

Reconstruction de profils de corrosion à partir d'images
ultrasonores à l'aide de réseaux antagonistes génératifs
conditionnels (cGAN)

par

Antoine CUVILLIER

MÉMOIRE PAR ARTICLE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE
SUPÉRIEURE COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA
MAÎTRISE AVEC MÉMOIRE EN GÉNIE MÉCANIQUE
M. Sc. A.

MONTRÉAL, LE 11 DÉCEMBRE 2025

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Antoine Cuvillier, 2025



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette oeuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'oeuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉE

PAR UN JURY COMPOSÉ DE:

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

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

M. Guillaume Painchaud-April, examinateur externe
Evident Scientific

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

LE 8 DÉCEMBRE 2025

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je souhaite tout d'abord exprimer ma profonde gratitude à M. Pierre Bélanger pour m'avoir offert l'opportunité de réaliser ce projet de recherche et pour la confiance qu'il m'a témoignée tout au long de ma maîtrise. Sa rigueur scientifique, ses conseils avisés et sa grande disponibilité ont été essentiels à l'aboutissement de ce mémoire. Je le remercie également pour les occasions de conférence et de publication auxquelles j'ai pu participer grâce à son encadrement.

Je tiens également à remercier Evident Industrial pour son soutien financier, qui m'a permis de mener ce projet dans d'excellentes conditions, ainsi qu'Alain Le Duff et Guillaume Painchaud-April pour leur accompagnement, leurs retours pertinents et leur implication tout au long de cette collaboration.

Mes remerciements s'adressent aussi à l'ensemble des membres du laboratoire PULÉTS, dont l'ambiance stimulante et l'esprit de collaboration ont largement contribué à la réussite de ce projet. Je pense notamment à Aubin, Aurélien, Thibault, Éloi, Paul, Lucas, Tony, Rafaël, Léo, Maxime et Wala'a, dont le soutien, les échanges et la bonne humeur ont rendu cette expérience aussi enrichissante qu'agréable.

Enfin, j'adresse mes plus sincères remerciements à ma famille et à mes proches pour leur soutien constant tout au long de cette aventure au Québec.

Reconstruction de profils de corrosion à partir d'images ultrasonores à l'aide de réseaux antagonistes génératifs conditionnels (cGAN)

Antoine CUVILLIER

RÉSUMÉ

La cartographie de la corrosion par contrôle ultrasonore est largement utilisée dans le domaine industriel, mais demeure une tâche complexe en raison de la difficulté d'interprétation des données acquises. Pour y remédier, une méthode basée sur un réseau antagoniste génératif conditionnel (conditional Generative Adversarial Network, cGAN), entraîné à partir de données simulées et expérimentales, est proposée afin d'interpréter les images ultrasonores et de générer des profils de corrosion schématiques destinés à assister les inspecteurs dans l'analyse des résultats.

Les jeux de données simulés ont été générés à l'aide d'un solveur par éléments finis accéléré sur GPU, intégrant des profils de corrosion réalistes, les caractéristiques des sondes et différents niveaux de bruit. Les données expérimentales ont été acquises avec une grande précision de positionnement à l'aide d'un bras robotisé et d'une sonde multiéléments ultrasonore. L'architecture du cGAN repose sur un générateur de type U-Net pour traduire les images ultrasonores en représentations schématiques de corrosion, tandis qu'un discriminateur convolutionnel assure le réalisme des images générées.

Plusieurs stratégies d'entraînement ont été évaluées et comparées, incluant des approches basées uniquement sur des données simulées, des ensembles mixtes et des techniques d'apprentissage par transfert. Les performances ont été mesurées à l'aide de métriques telles que l'erreur quadratique moyenne (MSE), l'indice de similarité structurale (SSIM), la corrélation de Pearson et la distance de Hausdorff.

Enfin, le modèle proposé a été comparé à la méthode conventionnelle d'intensité maximale, démontrant une amélioration significative dans l'estimation de l'épaisseur et la précision du profil de corrosion reconstruit. Les résultats montrent que les images issues de la méthode Total Focusing Method (TFM) produisent systématiquement les reconstructions les plus précises, et que l'apprentissage par transfert améliore nettement les performances du modèle, en particulier pour les entrées de type B-Scan à plus faible résolution. Cette approche met en évidence le potentiel de l'imagerie ultrasonore assistée par intelligence artificielle pour reconstruire avec précision des profils de corrosion complexes, offrant ainsi une base solide pour le développement de techniques de contrôle non destructif avancées en milieu industriel.

Mots-clés: TFM, B-Scan, FMC, Contrôle non destructif, Ultrason, cGAN, Corrosion

CREATING SCHEMATIC REPRESENTATION OF CORROSION USING CGAN AND ULTRASONIC IMAGING

Antoine CUVILLIER

ABSTRACT

Corrosion mapping using ultrasonic testing is widely employed in industry but remains a challenging task due to the complexity of interpreting the acquired data. To address this, a method based on a conditional Generative Adversarial Network (cGAN), trained on both simulated and experimental data, is proposed to interpret ultrasonic images and generate schematic corrosion profiles that assist inspectors in data interpretation. Simulated datasets were generated using a GPU-accelerated finite element solver, incorporating realistic corrosion patterns, probe characteristics, and noise. Experimental data were acquired with high positional accuracy using a robotic arm and ultrasonic phased array probe. A U-Net generator is employed in the cGAN architecture to translate ultrasonic images into schematic corrosion representations, while a convolutional discriminator ensures realism in the generated outputs. Several training strategies, including simulated-only, mixed, and transfer learning approaches, were evaluated and compared in this paper. Performance was assessed using metrics such as Mean Squared Error, Structural Similarity Index, Pearson correlation, and Hausdorff distance. Additionally, the proposed model is compared with the traditional maximum-intensity method, demonstrating a substantial improvement in thickness estimation and corrosion profile accuracy. Results indicate that the Total Focusing Method (TFM) inputs consistently yield superior reconstruction quality, and that transfer learning substantially improves the model's performance, particularly when the inputs are lower-resolution B-Scan. The proposed approach demonstrates the potential of AI-driven ultrasonic imaging to accurately reconstruct complex corrosion profiles, providing a framework for enhanced nondestructive evaluation in industrial applications.

Keywords: TFM, B-Scan, FMC, non-destructive testing, Ultrasound, cGAN, corrosion

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE.	3
1.1 Présentation générale de la théorie des ondes ultrasonores	3
1.1.1 Equation de propagation à une dimension	3
1.1.2 Equation de propagation à trois dimension	4
1.1.3 Phénomène d'atténuation des ondes	8
1.1.4 Comportement des ondes ultrasonores aux interfaces	8
1.2 L'imagerie ultrasonore	10
1.2.1 Les sondes ultrasonores	10
1.2.2 Le A-Scan	10
1.2.3 Le B-Scan	11
1.2.4 Exemple d'image ultrasonore 'B-Scan' pour un profil corrodé	12
1.2.5 Construction d'image : Total Focusing Method (TFM)	13
1.3 Les réseaux de neurones	14
1.3.1 Réseaux multicouches et structure d'un réseau de neurones	14
1.3.2 Fonctions d'activation	16
1.3.3 Apprentissage supervisé et rétropropagation	17
1.3.4 Améliorations pratiques : normalisation et régularisation	18
1.3.4.1 Batch Normalization	18
1.3.4.2 Le Dropout	18
1.3.5 Réseaux de neurones convolutionnels (CNN)	19
1.3.6 Présentation du cGAN (conditional Generative Adversarial Network)	20
CHAPITRE 2 CORROSION PROFILE RECONSTRUCTION FROM ULTRASONIC IMAGING USING CONDITIONAL GANS	23
2.1 Abstract	23
2.2 Introduction	24
2.3 Materials and Methods	26
2.3.1 Simulation of Ultrasonic Data for Corrosion Profiling	26
2.3.1.1 Material Parameters	26
2.3.1.2 Generation of the Input Signal	27
2.3.1.3 Generation of Corrosion Profiles	28
2.3.1.4 Incorporating noise into simulated data	30
2.3.2 Generation of Experimental Data	31
2.3.3 Ultrasonic Imaging Parameters	33
2.3.3.1 B-Scan	33
2.3.3.2 TFM	33
2.3.3.3 Maximum Intensity Method for Corrosion Profiling	35
2.3.4 Architecture	35

2.3.4.1	Generator	36
2.3.4.2	Discriminator	37
2.3.4.3	Training parameters	38
2.3.4.4	Performance Metrics	41
2.4	Results	44
2.5	Discussion	52
2.6	Conclusion	56
CONCLUSION ET RECOMMANDATIONS		59
BIBLIOGRAPHIE		61

