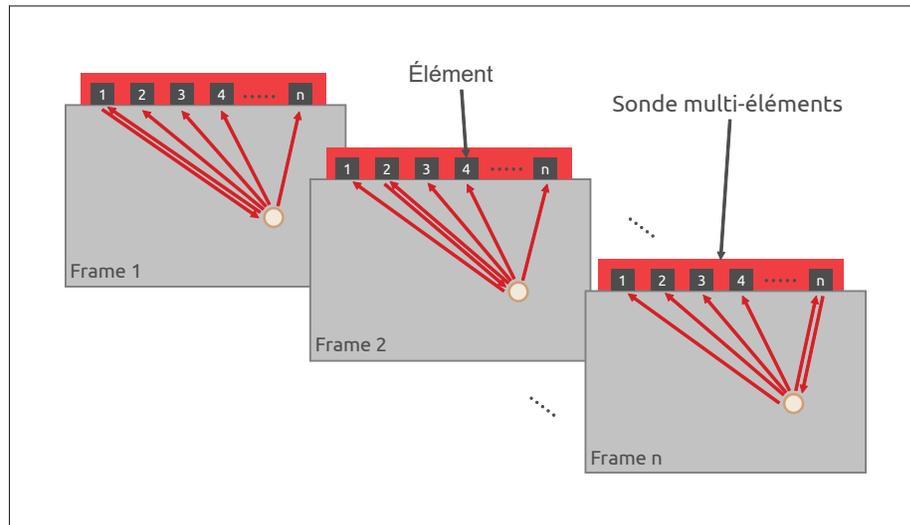


Figure 1.7 Illustration d'une acquisition de type FMC

Une fois le B-Scan acquis, une zone de reconstruction doit être choisie et une matrice des distances entre chaque point de cette zone et chaque émetteur est calculée. La connaissance de la vitesse de propagation du son dans le matériau permet de lier les délais dans les A-Scans à la distance dans la matrice des distances. L'amplitude attribuée à chaque point de la zone de reconstruction est la somme des amplitudes des A-Scans calculé pour ce point.

La TFM est une méthode de reconstruction par interférence (Schmerr Jr, 2014). Aux abords d'une interface, il y aura des interférences constructives, les crêtes de tous les A-Scans se somment les unes aux autres. Plus loin des interfaces, les interférences sont destructives et les creux se somment avec des crêtes pour donner un résultat nul.

La TFM donne une représentation de l'intérieur pièce. De nombreuses tâches visibles sont en fait des artéfacts de reconstruction qui demandent de l'expérience pour les reconnaître. Sur la figure 1.8 (issue d'une simulation CIVA), on peut en reconnaître de différentes sortes. Des réflexions successives sur un même réflecteur peuvent le faire apparaître plusieurs fois sur une image comme on peut le voir dans la zone entourée en bleu. La conversion des modes transversaux en longitudinaux et inversement peut aussi multiplier les apparition du même défaut à cause de la différence de vitesse de propagation. Ainsi dans la zone entourée en vert, c'est le

réflecteur qui est représenté avec les ondes transversales. Un défaut situé hors de l'ouverture de la sonde apparaîtra comme distordu. Le trou de côté simulé ici ne laisse pas apparaître une tâche circulaire comme attendu. De part et d'autre de de réflecteurs, des « moustaches » entourées en jaune révèlent des interférences visibles. Une zone d'interférences constructives située juste sous la sonde représentée en rose sur l'image peut gêner la détection de défauts.

Toutefois les artéfacts ne peuvent pas vraiment être considérer comme une limite de la TFM. L'expérience permet de les reconnaître et de ne pas les prendre en compte lors des mesures et des diagnostics. Le second grand enjeu de la TFM en industrie, après l'augmentation des capacités de calcul et de gestion des flux de données, est l'assistance en analyse des images pour représenter uniquement les réflecteurs et atténuer les artéfacts.

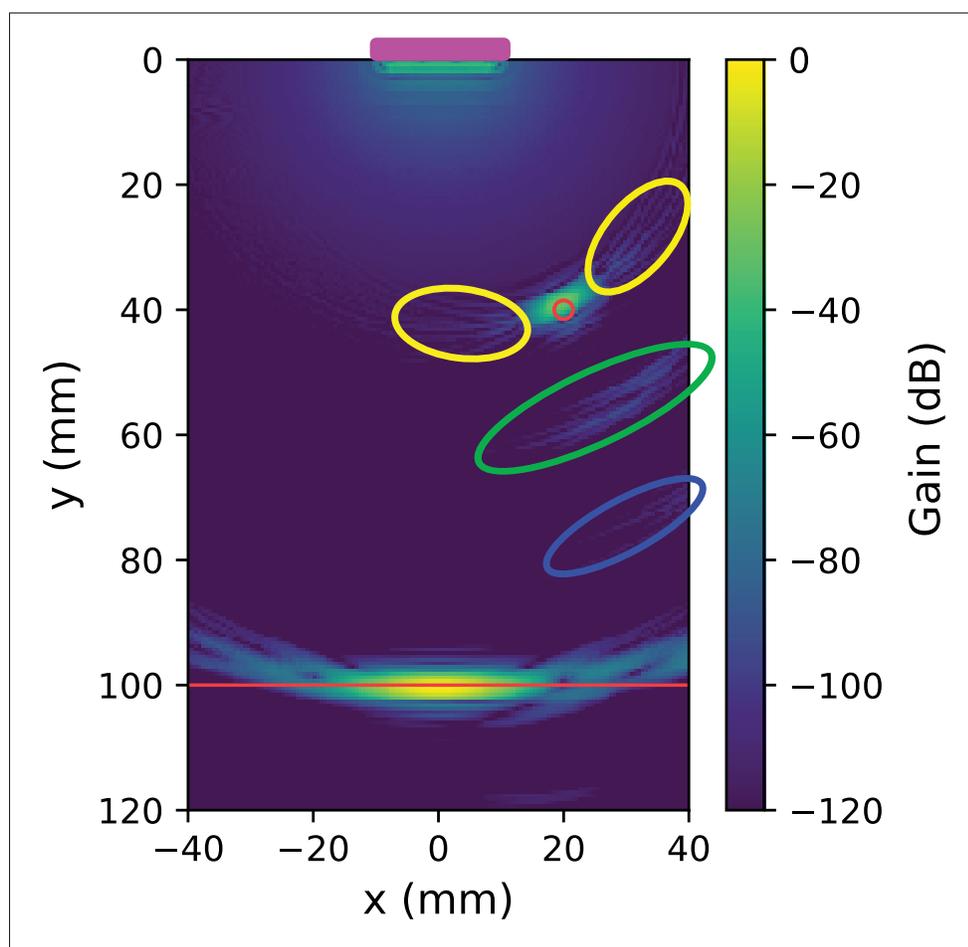


Figure 1.8 Plusieurs artéfacts de reconstruction sont visibles sur la TFM, les interfaces simulées sont tracées en rouge

CHAPITRE 2

DECONVOLUTION OF ULTRASONIC SIGNALS USING A CONVOLUTIONAL NEURAL NETWORK

Arthur Chapon, Daniel Pereira, Pierre Bélanger

Department of Mechanical Engineering, École de technologie supérieure,
1100 rue Notre-Dame Ouest, Montréal, Québec, H3C 1K3, Canada

Article soumis à la revue *Ultrasonics*, le 19 novembre 2019.

2.1 Abstract

Successfully employing ultrasonic testing to distinguish a flaw in close proximity to another flaw or geometrical feature depends on the wavelength and the bandwidth of the ultrasonic transducer. This explains why the frequency is commonly increased in ultrasonic testing in order to improve the axial resolution. However, as the frequency increases, the penetration depth of the propagating ultrasonic waves are reduced due to an attendant increase in attenuation. The nondestructive testing research community is consequently very interested in finding methods that combine high penetration depth with high axial resolution. This work aims to improve the compromise between the penetration depth and the axial resolution by using a convolutional neural network to separate overlapping echoes in time traces. The originality of the proposed framework consists in its training the neural network using data generated in simulations. The framework was validated experimentally to detect flat bottom holes in an aluminum block with a minimum depth corresponding to $\lambda/4$.

Keywords : Ultrasonic testing, Axial resolution, Time-of-Flight, Deconvolution, Convolutional Neural Network

2.2 Introduction

In the metal forming and composite manufacturing industries, flaws detection close to interfaces is critical. A successful early detection of these flaws can reduce the probability of failure during the useful life of manufactured components. Ultrasonic testing (UT) is commonly used to quality control such components. In the inspection of thick components and/or highly attenuative materials (such as cast iron or composite), a compromise between the penetration depth and the axial resolution must be reached. It may therefore become difficult to detect flaws in close proximity or near the boundaries of the part under inspection. Increasing the frequency reduces the wavelength and therefore leads to an increase in the axial resolution. However, attenuation increases as the frequency increases, and, consequently, the maximum propagation depth reduces. The duration of the transmitted wave packet associated with the bandwidth of the transducers also plays an important role in the axial resolution. For a transducer with an infinite bandwidth emitting a single cycle pulse waveform, the axial resolution is half a wavelength (Dance *et al.*, 2014). In practice, piezoelectric transducers have a limited bandwidth, which restricts the minimum duration of the transmitted pulse to a few cycles, and consequently, reduces the axial resolution. Therefore, achieving a satisfactory axial resolution is a function of the transducer bandwidth, the attenuation of the inspected medium, and the propagation distance.

Hoseini *et al.* (2012) showed that combining the Hilbert transform and a quasi- maximum likelihood method could be efficient for measuring the Time-of-Flight (ToF) and locating experimental reflectors in signals with a signal-to-noise ratio (SNR) as low as 5 dB. In their work, the location accuracy was better than in the cross-correlation method. However, the separation of two reflectors in close proximity was not covered. The separation of two overlapping wave packets is critical to increasing the axial resolution. In this context, the application of deconvolution methods to distinguish signals that are overlapped has been extensively studied in geophysics (Jurkevics & Wiggins, 1984) and ultrasonic NDT (Guarneri *et al.*, 2017). Researchers in geophysics are interested in extracting the ToF and amplitudes of overlapping seismic events. According to Crump (1975), the deconvolution may be used to separate echoes

to estimate the positions of emissions, but the difficulty in dealing with waveshape-changing phenomena, including noise and overlapping echoes, was noted. Deconvolution algorithms such as the least-squares deconvolution (Robinson & Treitel, 2000) or the autoregressive spectral extrapolation (Chen *et al.*, 2013) suffer from various limitations : (1) they require a priori knowledge of the interface reflectivity inside the propagating medium as well as information regarding the path of multiple reflections ; (2) they are very sensitive to structural and electronic noise. With Guarneri *et al.* (2017), blind deconvolution techniques were applied to address this problem by adding iterative filters. These filters were able to deconvolve with a weak knowledge of the echo pattern. Convolutional filters (e.g., the Wiener filter) have also been developed to improve the robustness of deconvolution against noise (Bickel & Martinez (1983); Cicero *et al.* (2009b)).