LISTE DES FIGURES

	Page
Figure 1.1	Illustration des deux types de propagation d'ondes 7
Figure 1.2	Illustration des deux types de propagation d'ondes 9
Figure 1.3	Fonctionnement A-Scan 11
Figure 1.4	Exemple de B-Scan 12
Figure 1.5	Fonctionnement de la création d'une FMC 13
Figure 1.6	Création d'une TFM 14
Figure 1.7	Schéma d'un réseau multicouche 15
Figure 1.8	Illustration du fonctionnement d'un réseau de neurones convolutionnel . 20
Figure 2.1	Comparison between the simulated input and the experimental input 28
Figure 2.2	Steps involved in corrosion profile generation 29
Figure 2.3	Different corrosion profiles generated for varying corrosion amplitude σ and correlation length λ 29
Figure 2.4	Simulated ultrasonic signal showing simulated signal, noise distribution, filtered noise, and final noisy signal 30
Figure 2.5	Experimental dataset generation process showing (a) simulated corrosion profile, (b) distribution of corrosion generation parameters along the part, (c) machined profile on a 1018 steel block, and (d) ultrasonic probe positioning using a robotic arm 32
Figure 2.6	Illustration of the TFM creation process 34
Figure 2.7	Example of ultrasonic imaging techniques 35
Figure 2.8	Model of the Generator Molinier, Painchaud-April, Le Duff, Toews & Bélanger (2023) 37
Figure 2.9	Model of the Discriminator 38
Figure 2.10	Visual examples of predicted vs. ground truth corrosion profiles to illustrate the different evaluation metrics : (a) low MSE, (b) high

	correlation with offset, (c) shape mismatch (low correlation), and (d) missing region (Hausdorff distance)	43
Figure 2.11	Hausdorff distance results across dataset configurations	44
Figure 2.12	Mean squared error (MSE) results across dataset configurations	45
Figure 2.13	Pearson correlation results across dataset configurations	45
Figure 2.14	Structural similarity index (SSIM) results across dataset configurations ..	46
Figure 2.15	Structural similarity index (SSIM) of the backwall across different dataset configurations	46
Figure 2.16	Best correlation results for dataset #8 (100% simulated data). Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green	48
Figure 2.17	Worst correlation results for dataset #8 (100% simulated data). Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green	49
Figure 2.18	Best correlation results for dataset #10 after transfer learning. Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green	50
Figure 2.19	Worst correlation results for dataset #10 after transfer learning. Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green	51

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

2D	Bidimensionnel
3D	Tridimensionnel
AI	Intelligence Artificielle (Artificial Intelligence)
CND	Contrôle Non Destructif (Nondestructive Evaluation)
CNN	Réseau de Neurones Convolutifs (Convolutional Neural Network)
cGAN	Réseaux antagonistes génératifs conditionnels (Conditional Generative Adversarial Network)
D	Discriminateur
FE	Éléments finis (Finite Element)
FMC	Capture de Matrice Complète (Full Matrix Capture)
GAN	Generative Adversarial Networks
G	Générateur
GPU	Processeur graphique (Graphics Processing Unit)
IA	Intelligence Artificielle
MLP	Perceptron multicouche (Multi-Layer Perceptron)
MSE	Erreur Quadratique Moyenne (Mean Squared Error)
NDE	Contrôle Non Destructif (Nondestructive Evaluation)
ReLU	Unité rectifiée linéaire (Rectified Linear Unit)
SSIM	Structure similaire
TFM	Méthode de focalisation en tous points (Total Focusing Method)

LISTE DES SYMBOLES ET UNITÉS DE MESURE

b	Biais du perceptron
c	Vitesse de l'onde
d	Épaisseur de la pièce (m)
E	Module de Young (Pa)
f	Fréquence (MHz)
I	Intensité acoustique (W/m^2)
m	Mètre
m/s	Mètre par seconde
s	Seconde / Sortie des réseaux de neurones
V	Vitesse de propagation de l'onde (m/s)
w	Poids des réseaux de neurones
x	Entrée des réseaux de neurones
α	Coefficient d'atténuation (m^{-1})
$\theta_{i,r,t,L,T}$	Angle de l'onde : incidente, réfléchie, transmise, Longitudinale, Transversale (rad)
σ	Fonction d'activation
ν	Coefficient de Poisson (sans unité)
λ	Longueur d'onde (m)
ρ	Masse volumique (kg/m^3)

INTRODUCTION

La corrosion constitue l'un des mécanismes de dégradation les plus critiques affectant l'intégrité structurelle des composants métalliques dans des secteurs industriels variés, tels que l'aérospatiale, la pétrochimie ou la production d'énergie. La mesure précise des profils de corrosion est essentielle pour évaluer l'épaisseur résiduelle des matériaux, garantir la sécurité des opérations et orienter les décisions de maintenance. Dans ce contexte, le contrôle non destructif par ultrasons (CND) est largement utilisé, puisqu'il permet d'inspecter les pièces en place sans prélèvements destructifs.

À partir des données FMC (Full Matrix Capture), il est possible de générer des images de type B-Scan ou TFM. Le B-Scan demeure de loin le plus utilisé en inspection grâce à sa simplicité et à son intégration dans les pratiques établies, tandis que la TFM, bien qu'en pleine croissance, reste encore en marge des méthodes véritablement normées dans la majorité des contrôleurs phased-array.

Malgré leur utilité, les approches FMC/TFM et B-Scan présentent des limites dans la reconstruction précise de la géométrie des défauts. Si elles permettent de détecter la présence de corrosion ou de discontinuités, l'interprétation des images reste largement dépendante de l'expertise humaine, ce qui peut introduire variabilité et erreurs, notamment pour des défauts complexes ou ambigus. Par ailleurs, la résolution inférieure des B-Scans standards peut réduire la fidélité de la visualisation des défauts, motivant le recours à des techniques de reconstruction assistée par intelligence artificielle (IA).

Traditionnellement, une méthode simple basée sur l'intensité maximale des pixels est utilisée pour estimer l'épaisseur des pièces à partir des images ultrasonores. Pour chaque colonne d'une image TFM ou B-Scan, le pixel d'amplitude maximale est identifié et sert à estimer la position du fond de pièce. Cette approche fournit une estimation directe de l'épaisseur de l'échantillon, mais reste très sensible au bruit et aux fluctuations du signal. Dans ce mémoire, cette méthode sert de référence pour comparer les performances de l'approche basée sur l'IA.

Les avancées récentes en intelligence artificielle, et plus particulièrement dans l'apprentissage profond (Deep Learning), offrent des solutions prometteuses pour surmonter ces limitations. Les Réseaux Antagonistes Génératifs (Generative Adversarial Networks ou GANs) ont démontré un potentiel important dans la génération et la reconstruction d'images. Les cGANs (conditionnel GANs) étendent cette capacité en générant des sorties conditionnées par des données d'entrée, ce qui les rend particulièrement adaptés à la traduction d'images ultrasonores, qu'il s'agisse de TFM ou de B-Scans, vers des représentations interprétables des profils de corrosion.

Dans ce mémoire, après une revue de la littérature sur les techniques d'inspection ultrasonore et les méthodes d'IA appliquées à la reconstruction d'images, une approche cGAN est proposée pour reconstruire des schémas 2D détaillés de pièces corrodées à partir d'images ultrasonores. L'objectif principal est de développer un modèle capable de générer des profils de corrosion précis et fiables, en combinant les avantages des données simulées pour la diversité des scénarios et des données expérimentales pour la fidélité réelle. La contribution spécifique du mémoire réside dans la conception et l'évaluation d'un cGAN entraîné initialement sur des données simulées, puis adapté via transfert learning à des données expérimentales, et dans l'établissement d'un cadre d'évaluation rigoureux basé sur des métriques objectives (MSE, distance de Hausdorff, corrélation, SSIM) pour comparer les profils générés aux profils réels. Cette approche permet de proposer une alternative à l'analyse traditionnelle dépendante de l'expertise humaine, tout en améliorant la précision et la reproductibilité de la reconstruction des profils de corrosion.

CHAPITRE 1

REVUE DE LITTÉRATURE.

1.1 Présentation générale de la théorie des ondes ultrasonores

Les ultrasons sont des ondes mécaniques de haute fréquence, supérieures à 20 kHz et donc inaudibles pour l'oreille humaine, capables de se propager dans des solides, des liquides ou des gaz. Leur comportement dépend des propriétés du matériau traversé ainsi que des interfaces rencontrées, et peut être décrit et prédit avec précision à l'aide de modèles physiques et mathématiques. Dans le domaine du contrôle non destructif (CND), les ultrasons sont largement utilisés pour mesurer l'épaisseur des pièces, détecter la présence de défauts internes et caractériser certaines propriétés mécaniques des matériaux, grâce à leur aptitude à pénétrer les solides et à fournir des informations détaillées sur leur structure interne.

1.1.1 Equation de propagation à une dimension

Dans un premier temps, il est important de noter que l'équation de propagation d'une onde peut être décrite par l'équation de d'Alembert. Celle-ci a été obtenue en combinant la loi de Hooke et la seconde loi de Newton, en considérant une onde unidimensionnelle se propageant dans un matériau isotrope et homogène (Cheeke & Cheeke, 2002).