In UT, time-of-flight measurement of strongly overlapping wave packets in noisy signals was also studied. Soussen *et al.* (2012) proposed a sparse deconvolution method able to pick more than 6 successive reflections in a simulated 2 mm aluminum plate. The wavelength was greater than the plate thickness and the pulse was a 3-cycle Hann windowed toneburst, thus leading to overlapping echoes. The results showed a reduction in performance when the SNR was synthetically reduced from 20 dB to 10 dB. Cicero *et al.* (2009b) came across another problem with deconvolution in structural health monitoring (SHM). Their simulation study showed the potential of the optimal Wiener filter to deal with overlapped signals. The deconvolutional algorithm was able to separate two completely overlapped and noisy 4-cycle waveforms in a metal plate. The performance of the method was satisfactory when using simulated data but the experimental implementation was disappointing. The poor experimental performance was associated with the narrow bandwidth of transducers which extends the temporal size of the echo patterns. Various methods have been proposed in the field of ultrasonic tomography for the estimation of the time-of-flight of overlapping wave packets (Li *et al.* (2009); Falardeau & Bélanger (2018); Espinosa *et al.* (2018)) with limited success.

In UT, the time-of-flight measurement of strongly overlapping wave packets in noisy signals was also studied. Soussen *et al.* (2012) proposed a sparse deconvolution method capable of

picking more than 6 successive reflections in a simulated 2 mm aluminum plate. The wavelength was greater than the plate thickness and the pulse was a 3-cycle Hann windowed toneburst, thus leading to overlapping echoes. The results showed a reduction in performance when the SNR was synthetically reduced from 20 dB to 10 dB. Cicero *et al.* (2009b) encountered another problem with deconvolution in structural health monitoring (SHM). Their simulation study showed the potential of the optimal Wiener filter to deal with overlapped signals. The deconvolutional algorithm was able to separate two completely overlapped and noisy 4-cycle waveforms in a metal plate. The performance of the method was satisfactory when using simulated data, but the experimental implementation was disappointing. This poor performance was associated with the narrow bandwidth of transducers, which extends the temporal size of the echo patterns. Various methods have been proposed in the field of ultrasonic tomography for the estimation of the time-of-flight of overlapping wave packets (Li *et al.* (2009); Falardeau & Bélanger (2018); Espinosa *et al.* (2018)), with limited success.

Convolutional neural networks (CNN) may allow to overcome the problem of transduction bandwidth by learning the shape of overlapping signals in the time domain. A CNN contains several layers and adapts the filters by learning the waveforms. The classification of ultrasonic testing signals using CNN has already been demonstrated. Virupakshappa *et al.* (2018) used a CNN to detect the presence or the absence of flaws, and demonstrated the ability of neural networks to process signals in noisy situations. In their case, the signal was pre-processed by a discrete wavelet transform. Munir *et al.* (2019) also demonstrated that CNN were able to classify defects in welds, even in the presence of noise. Training a CNN requires a large amount of data to achieve acceptable performances. Large sets of experimental measurements are difficult to generate because of the cost associated with preparing samples. Data augmentation solutions exist, and allow to compensate for the small amount of samples through minor geometric changes such as translation, rotation, etc (Virkkunen *et al.*, 2019). Munir *et al.* (2019) implemented data augmentation through time shifting of the A-Scans and the addition of white Gaussian noise representing electronic noise. Data augmentation methods are particularly interesting when it is difficult to generate a high fidelity simulated dataset .

As mentioned above, this paper aims to demonstrate the concept of employing a CNN trained using simulated data to deconvolve experimental A-Scans even when wave packets are strongly overlapping. Experimental measurements are used to validate the performance of the proposed approach. The paper begins with the materials and methods section describing the finite element model, the CNN and its training, followed by the experimental procedure. The presentation of the results is then followed by discussions. Finally, conclusions are drawn.

2.3 Material and Methods

2.3.1 Finite Element simulated dataset

To satisfactorily train neural networks, a large amount of data is required. A convenient way to generate this data is to use simulations rather than experiments. In this paper, the dataset was generated using GPU-accelerated finite element (FE) simulations using Pogo FEA (Huthwaite, 2014). A 2D plane strain model was used to simulate an aluminum block with flaws near the backwall. The aluminum material properties were $E=72.5 \text{ GPa}$, $\nu=0.33$, $\rho=2706 \text{ kg/m}^3$. The model was discretized at 30 elements per wavelength using linear square elements. In the simulation set, the cases were all different in order to avoid unbalancing the training. To this end, a matrix of parameters containing random sizes and reflector positions was generated. These parameters were used to generate FE models whose schematic is presented in Figure 2.1.

Absorbing boundaries (Rajagopal *et al.*, 2012), in light grey in Figure 2.1, were added to both sides and to the bottom boundary of the model. Their aim was to reduce the size of the mesh in the x-direction and to avoid reverberations between a reflector and the backwall. In this study, the reflectors (shown in white) were flat, and were generated through element suppression, and therefore correspond to voids. Their thickness corresponded to one layer of elements. The black dots at the top of the model show the nodes used for the excitation. The positions (X_1 , X_2 , Y_1 and Y_2) and lengths (L_1 and L_2) of the two reflectors were random while L_2 was always

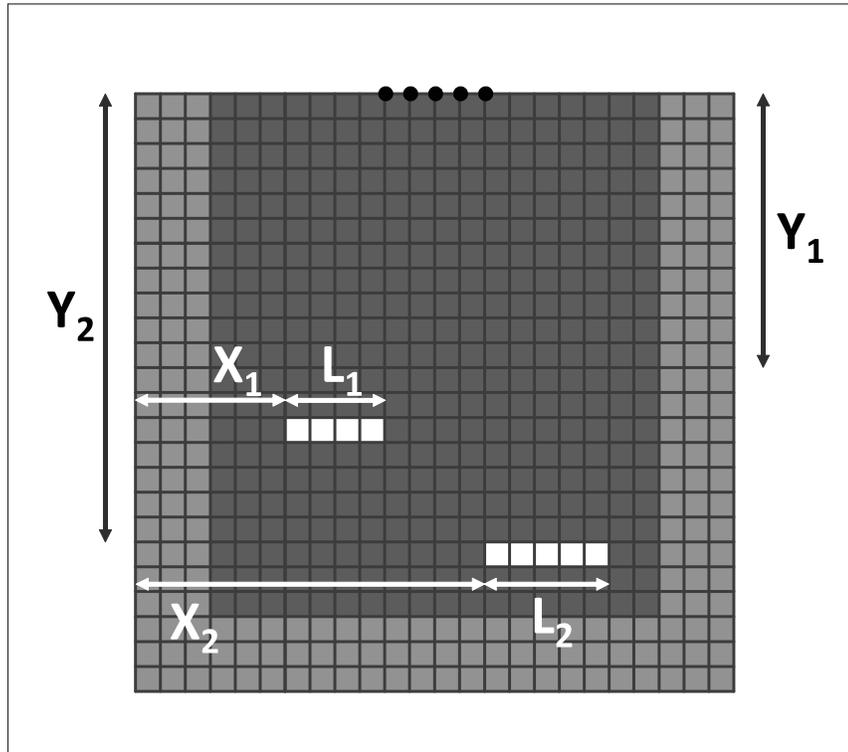


Figure 2.1 Schematic of the FE model

greater than L_1 . The positions and lengths of the reflectors were stored in memory to be used during the supervised learning of the network.

When using a simulated dataset to train a CNN, the fidelity of the simulations is paramount. Therefore, an initial experimental measurement in an aluminum block was used to estimate the bandwidth of the acquisition chain used in the experimental validation of the method (see section 2.3.4). The average time trace obtained in this experiment was used as the input signal of the finite element simulations.

A set of 2000 simulated A-Scans were simulated in under an hour for the training of the CNN.

2.3.2 Architecture of the CNN

Among the diversity of artificial neural networks, the CNN caught attention because of its ability to take into account the temporal organization of an A-Scan. Moreover, this type of

neural network is the most commonly used in pattern recognition (Rawat & Wang, 2017). CNN have been studied in the classification or detection of reflectors in ultrasonic signals (Virupakshappa *et al.*, 2018). However, the detection of the time of arrival of wave packets is a regression problem. Regression problems have been not studied to the same depth by the research community. As the temporal size of the echo pattern is known with the parameters of the simulation, the size of the region of interest (ROI) can be computed using equation 2.1 :

$$ROI = \frac{N_{cycle} f_{sampling}}{f_{signal}} \quad (2.1)$$

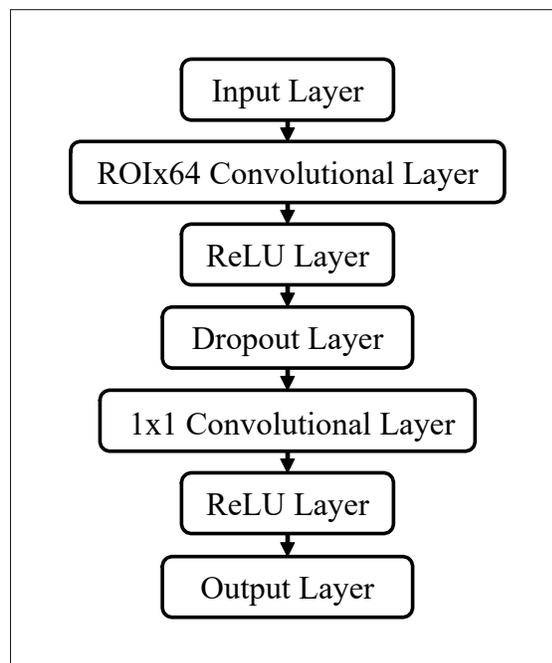


Figure 2.2 Architecture of the CNN

In order to reduce computational complexity and the number of unknowns during the training phase, the input layer of neurons can be adapted to the size of the ROI. Since the duration of an echo is known, the filter size of the first layer of the CNN is adapted to this size. Adding more neurons would not provide more information, whereas using less would mean not all the information available is used. The kernel of the first convolutional layer was set to cover the full length of ROI.

The estimation of the time of arrival of wave packets in an A-Scan is a regression problem, where the amplitude of the wave packet is expected. A proportional output imposes the usage of ReLU, eLU or other linear-when-positive activation functions rather than the sigmoid or the hyperbolic tangent (Goodfellow *et al.*, 2016). Moreover, since the interest is in detecting direct and hard skips, negative outputs are not expected. Therefore, the most adapted activation function was chosen as the ReLU.

A dropout layer with a rate of 0.5 was set between both convolutional layers. The expected effect of this layer is to avoid overfitting (Srivastava *et al.*, 2014), or specialization of the CNN in the simulation domain. The last 1x1 convolutional layer synthesized the results from all channels. The architecture of the CNN is shown in Figure 2.2.

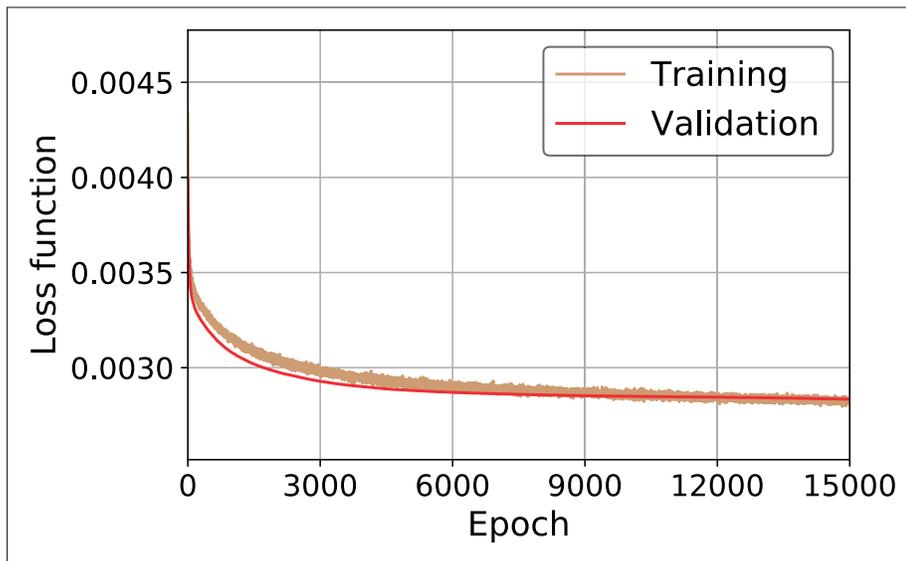


Figure 2.3 Learning curve and loss function as a function of epoch

The learning dataset comprised 2000 simulated A-Scans. 400 (20%) of them were used as a validation set to evaluate the performance during the learning. Another batch of 50 simulations (2.5%) was used to test the performances of the CNN. All the other A-Scans (1550) were used for the supervised training.

A stochastic gradient descent was used to minimize the mean square error loss function. The learning rate was initially 0.005, and decreased logarithmically with the epochs. The learning stopped when 15,000 epochs were computed. Figure 2.3 shows the evolution of the loss function; an asymptote was reached from approximately the 12,000th epoch. The gap between the scores of the training and validation sets was still narrow enough to suggest that overfitting was avoided.

2.3.3 Training the CNN with simulations

A typical A-Scan (Figure 2.4) is a time vector containing the temporal position and amplitude of echoes as well as some noise. The A-Scan is the convolution of the input signal (p) with the position of the reflectors and their amplitude (g) plus some noise (n). In this paper, the aim of the CNN is to recover the position of the reflectors (g) from the A-Scan.

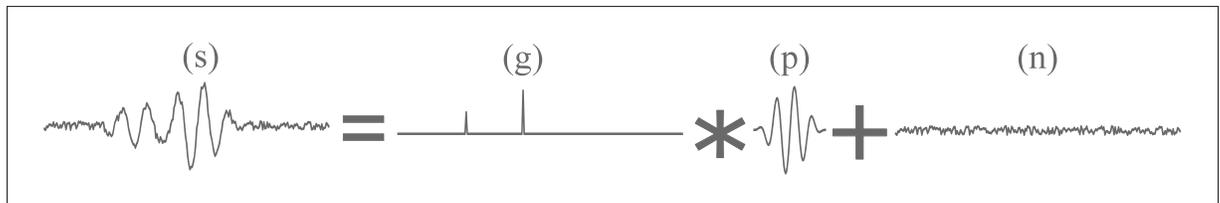


Figure 2.4 A typical A-Scan (s) with its three components : (g) the position of the reflectors, (p) the input signal and (n) the noise

The steps to format the data into a training set are summarized in Figure 2.5. As mentioned previously, only five experimental measurements were used in the preparation of the simulated training set. The experimental noise, the experimental echo pattern and the speed of sound were extracted from them.

As the CNN work as a waveform filter in the time domain, the echo patterns from simulations and experiments must be similar. Hence, five preliminary experimental measurements were made to extract a backwall echo waveform. The approach was therefore close to a non-blind deconvolution method. After the simulations were completed, the simulated A-Scans were

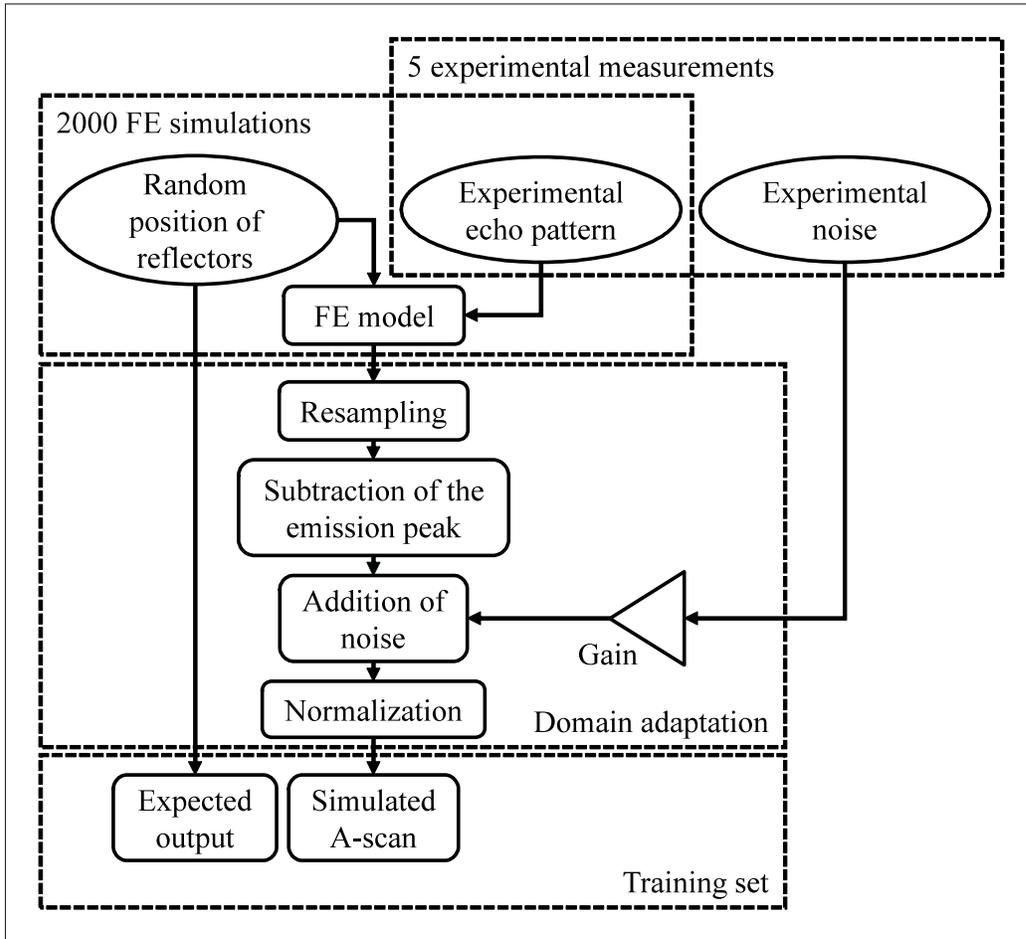


Figure 2.5 Preparation of the simulated training batch for the CNN

downsampled to fit the sampling frequency of the experiments. The downsampling step also had the benefit of reducing the size of the input data thus reducing the training time. A typical simulated A-Scan, before suppression of the input signal, is presented in figure 2.6.

Noise is commonly added to the simulations when training or testing CNN (Munir *et al.*, 2019) to simulate structural, systems or electronic noise, and to introduce a more random part in simulated and experimental signals. To that end, experimental noise was extracted from the five preliminary experimental measurements in sections of the A-Scans where no reflectors were present. All the noise was then concatenated into a single vector. A weighted random section of the noise was added to each simulated A-Scan as showed in Figure 2.7. This method allowed

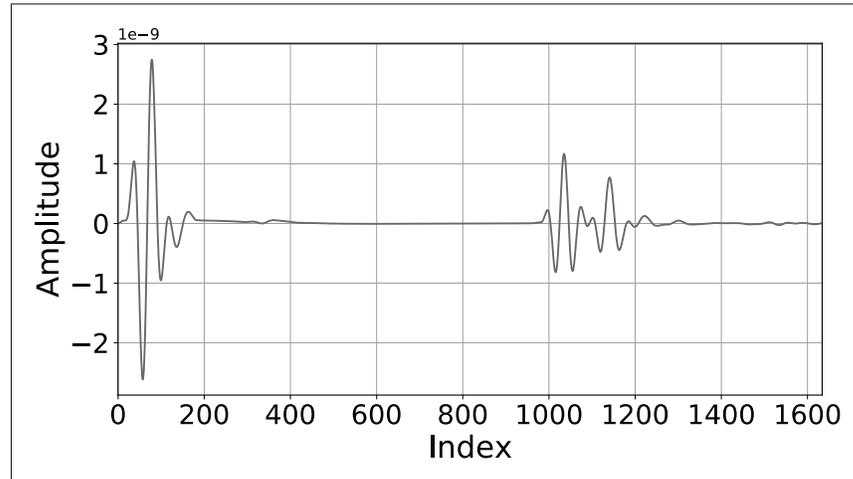


Figure 2.6 FE simulated A-Scan

using typical noise acquired in experiments. The noise takes into account the bandwidth of the entire acquisition chain, including the transducer, the acquisition card and all unwanted filtering. Three learning batches of 2000 simulations were generated : (1) free from any noise, (2) with an SNR of 20 dB, and (3) with an SNR of 5 dB. The effect of noise on the performance of the CNN could therefore be studied. The amplitude of the added noise A_{noise} was set using equation 2.2 as a function of the signal amplitude A_{signal} :

$$A_{noise} = A_{signal} 10^{\frac{-SNR_{dB}}{20}} \quad (2.2)$$

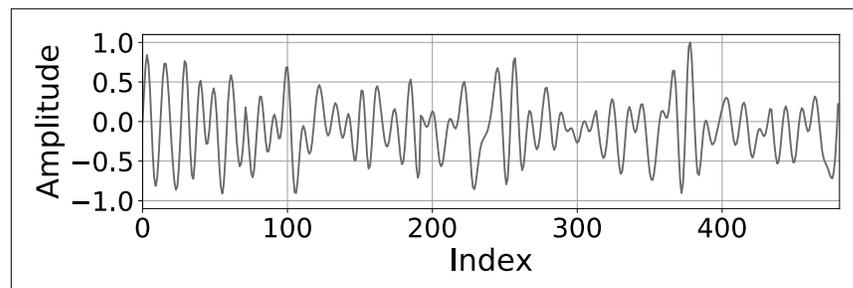


Figure 2.7 Noise extracted from the preliminary experimental measurements, after normalization

Finally, the simulated signals were normalized to the amplitude of the strongest reflector in order to avoid the saturation of the activation functions and to get a more homogeneous dataset. In Figure 2.8, the grey line shows a simulated A-Scan after adaptation, and the brown line is the expected output from the CNN. The spikes in the brown line correspond to the beginning of the arrival of the signals from the two reflectors. Throughout the article, the amplitude of the expected signal is set to unity. Indeed, determining the amplitude contribution of each reflector in an overlapping wavepacket of an experimental signal is outside the scope of this paper.