Considérons un déplacement $u(x, t)$, fonction du temps et de l'espace, dans un fragment de matériau de longueur dx , lors du passage de l'onde ultrasonore. La déformation s'écrit alors :

$$\varepsilon = \frac{\partial u}{\partial x} \quad (1.1)$$

D'après les hypothèses, il est possible d'appliquer la loi de Hooke afin de déterminer la déformation du matériaux suivante :

$$\sigma = E \cdot \varepsilon \quad (1.2)$$

De plus, en appliquant la loi de Newton pour une force volumique appliqué sur une partie de matériaux, on obtient :

$$\frac{\partial \sigma}{\partial x} = \rho \frac{\partial^2 u}{\partial t^2} \quad (1.3)$$

Alors en combinant l'équation (1.2) ainsi que l'équation (1.3), nous obtenons :

$$\frac{\partial^2 u}{\partial x^2} = \frac{\rho}{E} \frac{\partial^2 u}{\partial t^2} \quad (1.4)$$

Il nous est alors possible de déterminer le déplacement $u(x, t)$ grâce à la solution générale de l'équation (1.4) :

$$u = A \exp j(\omega t - kx) + B \exp j(\omega t + kx) \quad (1.5)$$

En tenant compte que ω est la pulsation de l'onde, que le nombre d'onde est défini par $k = \frac{\omega}{c}$, et que la célérité de l'onde est donnée par $c = \sqrt{\frac{E}{\rho}}$, on obtient une description complète du déplacement d'une particule dans un milieu unidimensionnel.

1.1.2 Equation de propagation à trois dimension

La description du déplacement dans un matériau unidimensionnel ne suffit pas à représenter fidèlement la réalité. C'est pourquoi Euler a généralisé la propagation des ondes au cas tridimensionnel. Cette approche permet d'étendre l'équation (1.3) à trois dimensions (Shull, 2002) :

$$\sum_j \frac{\partial \sigma_{ij}}{\partial x_j} = \rho \frac{\partial^2 u_j}{\partial t^2} \quad (1.6)$$

Avec ρ la masse volumique du matériau. D'après la loi de Hooke généralisée, le tenseur des contraintes peut s'exprimer de la manière suivante :

$$\sigma_{ij} = \sum_k \sum_l c_{ijkl} \varepsilon_{kl} \quad (1.7)$$

Avec c_{ijkl} le tenseur d'élasticité et ε_{kl} le tenseur des déformations. Dans le cas où le matériau est homogène et isotrope, cette équation peut s'écrire sous la forme suivante :

$$\sigma_{ij} = (c_{11} - 2c_{44}) \sum_l \varepsilon_{ll} \delta_{ij} + 2c_{44} \varepsilon_{ij} \quad (1.8)$$

où δ_{ij} est le symbole de Kronecker, et :

$$\varepsilon_{ij} = \frac{1}{2} \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \quad (1.9)$$

Alors en combinant les équations (1.6) et (1.8), il nous est possible d'obtenir la forme vectorielle suivante :

$$\rho \frac{\partial^2 \vec{u}}{\partial t^2} = (c_{11} - c_{44}) \vec{\nabla} (\vec{\nabla} \cdot \vec{u}) + c_{44} \nabla^2 \vec{u} \quad (1.10)$$

En appliquant la décomposition de Helmholtz, le déplacement vectoriel $\vec{u}$ peut être exprimé comme la somme d'un champ scalaire φ et d'un champ vectoriel rotationnel $\vec{\Phi}$:

$$\vec{u} = \vec{\nabla} \varphi + \vec{\nabla} \times \vec{\Phi} = \vec{u}_L + \vec{u}_T \quad (1.11)$$

Enfin, grâce aux équations (1.10) et (1.11) on obtient l'équation suivante définie par φ et $\vec{\Phi}$:

$$\rho \vec{\nabla} \frac{\partial^2 \varphi}{\partial t^2} + \rho \vec{\nabla} \times \frac{\partial^2 (\vec{\Phi})}{\partial t^2} = (c_{11} - c_{44}) \vec{\nabla} (\nabla^2 \varphi) + c_{44} \nabla^2 (\vec{\nabla} \varphi) + c_{44} \nabla^2 (\vec{\nabla} \times \vec{\Phi}) \quad (1.12)$$

On peut alors séparer deux parties distinct de cette équation en la mettant sous la forme :

$$\vec{\nabla} \left(\rho \frac{\partial^2 \varphi}{\partial t^2} - c_{11} \nabla^2 \varphi \right) + \vec{\nabla} \times \left(\rho \frac{\partial^2 \vec{\Phi}}{\partial t^2} - c_{44} \nabla^2 \vec{\Phi} \right) = \vec{0} \quad (1.13)$$

On remarque alors deux termes, un scalaire à gauche et un vecteur à droite, alors l'équation (1.13) est nulle si chacun des deux termes est nulle donc on obtient ces deux équations :

$$\begin{cases} \rho \frac{\partial^2 \varphi}{\partial t^2} = c_{11} \nabla^2 \varphi \\ \rho \frac{\partial^2 \vec{\Phi}}{\partial t^2} = c_{44} \nabla^2 \vec{\Phi} \end{cases} \quad (1.14)$$

On distingue ainsi deux équations différentielles indépendantes correspondant respectivement à une onde longitudinale (associée au potentiel scalaire φ) et à une onde transversale (associée au potentiel vectoriel $\vec{\Phi}$). Elles sont de la même forme que l'équation (1.4), ce qui permet de déterminer les vitesses de propagation des ondes longitudinales (c_L) et transversales (c_T) :

$$\begin{cases} c_L = \sqrt{\frac{c_{11}}{\rho}} \\ c_T = \sqrt{\frac{c_{44}}{\rho}} \end{cases} \quad (1.15)$$

Une expression plus couramment utilisée fait intervenir les propriétés mécaniques usuelles du matériau : le module d'Young E et le coefficient de Poisson ν :

$$\begin{cases} c_L = \sqrt{\frac{E}{\rho} \left(\frac{1-\nu}{(1+\nu)(1-2\nu)} \right)} \\ c_T = \sqrt{\frac{E}{\rho} \frac{1}{2(1+\nu)}} \end{cases} \quad (1.16)$$

On constate alors qu'il existe uniquement deux types de propagation pouvant se propager dans un matériau isotrope et homogène et qu'une onde transmise est la combinaison linéaire de ces deux types de propagation. La Figure 1.1 présente le fonctionnement de ces deux types de propagation.




Figure 1.1 Illustration des deux types de propagation d'ondes

1.1.3 Phénomène d'atténuation des ondes

Il est essentiel de prendre en compte le phénomène d'atténuation lors de l'analyse de la propagation ultrasonore. En effet, l'énergie d'une onde décroît progressivement à mesure qu'elle se propage dans le matériau, non seulement en raison de l'absorption, phénomène intimement lié aux propriétés thermomécaniques du matériau et dont l'intensité croît avec le carré de la fréquence, mais également du fait de la dispersion. Cette dernière résulte des interactions de l'onde avec les hétérogénéités microscopiques (joints de grains, impuretés, dislocations, défauts cristallins), qui diffusent une partie de l'énergie hors de la direction de propagation et génèrent des ondes parasites. L'atténuation observée dans un solide est donc la combinaison de ces mécanismes, et non d'un unique phénomène. Cette diminution d'intensité est modélisée par l'équation suivante :

$$I = I_0 \cdot e^{-2\alpha x} \quad (1.17)$$

où x est la distance parcourue par l'onde au sein de la pièce, I est l'intensité de l'onde à cette distance x , I_0 l'énergie initiale et α est le coefficient d'atténuation de l'onde dans le matériau. L'atténuation peut être influencée par plusieurs caractéristiques, telles que l'absorption du matériau, qui dépend des effets thermiques du matériau, ou la composition du matériau, notamment la présence ou non de défauts comme des joints de grains, des fissures, des dislocations ou autres. Tout ceci est décrit en détail dans la littérature (Cheeke & Cheeke, 2002).

1.1.4 Comportement des ondes ultrasonores aux interfaces

Lors d'une inspection par ultrasons, une onde mécanique se propage dans un matériau et peut rencontrer un changement de milieu (fissure, inclusion, interface solide/liquide, etc.). Ces discontinuités modifient la propagation de l'onde : une partie de son énergie est transmise, tandis qu'une autre est réfléchi. Ce phénomène, incluant la réfraction, est gouverné par la loi de Snell-Descartes :

$$\frac{\sin(\theta_i)}{c_i} = \frac{\sin(\theta_{rT})}{c_{rT}} = \frac{\sin(\theta_{rL})}{c_{rL}} = \frac{\sin(\theta_{tT})}{c_{tT}} = \frac{\sin(\theta_{tL})}{c_{tL}} \quad (1.18)$$

Dans cette loi, θ_i , θ_{rT} , θ_{rL} , θ_{tT} et θ_{tL} représentent respectivement l'angle d'incidence, les angles de réflexion des ondes transversale et longitudinale, ainsi que les angles de transmission des ondes transversale et longitudinale. De plus les paramètres c_i , c_{rT} , c_{rL} , c_{tT} et c_{tL} sont les vitesses de ces ondes respectives. Ce phénomène est illustré sur la Figure 1.2.