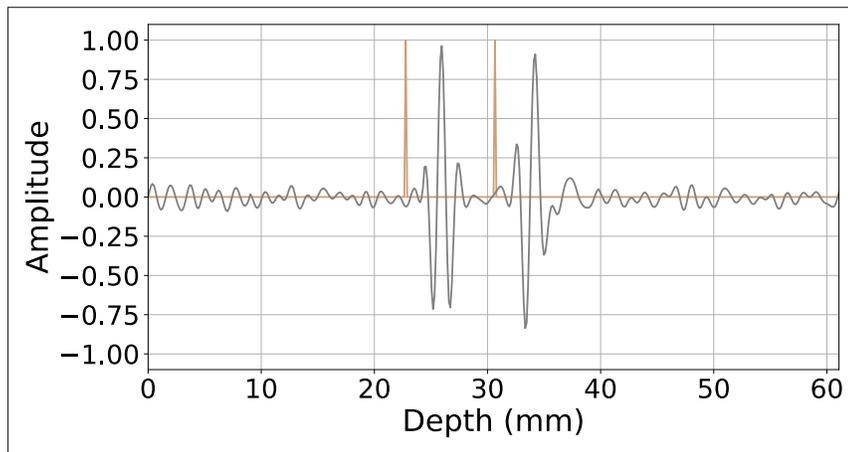


Figure 2.8 Simulated A-Scan used for CNN training after domain adaptation. The expected output corresponds to spikes at the beginning of the signals of interest

2.3.4 Experimental setup

An aluminum block was used to assess the performance of the framework to identify the time-of-flight of reflectors. 23 flat-bottom holes (FBH) were machined with depths ranging from 0.69 mm to 13.77 mm. The diameter of the FBH was 8 mm. The aim of the experiments was to distinguish the top of the FBH from the backwall. The performance of the CNN was evaluated as a measure of its ability to identify reflectors as well as the minimum resolvable distance between the top of an FBH and the backwall of the block. An Olympus single-element probe V125-RM with a center frequency of 2.25 MHz was used in a pulse-echo arrangement. The 3-cycle Hann windowed toneburst were generated using a Verasonics Vantage 64LE data acquisition system. The sampling frequency was set to 25 MHz. The aluminum block and the experimental setup are shown in Figure 2.9.

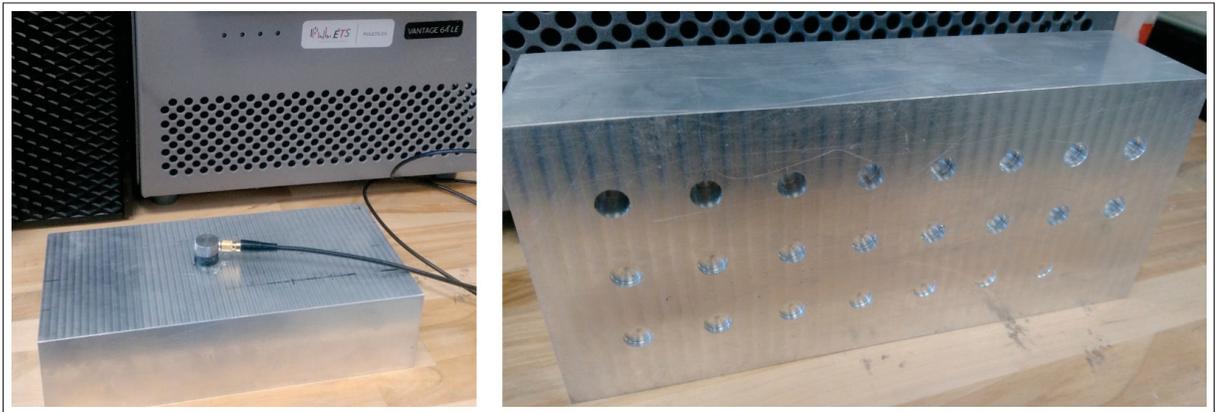


Figure 2.9 Aluminum block with different FBH depths and the Olympus V125-RM probe

Figure 2.10 shows five experimental reflections obtained from the backwall of an aluminum block and the frequency spectrum of the averaged signals. The average time trace obtained in this experiment was used as the input signal of the finite element simulations as well as to extract typical experimental noise.

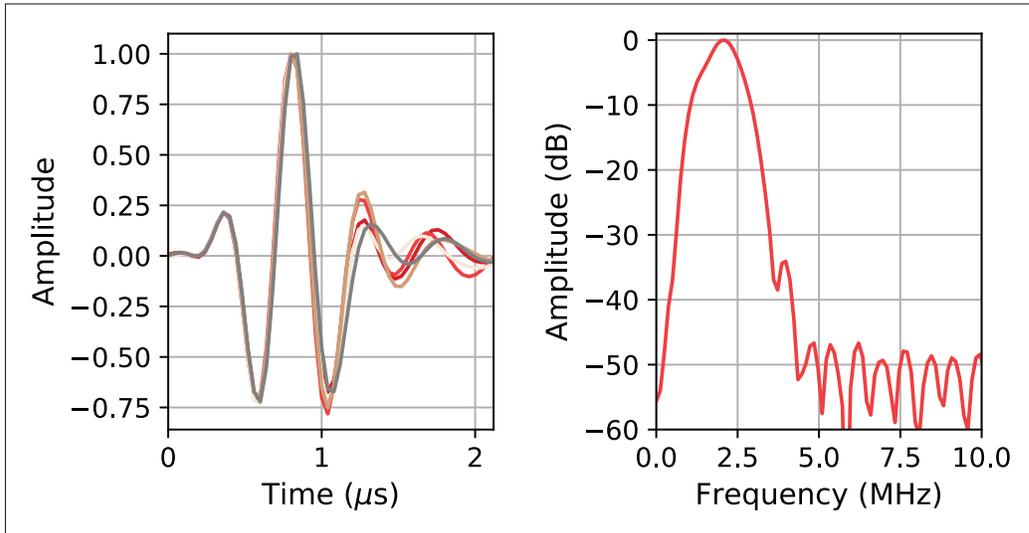


Figure 2.10 Five reflections from the backwall of an aluminum block using an Olympus V125-RM probe centered at 2.25 MHz : (a) 5 time traces and (b) the averaged frequency spectrum

After the CNN training, a series of measurements were acquired to test the algorithm in laboratory conditions. 48 A-Scans – 2 for each position above the FBH and 2 others above the backwall – were stored. The measured A-Scans were normalized following the same procedure as for the simulated A-Scans and directly passed through the CNN.

2.4 Results

The experimental measurements were repeated twice for 23 FBH and 1 position without defect. Hence, the CNN had to locate 94 reflectors (2 per measurement with an FBH and only 1 when there was no FBH) in the 48 experimental A-Scans. These signals were passed through the CNN without any pre-filtering.

When compiling the results, an FBH or the backwall was considered detected if it was located within a window of five sample indices from the expected position. Five sample indices at 25 MHz corresponded to 0.04 μs or 1.3 mm in the aluminum block. If the location was outside this narrow window, it was considered either a false detection or a non-detected reflector. An amplitude threshold of 10% was used along the amplitude axis; this value was set using the

50 simulations of the performance test batch. Indications from the CNN below this threshold were ignored.

Firstly, the neural network was applied on the raw experimental A-Scans. The SNR on the raw A-Scans was approximately 40 dB. The CNN trained without noise was used for this case. The results are summarized in Table 2.1. All the reflectors were detected, with no false detection recorded. Figure 2.11 shows an example of the result obtained on the shallowest FBH (depth of 0.69 mm).

Tableau 2.1 Results of the CNN deconvolution on the raw experimental A-Scans

	True	False	Total
Detection	Reflector detection: 92 (100%)	False detection: 0 (0.0%)	92
Reflector	Reflector detected: 92 (97.9%)	Non-detected reflectors: 0 (0.0%)	92

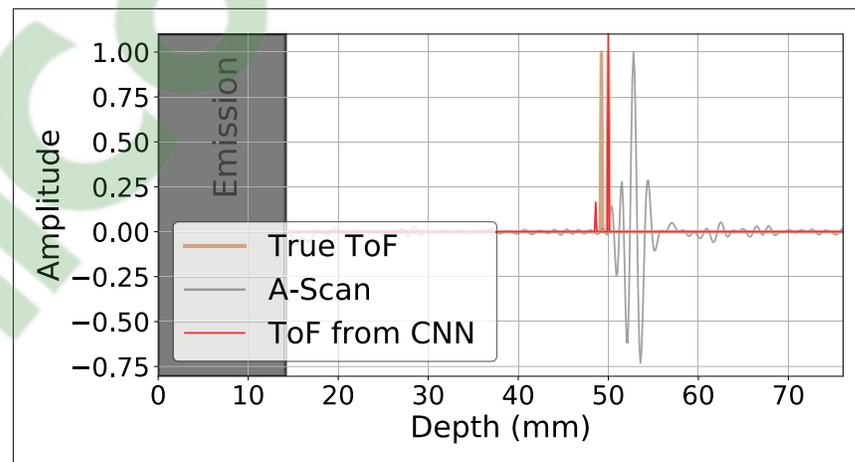


Figure 2.11 Location of reflectors in a raw A-Scan for an FBH with a depth of 0.69 mm

The top of the FBH is slightly misplaced in Figure 2.11, but still within the acceptable range of 5 indices. Although the amplitude of the CNN output was weak, it was above the 10% threshold.