Figure 1.2 Illustration des deux types de propagation d'ondes

En définissant l'impédance acoustique d'un matériau comme $Z = \rho c$, il est possible d'évaluer les coefficients de réflexion (R) et de transmission (T) d'une onde à l'interface entre deux milieux :

$$\begin{cases} R = \frac{Z_2 - Z_1}{Z_2 + Z_1} \\ T = 1 + R \end{cases} \quad (1.19)$$

où ρ est la masse volumique du matériau et c la vitesse de propagation de l'onde, il est possible de déterminer la part d'énergie réfléchie R et transmise T .

Il est toutefois important de noter que ces expressions ne sont valables qu'en incidence normale et pour des milieux isotropes. Dans le cas général, l'angle d'incidence influence fortement les coefficients de réflexion et de transmission, et il est alors nécessaire d'appliquer les lois de Snell-Descartes.

1.2 L'imagerie ultrasonore

Dans cette section, nous nous intéressons à l'imagerie ultrasonore, et plus particulièrement aux méthodes permettant sa mise en œuvre. Cette technique est l'une des plus couramment utilisées en contrôle non destructif, car elle permet à l'inspecteur d'interpréter visuellement les données recueillies, facilitant ainsi l'évaluation de l'état du matériau inspecté.

1.2.1 Les sondes ultrasonores

L'imagerie ultrasonore repose sur l'émission et la réception d'ondes acoustiques, assurées par les sondes ultrasonores. Ces transducteurs, généralement de type piézoélectrique, sont capables de convertir une excitation électrique en une onde acoustique, et inversement.

Les sondes piézoélectriques existent sous différentes formes, mais les plus répandues sont les sondes multi-éléments, également appelées sondes phased array. Celles-ci sont caractérisées par plusieurs paramètres, notamment le nombre d'éléments, leur géométrie, et l'espacement entre eux (pitch).

1.2.2 Le A-Scan

Un A-Scan correspond à l'enregistrement de l'amplitude d'un signal ultrasonore en fonction du temps. Il peut être obtenu à partir d'un seul élément piézoélectrique (comme dans une sonde mono-élément classique) ou de l'un des éléments d'une sonde phased array. Dans ce dernier cas, chaque élément du réseau peut émettre et/ou recevoir indépendamment, fournissant ainsi autant d'A-Scans que l'on souhaite activer d'éléments. Les échos enregistrés traduisent les réflexions internes engendrées par les interfaces, les défauts ou le fond de pièce.

Étant donné que la vitesse de propagation de l'onde est connue dans un matériau homogène, chaque écho peut être associé à une distance parcourue. Ainsi, l'analyse temporelle du signal permet d'estimer l'épaisseur de la pièce ou encore la position d'un défaut interne.




Figure 1.3 Fonctionnement A-Scan

La figure 1.3 illustre la réponse typique d'un A-Scan dans une pièce comportant un défaut. Le premier pic correspond à l'émission de l'impulsion ultrasonore, le second à la réflexion sur le défaut, et le troisième à l'écho de fond de la pièce.

1.2.3 Le B-Scan

Le B-Scan constitue une méthode d'imagerie ultrasonore élémentaire. Il consiste à juxtaposer plusieurs A-Scans acquis successivement, ce qui permet de reconstruire une image bidimensionnelle représentant une coupe du matériau inspecté.

La Figure 1.4 illustre un exemple de B-Scan, où chaque A-Scan est affiché côte à côte pour former l'image complète.




Figure 1.4 Exemple de B-Scan

1.2.4 Exemple d'image ultrasonore 'B-Scan' pour un profil corrodé

Les méthodes présentées précédemment constituent les approches les plus rudimentaires en imagerie ultrasonore. L'utilisation d'une sonde multi-éléments permet d'aller bien au-delà, notamment grâce à l'acquisition d'une matrice complète des signaux émis et reçus, appelée Capture Matricielle Complète (Full Matrix Capture, FMC).

Le principe de la FMC repose sur l'acquisition de toutes les combinaisons possibles entre les éléments émetteurs et récepteurs d'une même sonde. Plus précisément, chaque élément de la sonde émet successivement un signal ultrasonore dans la pièce à inspecter. Pour chaque émission, tous les éléments de la sonde, y compris celui ayant émis le signal, enregistrent la réponse acoustique sous forme de A-Scans. Ce processus est répété jusqu'à ce que chaque élément ait joué le rôle d'émetteur une fois. L'ensemble des A-Scans obtenus est ensuite organisé dans une matrice, la Capture Matricielle Complète, contenant toutes les réponses possibles pour chaque paire émetteur-récepteur. La figure 1.5 illustre ce processus de manière schématique.




Figure 1.5 Fonctionnement de la création d'une FMC

1.2.5 Construction d'image : Total Focusing Method (TFM)

La méthode d'imagerie ultrasonore la plus précise et la plus répandue à ce jour est le TFM (Total Focusing Method). Elle repose sur l'utilisation d'un algorithme de type delay-and-sum (DAS), dont l'objectif est de tirer parti de l'ensemble des signaux enregistrés dans la Capture Matricielle Complète (FMC, cf. section 1.2.4) afin de reconstruire au mieux les variations d'amplitude dans une région d'intérêt du milieu inspecté.

Le principe de la TFM consiste à se focaliser sur un point donné de la pièce, donc de la future image. En connaissant la célérité des ondes ultrasonores dans le matériau (supposé homogène), et pour chaque A-Scan de la FMC, les éléments émetteurs et récepteurs impliqués, il est possible de calculer le temps de vol de l'onde entre l'émetteur, le point de focalisation et le récepteur, comme illustré à la figure 1.6.

À partir de ces temps de vol, on peut extraire dans chaque A-Scan l'amplitude du signal correspondant à ce trajet spécifique. La sommation cohérente de ces amplitudes permet alors d'estimer l'intensité du signal associé à ce point focal. En répétant ce processus pour tous les

points de la région d'intérêt, on obtient une image complète où chaque pixel correspond à une amplitude reconstruite : il s'agit de l'image TFM.




Figure 1.6 Création d'une TFM

1.3 Les réseaux de neurones

Les réseaux de neurones artificiels constituent une pierre angulaire de l'intelligence artificielle. Inspirés du fonctionnement des neurones biologiques, ils sont conçus pour apprendre des représentations complexes à partir de données brutes. Leur essor a été considérablement favorisé par les progrès de l'informatique moderne, notamment grâce à l'utilisation massive des GPU permettant un calcul parallèle efficace.

1.3.1 Réseaux multicouches et structure d'un réseau de neurones

Un réseau de neurones dense, aussi appelé perceptron multicouche (MLP, pour *Multi-Layer Perceptron*), est une architecture formée de plusieurs couches successives de neurones artificiels. On y distingue généralement une couche d'entrée, une ou plusieurs couches dites « cachées », et une couche de sortie comme présenté sur la figure 1.7. Chaque couche est constituée de plusieurs unités appelées 'neurones artificiels', connectés à tous les neurones de la couche précédente (connexion dite « dense » ou « fully connected »).




Figure 1.7 Schéma d'un réseau multicouche

Le bloc fondamental de ce type de réseau est le 'neurone artificiel', dont le premier modèle formel a été proposé par Rosenblatt dans les années 1950 sous le nom de perceptron (Rosenblatt, 1958). Chaque neurone effectue une opération élémentaire : il calcule une somme pondérée des entrées reçues, y ajoute un biais, puis applique une fonction d'activation non linéaire. Cette opération est modélisée par l'équation suivante :

$$s = \sigma \left(\sum_{k=1}^n w_k x_k + b \right) \quad (1.20)$$

où x_k désigne les entrées, w_k les poids associés, b le biais, et σ la fonction d'activation. Cette dernière joue un rôle crucial : elle introduit de la non-linéarité dans le réseau, ce qui permet de modéliser des relations complexes entre les données.

1.3.2 Fonctions d'activation

Sans fonction d'activation, l'empilement de plusieurs couches linéaires serait équivalent à une seule couche linéaire. Pour pallier cela, différentes fonctions non linéaires sont utilisées, chacune ayant ses avantages. Parmi les plus courantes, on retrouve :

- La fonction sigmoïde : $\sigma(x) = \frac{1}{1+e^{-x}}$, utile pour modéliser des probabilités, mais sensible à la saturation pour les grandes valeurs absolues.
- La tangente hyperbolique : $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$, centrée en zéro, mais également sujette à la saturation.
- La ReLU (Rectified Linear Unit), définie comme :

$$\text{ReLU}(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ x & \text{si } x > 0 \end{cases} \quad (1.21)$$

largement utilisée pour sa simplicité et son efficacité (Agarap, 2019).

Cependant, la ReLU présente un inconvénient : si les entrées d'un neurone sont constamment négatives, sa sortie reste nulle, et le gradient est également nul, ce qui empêche la mise à jour des poids lors de l'apprentissage. Ce phénomène, appelé 'dying ReLU', peut conduire à l'inactivité permanente de certains neurones (Lau & Hann Lim, 2018).