Figure 2.12 shows the location error as a function of the distance between the reflectors for the CNN trained using simulated data and tested on raw experimental measurements.

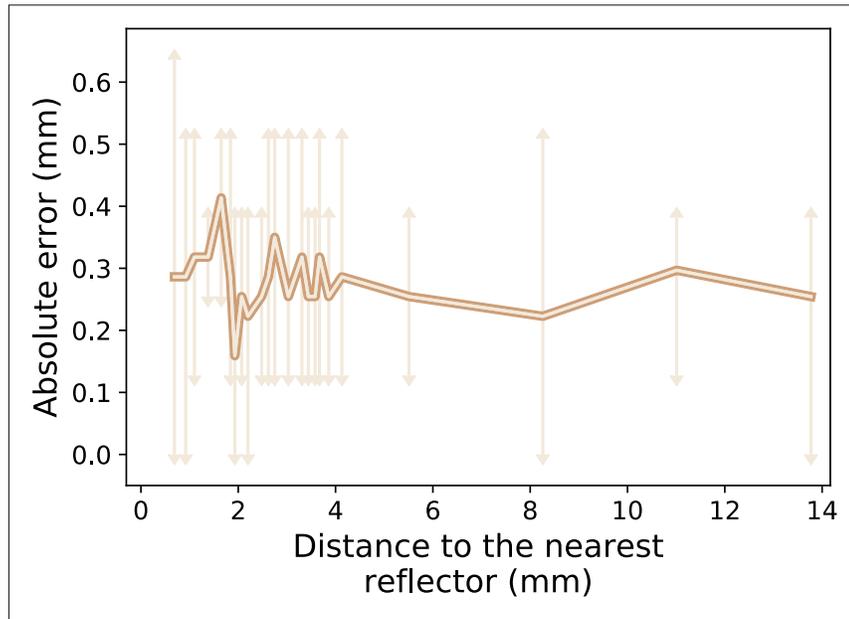


Figure 2.12 Location error in function of the distance to the nearest reflector

In order to verify the performance in a less favorable scenario, the noise level of the experimental A-Scans was synthetically increased to reach an SNR of 20 dB and 5 dB. The method to add the noise was the same as in the simulations.

The results for the SNR of 20 dB are presented in Table 2.2. The SNR of the training set for this case was also 20 dB. In this case, only the two measurements on the shallowest FBH were unsuccessful. Encouragingly, the CNN was right in all other cases and did not give any false detection.

When the SNR was 5 dB, the presence of false detection increased significantly as shown in Table 2.3. The SNR of the training set for this case was also 5 dB. 8% of the detections were false and only 85.1% of the reflectors were detected. As for when the SNR was 20 dB, the shallowest FBH were not detected. The other cases of non-detected reflectors or false detections

Tableau 2.2 Results of the CNN deconvolution on the experimental A-Scans with the noise synthetically increased to reach an SNR of 20 dB

	True	False	Total
Detection	Reflector detection: 92 (100%)	False detection: 0 (0.0%)	92
Reflector	Reflector detected: 92 (97.9%)	Non-detected reflectors: 2 (2.1%)	94

were not linked to the distance between two reflectors. Figure 2.13 shows a successful example, with an SNR of 5 dB when the depth of the FBH was 0.96 mm. This was the shallowest FBH that the CNN was able to distinguish from the backwall when the SNR was set to 5 dB.

Tableau 2.3 Results of the CNN deconvolution on the experimental A-Scans with the noise increased to reach an SNR of 5 dB

	True	False	Total
Detection	Reflector detection: 81 (92%)	False detection: 7 (8.0%)	88
Reflector	Reflector detected: 80 (85.1%)	Non-detected reflectors: 14 (14.9%)	94

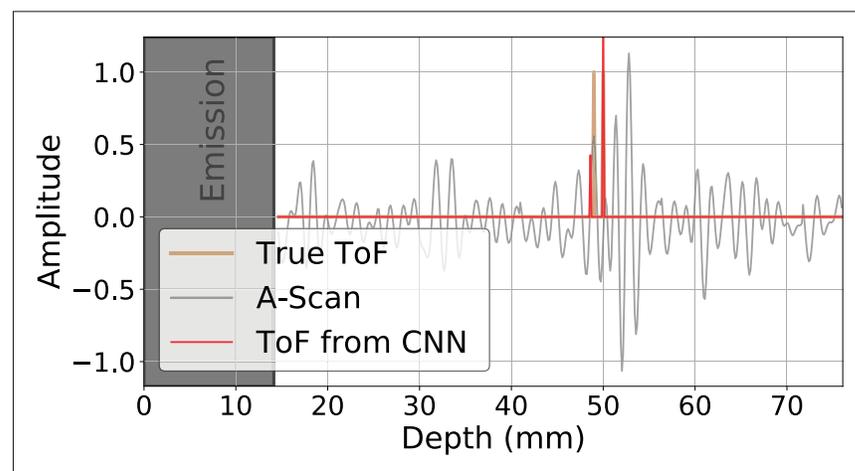


Figure 2.13 Example of an FBH detected with an SNR of 5 dB. The FBH depth was 0.96 mm

A threshold of 10% of the maximum amplitude was used to avoid false detection. Other threshold values were tested when the CNN was trained and tested with the 5 dB SNR. Initially, the threshold was set using only simulations to optimize the number of true detections. Table 2.4 shows the number of false detections and detected reflectors for three different thresholds (1%, 10% (original value) and 20%). A threshold value of 1% clearly led to many false detections, but also increased the number of detected reflectors. When the threshold increased to 20%, the number of detections – true and false – was reduced.

Tableau 2.4 Effect of the threshold value on the deconvolution of the experimental measurements with an SNR of 5 dB

Threshold	1%	10%	20%
False detections	42	7	4
Detected reflectors	90	80	78

The effect of noise on the CNN was also evaluated and the results are summarized in Table 2.5. The table shows the reflectors detected and the false detections for each case (Raw data – SNR = 40 dB, SNR = 20 dB and SNR = 5 dB) using the 3 different trainings (CNN trained without noise, SNR = 20 dB, and SNR = 5 dB).

Tableau 2.5 Results of the three CNN tested with experimental measurements with different added noise values

	CNN – Trained Without Noise Added		CNN – Trained with SNR = 20dB		CNN – Trained with SNR = 5dB	
	Reflectors Detected	False Detections	Reflectors Detected	False Detections	Reflectors Detected	False Detections
SNR = 40 dB (raw data)	100%	0%	93.7%	4.3%	92.6%	2.12%
SNR = 20dB	92.6%	7.4%	97.9%	0%	93.6%	0%
SNR = 5dB	89.4%	12.8%	90.4%	10.7%	85.1%	7.45%

2.5 Discussion

When using the raw experimental data, the CNN was able to separate the echoes for an FBH with a depth of only 0.69 mm. In this case, due to the pulse-echo propagation, this length corresponds to a separation distance of $\lambda/2$ at 2.25 MHz in the aluminum block. Moreover, on the raw experimental data, the CNN correctly identified all reflectors, with no false detection. As the raw experimental A-Scans had an SNR of approximately 40 dB, a standard deconvolution may provide similar results. Figure 2.14 compares the proposed CNN framework with the least squares deconvolution. Figure 2.14 (a) shows a comparison of the raw experimental data with a 0.96 mm FBH, while Figure 2.14 (b) shows the same comparison when noise was added to reach an SNR of 20 dB. The deconvolved signals were filtered in the bandwidth of the original signal. On the raw experimental signals, the deconvolution and the CNN provide similar results. However, when the SNR was reduced to 20 dB, the deconvolution had multiple secondary lobes, leading to difficulty in the interpretation of the results. In the presence of noise, even relatively weak, the proposed CNN framework appears to perform better than the least-squares deconvolution.

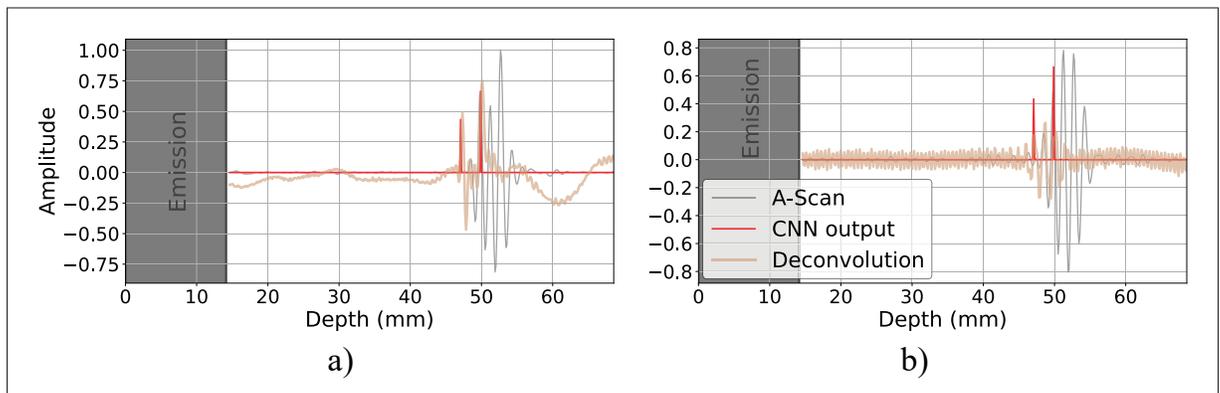


Figure 2.14 Comparison of the proposed CNN framework with the least-squares deconvolution. The FBH had a depth of 1.65 mm. (a) Raw experimental A-Scans and (b) SNR reduced to 20 dB

Figure 2.12 showed that the accuracy of the true detection was approximately 0.3 mm and remained constant for any distance between the reflectors. Hence, the proximity of reflectors did not affect the accuracy of the CNN.

When the SNR was reduced to 20 dB, the axial resolution achieved by the CNN was reduced and the shallowest FBH was not detected. Hence, the CNN was able to distinguish reflectors when the FBH depth was 0.96 mm, corresponding to 0.65λ in an aluminum block at 2.25 MHz.

When the SNR was reduced to 5 dB, the CNN again successfully detected the FBH with a depth of 0.96 mm. The reliability of the CNN was, however, dramatically reduced, with a 7.5% false detection and 14.9% of reflectors missed. Again, no relationship was found between the detected reflectors and their proximity in this case. Hence, the presence of significant noise was a greater problem than the overlapping echoes. Two reasons were identified to explain the number of false detections : 1) the noise was added in the bandwidth of the transducers, and therefore, in some instances, the noise pattern was similar to an echo pattern, and 2) some reflectors were slightly misplaced and dropped out of the acceptable window, and they were not detected and were considered as false detections. Table 2.4 showed that the threshold did have an effect on the performance of the CNN. When the SNR was at 5 dB, the initial threshold (10%) led to non-detected reflectors (see Figure 2.15 (a)). Hence, with a low threshold, the amount of detected reflectors would increase. However, the number of false detections would also increase. A tradeoff is made to keep an acceptable true location rate and false detection rate. The tradeoff between a threshold of 10% and 20% is more questionable, depending on the most unfavorable case (i.e., false detections or reflectors missed). In any case, the choice of the threshold value may have a strong impact on the success of the proposed framework.