Pour y remédier, la fonction Leaky ReLU a été introduite. Elle conserve une pente légère pour les entrées négatives, ce qui garantit un gradient non nul même si $x \leq 0$ (Dubey & Jain, 2019) :

$$\text{Leaky ReLU}(x) = \begin{cases} 0.01x & \text{si } x \leq 0 \\ x & \text{si } x > 0 \end{cases} \quad (1.22)$$

Cette légère modification permet d'améliorer la stabilité de l'apprentissage, notamment dans les réseaux profonds ou mal initialisés (Xu, Wang, Chen & Li, 2015).

1.3.3 Apprentissage supervisé et rétropropagation

Le fonctionnement d'un réseau de neurones repose sur un processus d'apprentissage supervisé, dans lequel le modèle apprend à associer des entrées à des sorties connues. L'objectif est d'ajuster progressivement les poids internes du réseau afin de minimiser l'écart entre les prédictions du modèle et les valeurs attendues (Murphy, 2012).

Cet ajustement repose sur l'optimisation d'une fonction de coût, qui quantifie l'erreur entre la sortie générée et la sortie cible. Dans le cadre de tâches de génération d'image, cette fonction mesure à quel point l'image produite est similaire à celle attendue. Selon le type de tâche, différentes fonctions peuvent être utilisées : erreur quadratique moyenne (MSE), erreur absolue moyenne (MAE).

Pour minimiser cette erreur, on utilise la descente de gradient, une méthode itérative qui consiste à mettre à jour les poids du réseau dans la direction opposée au gradient de la fonction de coût. Le calcul des gradients s'effectue à l'aide de l'algorithme de rétropropagation, qui propage l'erreur depuis la sortie du réseau vers les couches précédentes, permettant ainsi l'ajustement de tous les paramètres internes.

Dans la pratique, cet algorithme de descente est souvent combiné à des techniques d'optimisation plus avancées. L'optimiseur Adam (Adaptive Moment Estimation), largement utilisé dans les architectures modernes, améliore la descente de gradient classique en adaptant dynamiquement le taux d'apprentissage pour chaque paramètre, en tenant compte des moments d'ordre un et deux des gradients (Kingma & Ba, 2017). Cela permet une convergence plus rapide et plus stable, en particulier dans les réseaux profonds.

1.3.4 Améliorations pratiques : normalisation et régularisation

1.3.4.1 Batch Normalization

Dans l'apprentissage des réseaux de neurones profonds, la Batch Normalization est aujourd'hui une méthode standard pour accélérer et stabiliser l'entraînement. Elle consiste à normaliser les activations d'une couche en temps réel, à chaque itération, en utilisant les statistiques (moyenne et écart type) calculées sur le mini-lot d'exemples en cours de traitement. Concrètement, cette normalisation permet de maintenir les activations dans des plages de valeurs maîtrisées, évitant ainsi que certaines couches ne produisent des sorties excessivement grandes ou faibles, ce qui nuirait à la propagation du gradient.

Introduite par Ioffe et Szegedy, cette technique visait initialement à réduire ce qu'ils ont appelé le *décalage covariant interne* (Ioffe & Szegedy) : le fait que, pendant l'apprentissage, les entrées des couches intermédiaires changent constamment de distribution à mesure que les poids précédents sont mis à jour. En stabilisant ces entrées, la Batch Normalization rend chaque couche moins sensible aux perturbations causées par les couches précédentes.

Au-delà de cette motivation initiale, des recherches plus récentes ont montré que l'efficacité de la Batch Normalization repose surtout sur un effet plus profond : elle rend la fonction de coût plus « lisse », c'est-à-dire que les gradients y varient de manière plus régulière (Santurkar, Tsipras, Ilyas & Madry, 2018). Cela facilite la descente de gradient, permet l'utilisation de taux d'apprentissage plus élevés, et rend l'optimisation plus stable, notamment dans les réseaux très profonds.

1.3.4.2 Le Dropout

Lorsque l'on entraîne un réseau de neurones, il peut arriver que celui-ci apprenne à trop bien s'ajuster aux données d'entraînement, au détriment de sa capacité à généraliser sur des données nouvelles. Le dropout est une méthode conçue pour limiter ce phénomène, connu sous le nom de surapprentissage. Son fonctionnement repose sur une idée simple mais efficace : pendant

l'apprentissage, certains neurones sont temporairement ignorés, de manière aléatoire, à chaque passage dans le réseau (Srivastava, Hinton, Krizhevsky, Sutskever & Salakhutdinov).

Cette désactivation partielle oblige le modèle à ne pas reposer uniquement sur un petit groupe de neurones, mais à répartir l'apprentissage entre différentes parties du réseau. On obtient ainsi une représentation plus robuste, moins sensible aux variations des données ou aux erreurs locales.

L'application du dropout se fait uniquement à l'entraînement ; lors de l'inférence, tous les neurones sont réactivés, mais leurs contributions sont réajustées pour compenser les absences durant la phase d'apprentissage.

1.3.5 Réseaux de neurones convolutionnels (CNN)

Alors que les réseaux de neurones multicouches classiques (MLP) traitent des vecteurs d'entrée, les réseaux de neurones convolutionnels (CNN, pour Convolutional Neural Networks) sont spécifiquement conçus pour traiter des données structurées en grille, comme les images (Goodfellow, Bengio & Courville, 2016).

Une couche convolutionnelle applique un filtre (ou kernel) sur l'image d'entrée en le déplaçant par translation sur l'ensemble de l'image. À chaque position, une multiplication élément par élément est effectuée entre les valeurs du filtre et celles de la portion d'image couverte. La somme de ces produits donne une unique valeur pour cette position. L'ensemble des valeurs obtenues constitue une carte de caractéristiques (feature map), qui met en évidence des motifs locaux tels que les bords, textures ou motifs spécifiques.




Figure 1.8 Illustration du fonctionnement d'un réseau de neurones convolutionnel

Afin d'éviter une perte d'information aux bords de l'image et de conserver les dimensions initiales après convolution, il est courant d'ajouter des pixels supplémentaires (souvent de valeur nulle) autour de l'image. Ce processus est appelé padding et permet au filtre de traiter correctement les régions en périphérie.

1.3.6 Présentation du cGAN (conditional Generative Adversarial Network)

Avec les notions présentées précédemment, les modèles profonds sont aujourd'hui capables non seulement d'analyser le contenu et les caractéristiques d'une image, mais également d'en générer une nouvelle à partir de différents paramètres d'entrée. Parmi ces modèles, les GAN (Generative Adversarial Networks) se sont imposés comme une solution solide pour des tâches telles que la génération d'images, la segmentation ou encore la synthèse de données (Creswell *et al.*, 2018). Une variante particulièrement intéressante pour les applications conditionnées est

le cGAN (conditional GAN), qui permet de produire des images ciblées en fonction d'une entrée spécifique, généralement une autre image (Isola, Zhu, Zhou & Efros, 2017).

Dans un cGAN, le générateur G et le discriminateur D reçoivent tous deux une information de condition x , ce qui permet de guider la génération. Cette condition peut être un vecteur de paramètres, une étiquette, ou, comme c'est souvent le cas dans les tâches dites image-to-image, une image complète. Le générateur apprend à produire une image réaliste $G(x)$ à partir de cette condition, tandis que le rôle du discriminateur est de distinguer si une paire (x, y) provient des données réelles ou a été produite artificiellement, c'est-à-dire si $y = G(x)$ est crédible.

Le cGAN repose sur un apprentissage adversarial, où les deux réseaux s'entraînent simultanément selon des objectifs opposés. Le discriminateur cherche à maximiser sa capacité à différencier les vraies paires (x, y) des paires synthétiques $(x, G(x))$, tandis que le générateur cherche à le tromper en produisant des images qui rendent cette distinction difficile. Cette dynamique est formalisée par la perte adversariale, qui s'écrit :

$$\mathcal{L}_{\text{adv}}(G, D) = \mathbb{E}_{x,y} [\log(D(x, y))] + \mathbb{E}_x [\log(1 - D(x, G(x)))] \quad (1.23)$$

Le conditionnement à la création d'image cible y fait de cette architecture un outil adapté à la création d'image, comme c'est le cas en imagerie ultrasonore.

Conclusion de la revue de littérature

La revue de littérature montre que les méthodes classiques d'imagerie ultrasonore (A-Scan, B-Scan, TFM) permettent de détecter la corrosion ou d'autres types de défauts, mais restent dépendantes de l'interprétation humaine. Les réseaux de neurones, et plus particulièrement les architectures de type cGAN, ont montré de bons résultats pour la génération et la traduction d'images dans de nombreux domaines. Cette efficacité suggère qu'ils pourraient également être appliqués à l'imagerie ultrasonore pour reconstruire des profils de corrosion à partir des images acquises. Le présent mémoire se distingue en utilisant un cGAN entraîné initialement sur des

données simulées, puis ajusté via un mélange de données simulées et expérimentales dans une approche de transfert learning.

Méthodologie

La méthodologie adoptée dans ce mémoire commence par la création de données simulées, incluant la génération de profils de corrosion réalistes et l'ajout de bruit, afin de constituer un ensemble de données couvrant différents scénarios. Le cGAN est ensuite entraîné d'abord uniquement sur ces données simulées, avant d'être affiné par transfert learning à l'aide de données expérimentales. Enfin, les profils générés par le modèle sont analysés à l'aide de métriques objectives telles que la MSE, la distance de Hausdorff, la corrélation et la SSIM, afin d'évaluer la précision, la robustesse et la fidélité de la reconstruction. Cette approche combine la flexibilité des simulations et la fidélité des données expérimentales.

CHAPITRE 2

CORROSION PROFILE RECONSTRUCTION FROM ULTRASONIC IMAGING USING CONDITIONAL GANS

Antoine Cuvillier¹ , Guillaume Painchaud-April² , Alain Le Duff² , Pierre Bélanger¹

¹ PULETS, École de technologie supérieure, 1100 Notre-Dame Street West, Montréal, Canada

² Evident Industrial, 3415 Rue Pierre-Ardouin, Québec, QC, G1P 0B3, Canada

Article soumis à la revue « NDT & E International » en Novembre 2025.

2.1 Abstract

Corrosion mapping using ultrasonic testing is widely employed in industry but remains a challenging task due to the complexity of interpreting the acquired data. To address this, a method based on a conditional Generative Adversarial Network (cGAN), trained on both simulated and experimental data, was proposed to interpret ultrasonic images and generate schematic corrosion profiles that assist inspectors in data interpretation. Simulated datasets were generated using a GPU-accelerated finite element solver, incorporating realistic corrosion patterns, probe characteristics, and noise. Experimental data were acquired with high positional accuracy using a robotic arm and an ultrasonic phased array probe. A U-Net generator was employed in the cGAN architecture to translate ultrasonic images into schematic corrosion representations, while a convolutional discriminator ensured realism in the generated outputs. Several training strategies, including simulated-only, mixed, and transfer learning approaches, were evaluated and compared in this paper. Performance was assessed using metrics such as the Mean Squared Error, the Structural Similarity Index, the Pearson correlation, and the Hausdorff distance. Additionally, the proposed model was compared with the traditional maximum-intensity method, demonstrating a substantial improvement in thickness estimation and corrosion profile accuracy. Results indicated that the Total Focusing Method (TFM) inputs consistently yielded superior reconstruction quality, and that transfer learning substantially improved the model's performance, particularly when the inputs were lower-resolution B-Scan. The proposed approach demonstrated the potential of AI-driven ultrasonic imaging to accurately reconstruct complex

corrosion profiles, providing a framework for enhanced nondestructive evaluation in industrial applications.

keywords : TFM, B-Scan, FMC, NDT, Ultrasound, cGAN, Corrosion

2.2 Introduction

Corrosion is one of the most critical degradation mechanisms affecting the structural integrity of metallic components across industries such as aerospace, petrochemical, and energy production. Accurate measurement of corrosion profiles is essential to assess residual thickness, ensure safe operation, and guide maintenance decisions. Ultrasonic Nondestructive Testing (NDT) is widely employed for this purpose, as it enables in-situ inspection without requiring destructive sampling (Krautkrämer & Krautkrämer, 2013). While advanced techniques like Full Matrix Capture (FMC) combined with the Total Focusing Method (TFM) provide high-resolution imaging and superior flaw detection, their adoption is limited by slow acquisition speeds and availability only on high-end instruments. In contrast, B-Scans remain the most widely used method in industry due to their simplicity and integration into most phased-array controllers. (Luijten *et al.*, 2020; van Sloun, Cohen & Eldar, 2020).

Despite their widespread use, FMC/TFM and B-Scan (Wilcox, 2013; Chiao & Thomas, 1994) approaches face limitations in generating accurate representations of the geometry of defect (Liu, Chen, Zhu, Liu & He, 2025). While these methods effectively reveal the presence of corrosion or discontinuities, the interpretation of the resulting images largely depends on human expertise, introducing variability and potential errors, particularly for complex or ambiguous defects. Furthermore, the lower resolution of standard B-Scans can reduce the fidelity of defect visualization, motivating the exploration of Artificial Intelligence (AI) reconstruction techniques.

In addition to these approaches, a conventional technique based on the maximum pixel intensity is often used to extract corrosion profiles from ultrasonic images. For each column of a TFM or B-Scan image, the pixel with the highest amplitude is identified and used to estimate the backwall position. This simple method provides a direct estimation of the specimen thickness

but remains highly sensitive to noise and signal fluctuations. In this work, it is used as a baseline for comparison with the proposed AI-based reconstruction approach.

Recent developments (Litjens *et al.*, 2017; Li, Huo, Li, Wang & Feng, 2021; Denton, Chintala, Szlam & Fergus, 2015) offer promising solutions to these challenges. Deep learning, and in particular Generative Adversarial Networks (GANs) (Goodfellow *et al.*, 2020; Radford, Metz & Chintala, 2016; Salimans *et al.*, 2016) have demonstrated significant potential in image generation and reconstruction. Conditional GANs (cGANs) (Mirza & Osindero, 2014; Molinier *et al.*, 2023; Gauthier, 2014; Isola *et al.*, 2017) extend this capability by generating outputs conditioned on input data, making them suitable for translating ultrasonic images, including both TFM and various B-Scan modalities, into interpretable representations of defect profiles.

In this work, a cGAN framework is proposed to reconstruct detailed 2D schematics of corroded test pieces from ultrasonic images. The model is trained primarily on simulated corrosion profiles, allowing it to capture a wide variety of defect scenarios and generalize to experimental data. By accurately reconstructing both the front and back walls of the specimens, the approach enables precise dimensional assessment and visualization of corrosion patterns. Unlike conventional methods, the AI-driven technique reduces reliance on manual interpretation and improves the consistency and reliability of ultrasonic inspections.

The contributions of this study include the development of a realistic simulation pipeline for training data that incorporates corrosion patterns, noise modeling, and multiple imaging modalities such as TFM and B-scans. It also involves the implementation of a conditional GAN architecture designed to reconstruct corrosion profiles from ultrasonic images. Furthermore, the study evaluates how input modality and dataset composition influence reconstruction performance and demonstrates the effectiveness of transfer learning in improving results on experimental data.

This framework provides a pathway for enhancing the capabilities of ultrasonic NDT, potentially extending to other defect types and complex geometries in future work.

Section 2 describes the methodology, including data simulation, experimental acquisition, and the proposed cGAN architecture. Section 3 presents the results along with the metrics used to evaluate model performance. Section 4 discusses the findings, limitations, and implications for industrial applications. Finally, Section 5 concludes the paper and outlines directions for future work.

2.3 Materials and Methods

In this section, the construction of ultrasonic images from simulated data is first described, along with the key parameters that enhance the similarity between simulated and experimental measurements. The methodology used to generate experimental images is then outlined to ensure a representative dataset for training. The operational principles, architecture, and parameterization of the conditional GAN (cGAN) are subsequently detailed. Finally, the evaluation metrics employed are presented, and the datasets to which they are applied are specified.

2.3.1 Simulation of Ultrasonic Data for Corrosion Profiling

To construct a reliable dataset suitable for AI processing, particular attention was paid to the accuracy and consistency of the simulated data. A more complete and coherent dataset directly translated into more reliable AI performance when applied to experimental data.

2.3.1.1 Material Parameters

The Pogo GPU-accelerated Finite Element (FE) (Huthwaite, 2014) solver was used to simulate corroded blocks. Each block had a width of 50 mm and a thickness varying between 37 mm and 39 mm, discretized using 20 elements per wavelength to ensure the shortest wavelength was accurately modeled. The finite element (FE) method was well-suited for accurately modeling complex wave interactions in components with irregular geometries, such as corroded steel surfaces, and was therefore employed to simulate wave propagation in the corroded blocks.

The wave propagation velocity was computed based on the mechanical properties of 1018 steel, characterized by a Young's modulus $E = 200$ GPa, a density $\rho = 7870$ kg/m³, and a Poisson's ratio $\nu = 0.29$. These parameters yielded a longitudinal wave velocity of $V_l = 5771$ m/s.

2.3.1.2 Generation of the Input Signal

The input signal was carefully designed, as it significantly impacted the amplitude variations of the wave propagating through the material during the simulation. The goal was to reproduce an emission as close as possible to the one generated during the experimental acquisitions performed with a Verasonics Vantage 64 LE system and an Evident 5 MHz phased array transducer (5L64-32X10-A32-P-2.5-OM).

To this end, the Nakagami model (Lian *et al.*, 2019; Li, Chen, Zhang, Zhao & Liu, 2023) defined the temporal waveform of the emitted pulse, whose amplitude followed a Nakagami distribution. In other words, the pulse itself acted as an envelope modulating a sinusoidal carrier. The corresponding analytical expression was given by :

$$f(t) = A \cdot \frac{2m^m}{\Omega^{2m}\Gamma(m)} \cdot (t - \tau)^{2m-1} \cdot \exp\left(-\frac{m}{\Omega^2}(t - \tau)^2\right) \cdot \cos(2\pi f(t - \tau) + \phi), \quad (2.1)$$

where the parameters $[A; m; \Omega; \tau]$ were set to $[1; 2.8; 8.4 \times 10^{-7}; 1.6 \times 10^{-7}]$.