In terms of limitations of this study, since it was difficult to compute the contribution of each reflector in amplitude in a wave packet of overlapped echoes, the performance of the CNN in terms of amplitude prediction was therefore not assessed. Another possible limitation of the method presented in this paper is the low number of reflectors present in a single A-Scan. A second study should consider more reflectors in order to open this method up to other appli-

cations, such as ultrasonic guided wave structural health monitoring or ultrasonic tomography, where several modes propagate. Another limitation of the proposed method is the need to re-train the CNN when measurement parameter, such as the transducer bandwidth, change. In such cases, running the simulations would take a few hours, and the training, several minutes.

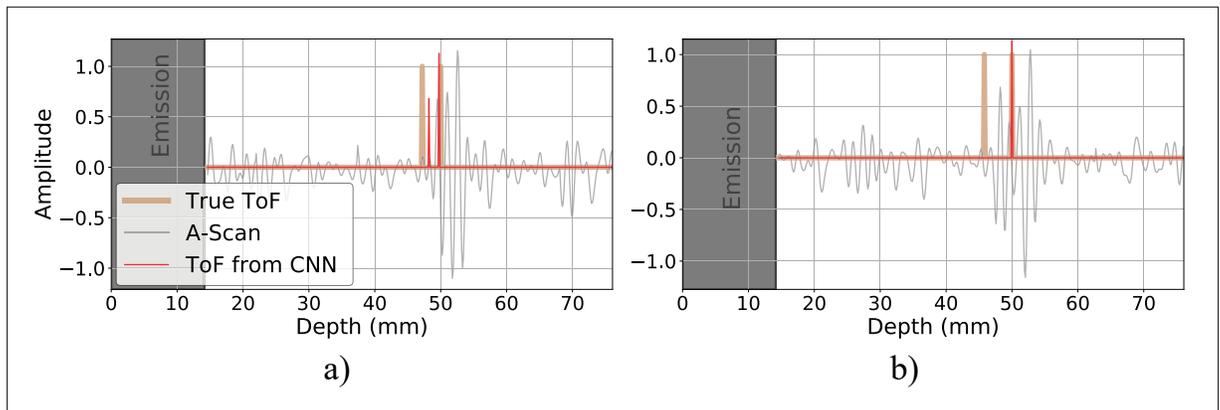


Figure 2.15 Examples of (a) misplaced and (b) non-detected reflectors with a 5 dB noise

2.6 Conclusion

This paper investigated the use of CNN for the deconvolution of A-Scans. The CNN was trained using simulations. However, the simulations were generated from 5 experimental measurements in order to extract the bandwidth of the transducers, the speed of sound in the material, and a typical measurement noise. Using GPU-accelerated FE simulations, 2000 A-Scans were generated in only a few hours. The trained CNN was then used to deconvolve experimental A-Scans acquired on an aluminum block with FBH. On the raw experimental measurements, the axial resolution was 0.5λ , with no false detection and no reflectors missed. When the noise was artificially increased to 20 dB, the axial resolution was reduced to 0.65λ , with no false detection, and only the shallowest FBH missed. When the noise was artificially increased to 5 dB, the axial resolution remained at 0.65λ , but the number of false detections and missed reflectors increased dramatically.

2.7 Acknowledgements

We would like to thank Nvidia for providing us with an Nvidia Quadro P6000 graphics card for our GPU simulations. The authors would also like to thank the Natural Sciences and Engineering Research Council of Canada for funding this project under the oN DuTy! program.

CHAPITRE 3

EXEMPLES D'APPLICATION EN IMAGERIE

3.1 Introduction

L'idée de cette partie est d'élargir les améliorations de la résolution dans les A-Scans à l'imagerie. En effet, le A-Scan seul permet d'avoir une information sur la distance des réflecteurs mais plus difficilement sur leurs positions ou leurs natures. Ainsi dans cette partie, le réseau de neurones présenté dans le chapitre précédent a été adapté puis utilisé pour pré-traiter individuellement chaque signal d'un B-Scan et l'algorithme d'imagerie de focalisation en tout point (TFM) a été utilisé pour obtenir une représentation des réflecteurs dans les pièces étudiées. L'objectif est de comparer les images issues TFM classique avec celles issues d'une TFM utilisant les signaux traités par le réseau de neurones.

Deux cas ont été étudiés dans ce chapitre. Premièrement, l'augmentation de la résolution axiale d'une image TFM a été tentée dans la continuité de la partie précédente. Enfin un essai d'imagerie de l'interface a été testé.

3.2 Augmentation de la résolution des images ultrasonores

Dans cette partie, l'objectif est de comparer une TFM classique et une autre utilisant les signaux traités par le réseau de neurones. Les résultats sont expérimentaux et obtenus sur le même bloc d'aluminium que précédemment. Le transducteur utilisé pour acquérir les données est une sonde P4-2v de Verasonics. Il comporte 64 éléments et a été utilisé à 2 MHz (figure 3.1). Une première série de mesures a permis d'extraire parmi 5 A-Scans un motif général de l'écho de fond dans les conditions expérimentales. Ce motif a été injecté dans les modèles Pogo, similaires à ceux utilisés dans la partie précédente. Les A-Scans simulés sont pré-traités comme décrit dans l'article : rééchantillonnage, coupure des pulsations initiales, normalisation et léger bruitage (ici, 15 dB). Le réseau de neurones a été modifié, en effet, la fréquence du signal et

le nombre de cycles de l'excitation ont changé. La taille de la première couche de convolution compte désormais 63 neurones. Les autres hyperparamètres sont restés identiques.

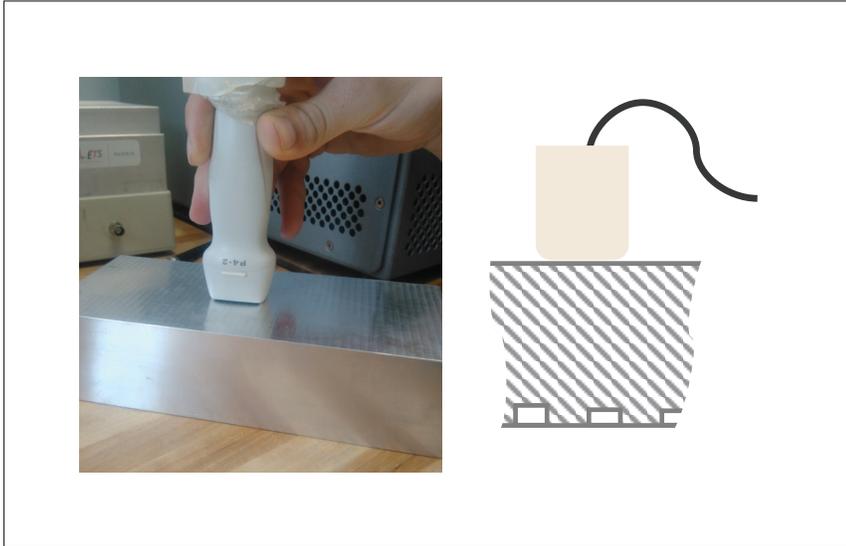


Figure 3.1 À gauche, la sonde multi-élément et le bloc inspecté et à droite, un schéma en coupe du bloc

Une acquisition de type FMC a été faite au dessus du trou à fond plat d'une profondeur de 0.96 mm. Cette profondeur correspond à sept dixième de la longueur d'onde du signal dans le bloc d'aluminium. L'algorithme de TFM classique a été appliqué à la mesure. L'image est présentée à gauche sur la figure 3.2.

Après l'apprentissage, le réseau de neurones a été appliqué à chacun des 4096 A-Scans obtenus avec la FMC (64 éléments en émission pour 64 en réception). Le coût d'application du réseau de neurones est négligeable devant le coût de calcul d'une image TFM. Ensuite, l'algorithme de TFM est appliqué et l'image est obtenue à droite de la figure 3.2.

Sur la TFM standard, l'écho de fond est confondu avec l'écho du trou à fond plat. Leur proximité provoque des interférences rendant difficile l'analyse de la tache colorée. Dans la seconde image, avec les données pré-traitées par le CNN, deux zones colorées sont visibles aux places attendues, la tache inférieure représente le fond de la pièce alors que la tache supérieure re-

présente le trou à fond plat. La distance du maximum des de échos projetée sur l'axe y est de 0.9 mm pour une valeur réelle de 0.96 mm.

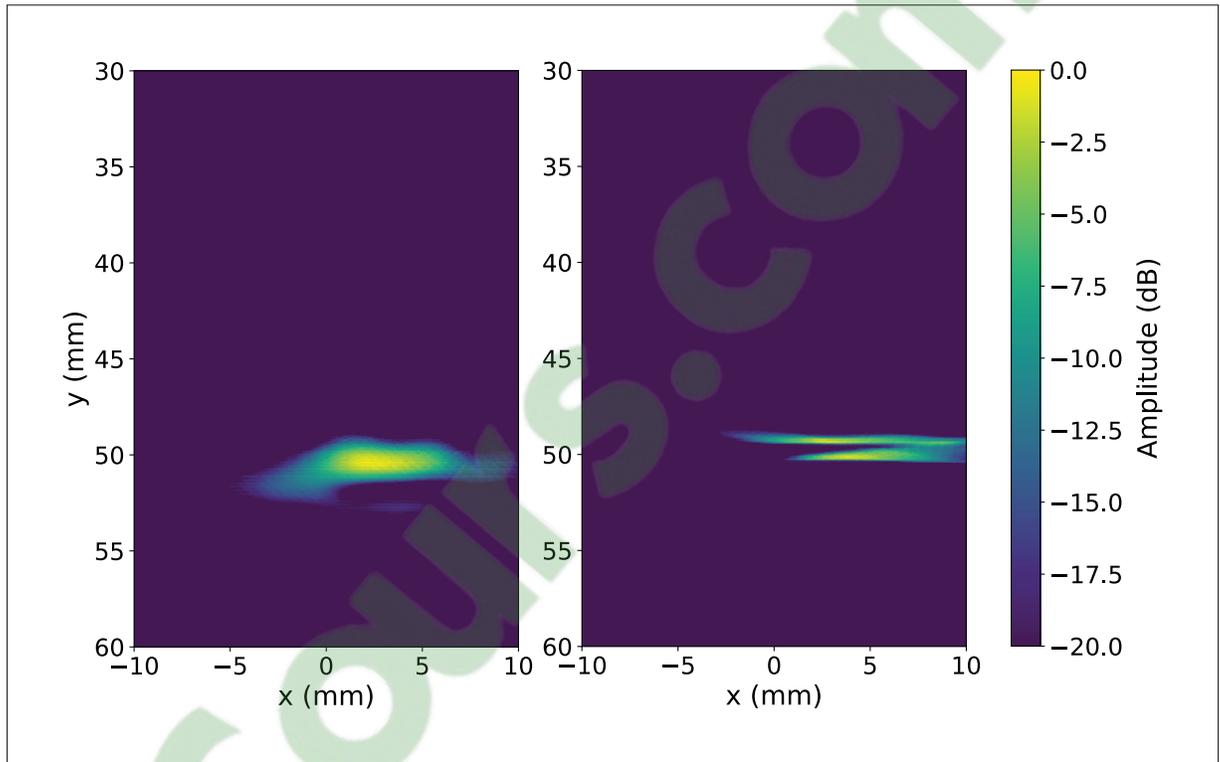


Figure 3.2 Comparaison de deux images obtenues par une TFM : à gauche, la TFM standard et à droite, la TFM obtenues avec les A-Scans pré-traités

Ainsi, le traitement des données d'une FMC par un réseau de neurone permet d'augmenter l'exploitabilité d'une image ultrasonore en donnant une représentation plus quantifiable de la réalité.