Figure 2.1 illustrates the comparison between the simulated input signal generated using this model and an experimentally acquired signal.




Figure 2.1 Comparison between the simulated input and the experimental input

2.3.1.3 Generation of Corrosion Profiles

To simulate realistic corrosion patterns, two parameters were defined : the corrosion amplitude σ and the correlation length λ , which were randomly sampled within the ranges $[0.2, 0.8]$ mm and $[0.3, 1.1]$ mm, respectively. These ranges were chosen to reflect realistic variations observed in experimental data.

A normally distributed random vector with a standard deviation σ was generated, matching the number of spatial points along the simulated corrosion profile. A Gaussian filter was applied in the Fourier domain, defined as :

$$H(k) = \exp \left[-\frac{1}{2} \left(\frac{k - \frac{2\pi}{L\lambda}}{\sigma} \right)^2 \right], \quad (2.2)$$

where k was the spatial frequency, σ was the corrosion amplitude, λ was the correlation length, and L was the total length of the corrosion profile. This filter was applied to the FFT of the

random vector, and the inverse FFT of the product was then computed and normalized (Cantero-Chinchilla, Simpson, Ballisat, Croxford & Wilcox, 2023). Figure 2.2 illustrated the different steps involved in the generation of a corrosion profile. Several examples of resulting corrosion profiles, obtained for different combinations of σ and λ , were shown in Figure 2.3.




Figure 2.2 Steps involved in corrosion profile generation




Figure 2.3 Different corrosion profiles generated for varying corrosion amplitude σ and correlation length λ

2.3.1.4 Incorporating noise into simulated data

Noise was introduced for two primary purposes : to mimic real-world measurement conditions, since even filtered experimental signals were never completely noise-free, and to improve the model's ability to generalize by reducing overfitting. Without this variability, the dataset might have become too uniform, causing the model to memorize patterns rather than learn meaningful features.(Uhlig, Alkhasli, Schubert, Tschöpe & Wolff, 2023).

Specifically, normally distributed noise was added with a standard deviation randomly selected between 2% and 20% of the maximum signal amplitude, corresponding to a SNR ranging from 19.37 dB to 39.31 dB. Afterwards, a band-pass filter centered at 5 MHz (matching the probe's bandwidth) was applied, considering the 62.5 MHz sampling frequency (Cantero-Chinchilla *et al.*, 2023).

Incorporating noise in the simulation results in simulated FMC data ready for ultrasonic imaging, as illustrated in Figure 2.4.




Figure 2.4 Simulated ultrasonic signal showing simulated signal, noise distribution, filtered noise, and final noisy signal


2.3.2 Generation of Experimental Data

The previous section introduced the simulated data, which was carefully designed to closely match real-world conditions. In parallel, special attention was given to the generation of experimental data, which played a key role in validating the AI model, improving its accuracy, and, in some cases, contributing to its training via transfer learning.


To achieve this, a 3D corrosion profile, generated as described before, was created (Figure 2.5a). In order to increase the variability of corrosion profiles, the 3D shape was divided into sections, with each section assigned its own values of λ and σ (Figure 2.5b). This corrosion profile was then machined onto a 1018 steel block with an initial thickness of 38 mm (Figure 2.5c). The profile was subsequently adjusted to match the machining precision, which was limited to 0.8 mm (1/32”).

To ensure high positional accuracy of the ultrasonic probe over the surface of the machined piece, a robotic arm was employed and motion control was managed through the software *RoboDK*, (RoboDK software, Version 5.6, 2025. [Online]. Available : <https://robodk.com>), (Figure 2.5d). The system’s positioning error was approximately 1 mm. Using this methodology, a total of 321 experimental samples were acquired.

The ultrasonic data acquisition was carried out using a 5 MHz phased-array probe (Olympus 5L64-32X10-A32-P-2.5-OM) in combination with a Verasonics Vantage 64 LE system, operating at a sampling frequency of 62.5 MHz.




a)



b)



c)



d)

Figure 2.5 Experimental dataset generation process showing (a) simulated corrosion profile, (b) distribution of corrosion generation parameters along the part, (c) machined profile on a 1018 steel block, and (d) ultrasonic probe positioning using a robotic arm

2.3.3 Ultrasonic Imaging Parameters

2.3.3.1 B-Scan

The B-Scan is one of the most basic ultrasonic imaging techniques. The simplest B-Scan is obtained by displaying all A-Scans along the diagonal of the Full Matrix Capture (FMC), that is, all transmitter/receiver pairs (i, i) , with i ranging from 1 to the total number of elements in the array. This basic B-Scan visualizes only the amplitude variations of the ultrasonic waves during their propagation through the specimen.

In addition to this form, alternative types of B-Scans were also considered. By summing adjacent A-Scans around the diagonal of the FMC matrix, enhanced B-Scans were constructed. In the present work, two additional configurations were examined : the first employs a sliding window that sums the four nearest A-Scans around the diagonal, while the second used a window of eight A-Scans. These variants were designed to improve the visualization of wave propagation and to provide a more detailed representation of the internal structure of the inspected component.

2.3.3.2 TFM

The Total Focusing Method (TFM) is a more advanced ultrasonic imaging technique. This technique reconstructs an image by summing the signal amplitudes obtained from a Full Matrix Capture (FMC). The FMC is acquired using an ultrasonic probe comprising N elements, each capable of independently transmitting and receiving ultrasonic signals.

In this process, a single element transmits a signal while all N elements receive it, producing N one-dimensional signals. This procedure is repeated for each transmitting element, ultimately forming an N^2 matrix, which constitutes the FMC.




Figure 2.6 Illustration of the TFM creation process

The TFM processes the FMC through the Delay and Sum (DAS) beamforming algorithm described in Equation 2.3. When element k transmits a signal and element j receives it, the signal I_{kj} represents the amplitude variation of the analytic signal (Holmes, Drinkwater & Wilcox, 2005, 2004). The final image is obtained by summing the amplitude contributions at each pixel $I_{\text{pixel}}(x, y)$ from all N^2 signal paths, as depicted in Figure 2.6. The time-of-flight for each wave path is computed using the following equation :

$$I_{\text{pixel}}(x, y) = \left| \sum_{k=1}^N \sum_{j=1}^N I_{kj}(t_{kj}(x, y)) \right|, \quad (2.3)$$

where $t_{kj}(x, y)$ represents the wave travel time from the transmitting element to the pixel location via the receiving element.

This approach allows TFM to achieve high-resolution imaging by precisely accounting for ultrasonic wave propagation times, enabling accurate field-of-view reconstruction.

Furthermore, understanding the dimensions of the generated images was crucial for interpreting the specimen's thickness and corrosion profile variations. The simulated images were 256×256

pixels, representing a width equal to the probe's aperture (32 mm in this case) and a height of 51 mm to capture both the front and back walls effectively.

All these parameters were used to generate thousands of images that closely resemble real-world conditions.




Figure 2.7 Example of ultrasonic imaging techniques

2.3.3.3 Maximum Intensity Method for Corrosion Profiling

The corrosion profile is typically obtained from ultrasonic images such as those previously presented. One of the imaging techniques (TFM or B-Scan) is employed, and the analysis consists in identifying, for each image column, the pixel corresponding to the strongest ultrasonic response. This is achieved by computing the argument of the maximum pixel intensity within each column, that is, the index of the pixel exhibiting the highest amplitude. By repeating this operation across all horizontal positions, a set of vertical coordinates is obtained. When assembled side by side, these points form the corrosion profile, which directly represents the thickness distribution of the specimen. This method is labeled as conventional in the results.

2.3.4 Architecture

The objective of a conditional Generative Adversarial Network (cGAN) is to generate an output image y from an input image x and, optionally, a random noise vector z , effectively reconstructing y based on x (Isola *et al.*, 2017). A cGAN is composed of two main components :

Generator : A neural network designed to produce realistic output images that closely resemble the target data distribution.

Discriminator : A neural network that attempts to distinguish whether a given image is real (i.e., from the dataset) or generated by the generator.

These two networks are trained simultaneously in an adversarial fashion : the generator learns to produce increasingly realistic images in order to fool the discriminator, while the discriminator learns to improve its accuracy in differentiating real from generated samples.

The following sections describe the internal structure and roles of both networks in more detail.

2.3.4.1 Generator

The generator is the central component of the cGAN. In this work, it takes an ultrasonic image as input and outputs a schematic representation of the test piece, including both its thickness and the detailed corrosion profile. Since the generator produces the final output, only its weights are retained after training, enabling inference on unseen or experimental data, even if the training is performed solely on simulated images.

The architecture of the generator is based on the U-Net model (Ronneberger, Fischer & Brox, 2015), which is known for its U-shaped encoder-decoder structure and has proven effective in image-to-image translation tasks.

Encoding path : This stage captures high-level features from the input using repeated convolutional blocks, each composed of convolutional layers, batch normalization, and LeakyReLU activation functions.

Decoding path : This stage reconstructs the output image through transposed convolutions, batch normalization, and ReLU activations. To mitigate overfitting, dropout layers are added in the initial decoding blocks. The final layer uses a hyperbolic tangent (Tanh) activation function to constrain the output values between -1 and 1 (Isola *et al.*, 2017).