3.3 Vers le contournage d'un défaut

Dans cette partie, l'objectif est d'obtenir des informations sur la forme de l'interface détectée. Cette information est capitale pour déterminer la nature du défaut associé. Contrairement à ce qui a été fait précédemment, le bloc utilisé est un bloc en acier inoxydable percé de trous de côté, visible sur la figure 3.3. Le but est d'observer la forme de l'écho sur une image TFM au

voisinage d'un des trous et de voir dans quelle mesure la tâche suit l'interface avec et sans aide du CNN.



Figure 3.3 Bloc en acier inoxydable percé de trous de côté à contourner

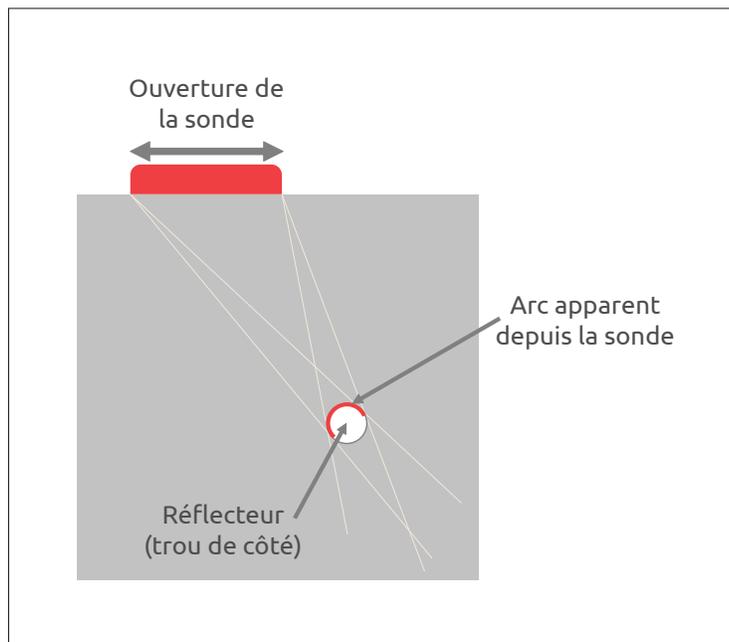


Figure 3.4 Schéma de l'arc apparent du point de vue du transducteur

En se plaçant dans le cas d'un trou de côté dans un bloc, on peut connaître l'arc apparent sur le contour du défaut du point de vue de la sonde multi-élément comme sur la figure 3.4.

La procédure pour la phase d'apprentissage reste la même qu'avant. Cependant des modifications sont apportées au modèle Pogo : les paramètres matériaux utilisés sont ceux du bloc d'acier et la forme du réflecteur simulé passe d'un rectangle à un cercle. L'architecture du réseau n'est pas modifiée car la durée d'un écho ne dépend pas du matériau. En effet, la sonde P4-2v émet le même signal que dans la section 3.2.

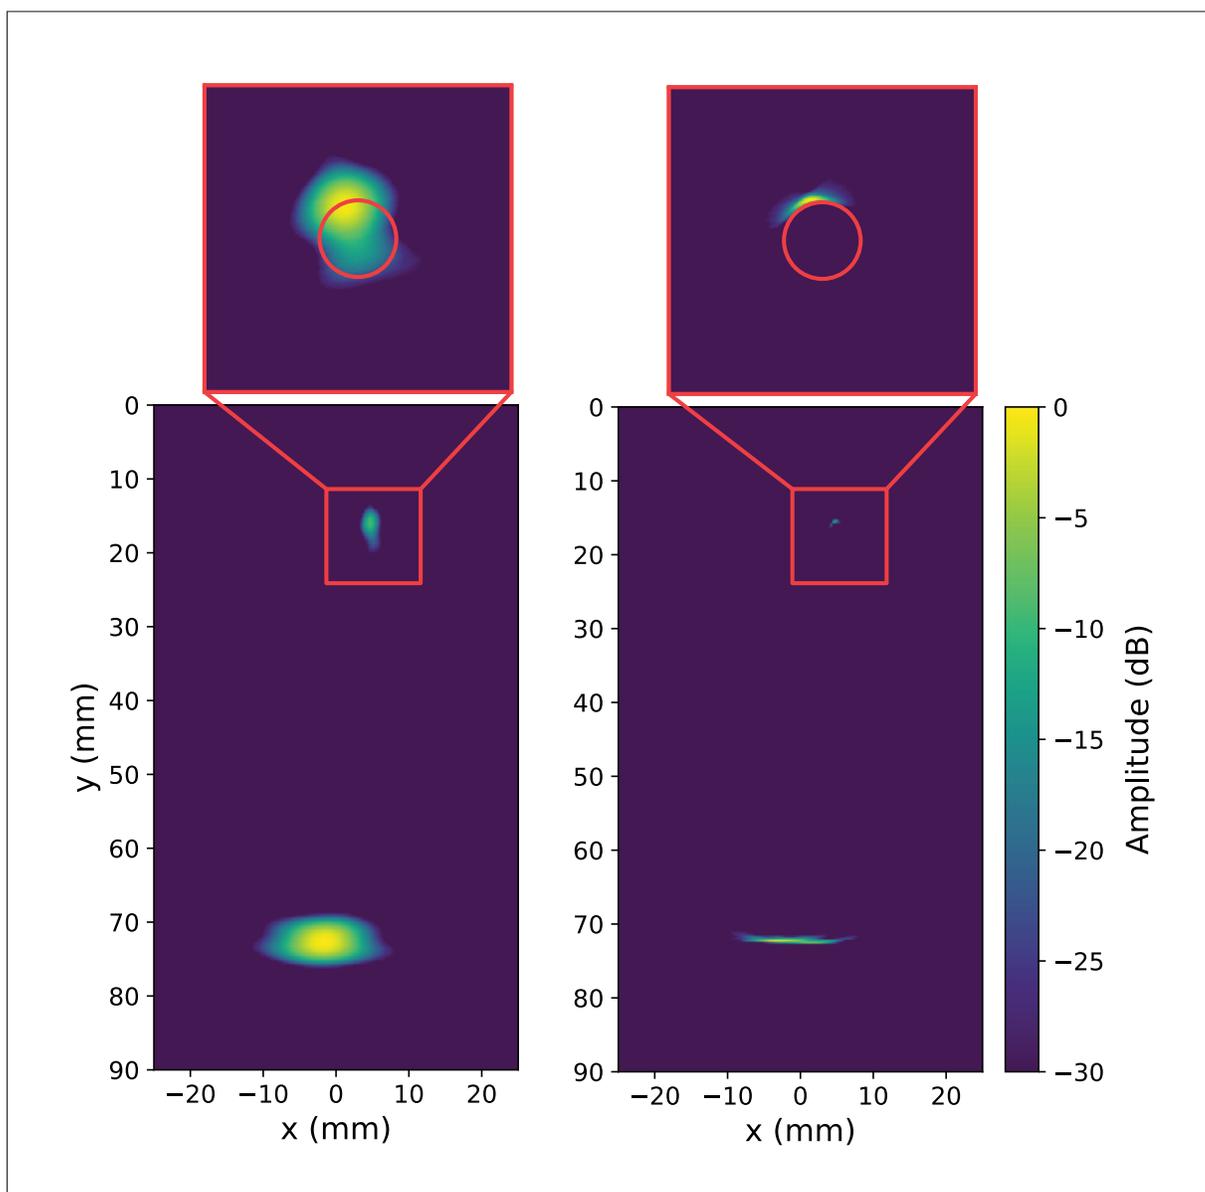


Figure 3.5 À gauche, un trou de côté représenté avec la méthode TFM classique, à droite, le même trou représenté avec les signaux pré-traités par le CNN.

La figure 3.5 présente les résultats de la TFM avec les données pré-traitées par le CNN comparativement à l'image TFM classique. La zone colorée indiquant la présence d'un trou sur l'image de gauche ne permet pas de prédire la forme du défaut. Le maximum en amplitude de la tache est bien situé exactement sur l'interface. Sur l'image de droite, la zone colorée suit le contour de l'interface sur trente degrés tout en s'atténuant fortement aux extrémités de l'arc.

La forme de la tache colorée sur l'image TFM utilisant les signaux pré-traités suit le contour du trou de manière satisfaisante, mais sur un angle assez réduit. Cette faible longueur de l'interface visible sur l'image risque de rendre la prédiction de la nature du réflecteur hasardeuse. Il devrait être possible d'augmenter la longueur de la surface vue en faisant circuler le transducteur au dessus du trou (ce qui reviendrait à augmenter l'ouverture de la sonde), ou bien en profitant des réflexions sur les autres interfaces de la pièce. Par exemple, un rebond intermédiaire sur le fond permettrait d'obtenir des informations sur le dessous du trou.

On peut noter plusieurs limitations de cette méthode de contournage du défaut. Tout d'abord l'ouverture du transducteur doit être relativement grande par rapport à la taille du réflecteur et ce dernier doit être dans une zone peu éloignée de la sonde et pas trop loin de son centre. Ensuite, le défaut doit être plus gros qu'une demi-longueur d'onde pour ne pas être modélisé comme une source point.

3.4 Conclusion sur l'imagerie

La méthode de mise au point et d'apprentissage d'un CNN développée dans le chapitre 2 a été appliquée dans un domaine plus exploitable au niveau industriel dans cette partie : l'imagerie ultrasonore.

Les résultats en matière d'augmentation de la résolution axiale d'une image TFM sont intéressants et permettent de faire une mesure quantitative même dans le cas où deux défauts sont extrêmement proches. Dans le cas où il fallait détecter le contour du défaut, les résultats expérimentaux sont plus décevants et ne sont pas assez concluants pour déterminer la taille ou la nature du défaut.

Dans les deux cas, les images ultrasonores expérimentales ont été réalisées à partir de mesures en laboratoire, en connaissant le type de réflecteur recherché, ce qui a, par exemple, permis d'adapter l'apprentissage (via l'entraînement avec des simulations) aux cas attendus. Cette dépendance au connaissance du contexte peut être une limite aux résultats présentés ici.

CONCLUSION ET RECOMMANDATIONS

Deux points sont remarquables dans ce projet. Premièrement, le réseau de neurones paraît être une alternative convenable à l'opération de déconvolution telle qu'elle est utilisée en contrôle ultrasonore. L'algorithme est capable de distinguer deux réflecteurs dans un bloc d'aluminium, distant de 0.69 mm, à une fréquence de 2.25 MHz. La limite de la demi-longueur d'onde est atteinte lorsque le bruit est faible. Cependant ce dernier devient gênant lorsqu'il atteint un SNR de 5 dB en augmentant le nombre de fausses détections. Ensuite, l'utilisation du logiciel Pogo permet de générer rapidement une base de données massives pour entraîner un réseau de neurones tout en obtenant des résultats très satisfaisants. Quelques transformations rapides sur cette base de données ont été nécessaires pour adapter le réseau de neurones à ce cas précis. Dans le cas du traitement du signal par des réseaux de neurones, cette méthode paraît efficace dans un but d'augmenter la taille du lot de données. Sans être l'objectif principal de cette étude, ce fait sera très intéressant pour des projets futurs.

Un intérêt de traiter le signal plutôt que l'image est le temps de calcul : le réseau de neurones prend un temps extrêmement court pour extraire les données (délai et amplitude des réflecteurs). Il serait possible de faire cette analyse en temps réel, ce qui pourrait présenter une application intéressante pour l'assistance à la détection.

Dans la mesure où le cas étudié ici est extrêmement simple, avec des réflecteurs imposants, parallèles à la surface. Il serait intéressant de tester l'algorithme dans des cas plus complexes, comme par exemple distinguer deux délaminations très proches dans une plaques de métal roulé, ou dans un milieu bruité, sans bruit ajouté en post-traitement. Cela permettrait d'élargir les résultats à un domaine plus industriel.

On pourra remarquer que, comme pour la déconvolution, une connaissance a priori du contexte, de la réflectivité et des paramètres de la mesure sont nécessaires. Il est dommage de ne pas

pouvoir s'affranchir de cela, même si, dans ce cas, seuls cinq A-Scans expérimentaux ont été utilisés pour entraîner le réseau.

Le pré-traitement des données par la méthode présentée dans le chapitre 2 avant de les utiliser en imagerie ultrasonore par la méthode de focalisation en tout point a permis d'augmenter sensiblement la lisibilité des mesures expérimentales réalisées en laboratoire et présentées dans la partie 3. Comme pour les A-Scans, la résolution axiale des images a été augmentée : deux défauts séparés de 0.96 mm ont été facilement localisés. La tentative de dessiner le contour d'une interface s'avère plus limitée, un arc de 30° a pu être affiché autour d'un réflecteur circulaire. Des axes d'améliorations de cette idée ont été identifiés comme par exemple l'utilisation d'un rebond intermédiaire sur le fond de la pièce.

BIBLIOGRAPHIE

- Bickel, S. H. & Martinez, D. (1983). Resolution performance of Wiener filters. *Geophysics*, 48(7), 887–899.
- Bloxham, H. A., Velichko, A. & Wilcox, P. D. (2016). Combining simulated and experimental data to simulate ultrasonic array data from defects in materials with high structural noise. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 63(12), 2198–2206.
- Brizuela, J., Katchadjian, P., Garcia, A. & Desimone, C. (2016). Spatial image compounding applied to a phase coherence corrected UT-PA technique for inspecting nuclear components of coarse-grained structure. *AIP Conference Proceedings*, 1706(1), 070011.
- Cheeke, J. D. N. (2002). *Fundamentals and applications of ultrasonic waves*. CRC press.
- Chen, J., Bai, X., Yang, K. & Ju, B.-F. (2013). An ultrasonic methodology for determining the mechanical and geometrical properties of a thin layer using a deconvolution technique. *Ultrasonics*, 53(7), 1377–1383.
- Cicero, T., Cawley, P., Simonetti, F. & Rokhlin, S. (2009b). Potential and limitations of a deconvolution approach for guided wave structural health monitoring. *Structural Health Monitoring*, 8(5), 381–395.
- Cicero, T. (2009a). *Signal processing for guided wave structural health monitoring*. (Thèse de doctorat, Department of Mechanical Engineering, Imperial College London).
- Crump, N. D. (1975). Techniques for the deconvolution of seismic signals. *1975 IEEE Conference on Decision and Control including the 14th Symposium on Adaptive Processes*, pp. 2–8.
- Dance, D., Christofides, S., Maidment, A., McLean, I. & Ng, K. (2014). Diagnostic radiology physics. *International Atomic Energy Agency*, 299.
- Durand, T. (2017). *Weakly supervised learning for visual recognition*. (Thèse de doctorat, Paris 6).
- Espinosa, L., Bacca, J., Prieto, F., Lasaygues, P. & Brancheriau, L. (2018). Accuracy on the time-of-flight estimation for ultrasonic waves applied to non-destructive evaluation of standing trees : a comparative experimental study. *Acta Acustica united with Acustica*, 104(3), 429–439.
- Falardeau, T. & Bélanger, P. (2018). Ultrasound tomography in bone mimicking phantoms : Simulations and experiments. *The Journal of the Acoustical Society of America*, 144(5), 2937–2946.
- Gallager, R. G. (2008). *Principles of digital communication*. Technical Publications.

- Goodfellow, I., Bengio, Y., Courville, A. & Bengio, Y. (2016). Deep learning. vol. 1. MIT press Cambridge.
- Goyal, D. & Pabla, B. (2016). The vibration monitoring methods and signal processing techniques for structural health monitoring : a review. *Archives of Computational Methods in Engineering*, 23(4), 585–594.
- Guarneri, G. A., Pipa, D. R., Neves, F. & de Arruda, L. V. (2017). A blind deconvolution approach to discontinuity location and characterization in ultrasonic nondestructive testing. *2017 25th European Signal Processing Conference (EUSIPCO)*, pp. 2496–2500.
- Guerchaoui, A., Balluet, J.-C. & Lacoume, J.-L. (1989). Etude comparative des principales méthodes de déconvolution sur des données de type sismique. *TS Traitement du signal*, 6(3), 187–203.
- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.
- Hoseini, M. R., Wang, X. & Zuo, M. J. (2012). Estimating ultrasonic time of flight using envelope and quasi maximum likelihood method for damage detection and assessment. *Measurement*, 45(8), 2072–2080.
- Huthwaite, P. (2014). Accelerated finite element elastodynamic simulations using the GPU. *Journal of Computational Physics*, 257, 687–707.
- Izadifar, Z., Babyn, P. & Chapman, D. (2017). Mechanical and biological effects of ultrasound : A review of present knowledge. *Ultrasound in medicine & biology*, 43(6), 1085–1104.
- Jurkevics, A. & Wiggins, R. (1984). A critique of seismic deconvolution methods. *Geophysics*, 49(12), 2109–2116.
- Kim, Y. H., Song, S.-J. & Kim, J. Y. (2004). A new technique for the identification of ultrasonic flaw signals using deconvolution. *Ultrasonics*, 41(10), 799–804.
- LeCun, Y. et al. (1989). Generalization and network design strategies. Dans *Connectionism in perspective* (vol. 19). Citeseer.
- Li, C., Huang, L., Duric, N., Zhang, H. & Rowe, C. (2009). An improved automatic time-of-flight picker for medical ultrasound tomography. *Ultrasonics*, 49(1), 61–72.
- Loupas, T., Pye, S. & McDicken, W. (1989). Deconvolution in medical ultrasonics : practical considerations. *Physics in Medicine & Biology*, 34(11), 1691.
- Munir, N., Kim, H.-J., Park, J., Song, S.-J. & Kang, S.-S. (2019). Convolutional neural network for ultrasonic weldment flaw classification in noisy conditions. *Ultrasonics*, 94, 74–81.
- Perrot, P. (1993). *Deconvolution algorithms applied in ultrasonics*. Clamart : Electricite de France (EDF).

- Rajagopal, P., Drozd, M., Skelton, E. A., Lowe, M. J. & Craster, R. V. (2012). On the use of absorbing layers to simulate the propagation of elastic waves in unbounded isotropic media using commercially available finite element packages. *NDT & E International*, 51, 30–40.
- Rawat, W. & Wang, Z. (2017). Deep convolutional neural networks for image classification : A comprehensive review. *Neural computation*, 29(9), 2352–2449.
- Robinson, E. A. & Treitel, S. (2000). *Geophysical signal analysis*. Society of Exploration Geophysicists.
- Rosenblatt, F. (1958). The perceptron : a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Sapriel, J. (1994). Ultrasons. *Techniques de l'ingénieur. Electronique*, 1(E1910), E1910–1.
- Schmerr Jr, L. W. (2014). *Fundamentals of ultrasonic phased arrays*. Springer.
- Shull, P. J. (2002). *Nondestructive evaluation : theory, techniques, and applications*. CRC press.
- Soussen, C., Idier, J., Carcreff, E., Simon, L. & Potel, C. (2012). Ultrasonic non destructive testing based on sparse deconvolution. *Journal of Physics : Conference Series*, 353(1), 012018.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout : a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929–1958.
- Virkkunen, I., Koskinen, T., Jessen-Juhler, O. & Rinta-Aho, J. (2019). Augmented Ultrasonic Data for Machine Learning. *arXiv preprint arXiv :1903.11399*.
- Virupakshappa, K., Marino, M. & Oruklu, E. (2018). A Multi-Resolution Convolutional Neural Network Architecture for Ultrasonic Flaw Detection. *2018 IEEE International Ultrasonics Symposium (IUS)*, pp. 1–4.
- Weston, J., Ratle, F., Mobahi, H. & Collobert, R. (2012). Deep learning via semi-supervised embedding. Dans *Neural Networks : Tricks of the Trade* (pp. 639–655). Springer.