An illustration of the generator architecture is provided in Figure 2.8.




Figure 2.8 Model of the Generator Molinier *et al.* (2023)

2.3.4.2 Discriminator

Compared to the generator, the discriminator has a simpler architecture. It consists of a series of convolutional blocks, each comprising a convolutional layer, batch normalization, and a LeakyReLU activation function (Radford *et al.*, 2016). Its purpose is to determine whether the input image pair (x, y) is real (from the dataset) or fake (generated).

The discriminator's output can be interpreted in two ways : (1) If it correctly identifies an image as real or fake, it may indicate that the discriminator is sufficiently powerful to distinguish between real and generated samples. (2) If it misclassifies a generated image as real, it suggests that the generator has succeeded in producing a highly realistic output—capable of "fooling" the discriminator.

This second case is particularly desirable. Indeed, if the discriminator achieves a high classification accuracy and the generator is still able to deceive it, this indicates that the generator produces

outputs that are nearly indistinguishable from real data, hence demonstrating the effectiveness of the model.

An illustration of the generator architecture is provided in Figure 2.9.




Figure 2.9 Model of the Discriminator

2.3.4.3 Training parameters

Loss functions

The training process of conditional GANs is highly sensitive to the choice of loss functions and optimization parameters. These factors directly influence the convergence behavior and final performance of the model.

One of the most critical components is the definition of the loss function. In conditional GANs, the standard objective includes an adversarial loss (also called conditional adversarial loss), which is equivalent to a binary cross-entropy (BCE) loss, and encourages the generator to produce outputs indistinguishable from real images. This loss is formulated as follows (Isola *et al.*, 2017) :

$$\mathcal{L}_{\text{adv}}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_x[\log(1 - D(x, G(x)))] \quad (2.4)$$

where $G(x)$ denotes the image generated by the generator given input x , and $D(x, y')$ outputs the probability that image y' is real given input x . Specifically, $D(x, y)$ is the discriminator's output for the real image y , and $D(x, G(x))$ is the output for the generated image. This loss enables the model to capture high-frequency structural information but often leads to mode collapse or blurry results if used in isolation.

To mitigate these limitations and improve fidelity, the adversarial loss is commonly combined with a pixel-wise reconstruction loss. In the present work, the L1 loss is employed to encourage the generated image to be close to the ground truth in terms of absolute pixel intensity differences (Abu-Srhan, Abushariah & Al-Kadi, 2022; Ma *et al.*, 2020).

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{x,y}[\|y - G(x)\|_1] \quad (2.5)$$

The combination of these two loss functions forms the total objective function.

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{adv}} + \delta \cdot \mathcal{L}_{L1} \quad (2.6)$$

The hyperparameter δ balances the importance of the adversarial term against the reconstruction loss. In this work, $\delta = 300$ was found to yield better results.

Learning Rate Scheduling

Another critical training hyperparameter is the learning rate. In our implementation, the Adam optimizer (Kingma & Ba, 2017) was used with an initial learning rate of 1×10^{-3} , consistent with values commonly adopted in image-to-image translation tasks (Isola *et al.*, 2017). The momentum parameters were set to $\beta_1 = 0.5$ and $\beta_2 = 0.999$, as recommended in the original Pix2Pix framework.

To facilitate stable convergence and avoid premature saturation of the loss landscape, a scheduled decay strategy was employed. Specifically, every eight epochs, the current learning rate was multiplied by a decay factor of 0.92. This exponential decay scheme progressively reduces the step size during training, allowing large updates during the early stages and finer adjustments in the later epochs. Such a scheduling policy is designed to maintain a balance between exploration and convergence, ultimately contributing to improved model generalization and training stability.

Software and Hardware

The training and implementation of the model were carried out using Python 3.11 and the PyTorch deep learning framework. All experiments were executed on a workstation equipped with an NVIDIA™ Quadro P6000 Graphics Processing Unit (GPU), which provided the computational resources necessary for efficient model training and inference.

Training Methodologies

To optimize the performance of the proposed artificial intelligence model, several training methodologies were investigated, relying on different combinations of simulated and experimental datasets (Table 2.1). Each configuration was designed to assess specific learning strategies, including purely simulated training, mixed training, and transfer learning. For the simulated-only strategy, the maximum number of training samples was systematically varied to determine the most relevant dataset size. Subsets corresponding to 10%, 20%, 40%, 55%, 60%, 65%, 80%, and 100% of the full database (1,700 images) were employed. Transfer learning was performed by pre-training the model on the entire simulated dataset, followed by fine-tuning with experimental data. In addition, to provide a direct comparison with transfer learning, a mixed training strategy was also tested, where simulated and experimental data were jointly used during training rather than sequentially.

Tableau 2.1 Summary of the different datasets used in each configuration

Model Configuration	Training		Validation	
	Simulated	Experimental	Simulated	Experimental
#1 Simulated Only 10%	170	0	300	327
#2 Simulated Only 20%	340	0	300	327
#3 Simulated Only 40%	680	0	300	327
#4 Simulated Only 55%	935	0	300	327
#5 Simulated Only 60%	1020	0	300	327
#6 Simulated Only 65%	1105	0	300	327
#7 Simulated Only 80%	1360	0	300	327
#8 Simulated Only 100%	1700	0	300	327
#9 Mixed training	1700	280	300	50
#10 Transfer Learning (pre-trained on model 8)	1700*	280	0	50

* 1700 simulated samples were used for pre-training ; experimental data training began after model #8

2.3.4.4 Performance Metrics

To assess the effectiveness and consistency of the learning process, several quantitative metrics were employed. These metrics evaluate both the overall similarity between images and the accuracy of the corrosion profile reconstruction.

Structural Similarity Index (SSIM)

The SSIM metric (Wang, Bovik, Sheikh & Simoncelli, 2004) is widely used to measure the perceptual similarity between two images. It considers luminance, contrast, and structural information, providing a value between -1 and 1 , where 1 indicates perfect similarity. It is defined as :

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2.7)$$

where μ_x and μ_y are the local means, σ_x^2 and σ_y^2 the variances, and σ_{xy} the covariance of the two images. C_1 and C_2 are stability constants.

Mean Squared Error (MSE)

To evaluate the vertical alignment of the corrosion profile, corresponding to the specimen thickness, the Mean Squared Error (MSE) between the predicted and ground truth profiles was employed. It provides a direct measurement of the AI's ability to reconstruct the thickness distribution of the specimen. This aspect is particularly critical, as a sufficiently accurate model could enable the estimation of a component's minimum thickness directly from the image, thereby eliminating the need for additional post-processing or computational steps.

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.8)$$

where y_i and $\hat{y}_i$ denote the true and predicted vertical coordinates at index i , and N represents the total number of evaluated points.

Pearson Correlation Coefficient

The correlation coefficient measures the linear relationship between the predicted and expected profiles, independently of their absolute values.

$$\rho = \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (2.9)$$

A correlation close to 1 indicates a strong agreement in the overall shape, while values closer to 0 or -1 reflect poor alignment.

Hausdorff Distance

The Hausdorff distance (Huttenlocher, Klanderman & Rucklidge, 1993) is employed to assess the geometric similarity between two point sets by considering both vertical and horizontal deviations. It is defined as

$$d_H(X, Y) = \max \left\{ \sup_{x \in X} \inf_{y \in Y} \|x - y\|, \sup_{y \in Y} \inf_{x \in X} \|y - x\| \right\} \quad (2.10)$$

where X and Y represent the points sets corresponding to the predicted and reference profiles, respectively. A smaller Hausdorff distance indicates a closer geometric agreement, whereas larger values typically arise from missing or misaligned regions in the reconstructed profile.

Together with the MSE, this metric is among the most relevant since it directly quantifies whether the reconstructed profile is positioned consistently and without excessive artifacts. Even if the global shape is not perfectly captured, the primary objective is to achieve a stable profile located at the correct position.




Figure 2.10 Visual examples of predicted vs. ground truth corrosion profiles to illustrate the different evaluation metrics : (a) low MSE, (b) high correlation with offset, (c) shape mismatch (low correlation), and (d) missing region (Hausdorff distance)

2.4 Results

This section presents the performance of the proposed model on the experimental validation dataset under different training configurations. The reported values correspond to the best checkpoints saved during training. Since the learning curves were stable and convergent, the difference between the best and last epochs was negligible. The main evaluation metrics are illustrated in Figures 2.11–2.15, which summarize the mean performance and standard deviation across dataset configurations for the Hausdorff distance, the mean squared error (MSE), the Pearson correlation, and the structural similarity index (SSIM), respectively.




Figure 2.11 Hausdorff distance results across dataset configurations




Figure 2.12 Mean squared error (MSE) results across dataset configurations




Figure 2.13 Pearson correlation results across dataset configurations




Figure 2.14 Structural similarity index (SSIM) results across dataset configurations




Figure 2.15 Structural similarity index (SSIM) of the backwall across different dataset configurations

In addition, to facilitate the interpretation of the results, Figures 2.16 and 2.17 present the best and worst images obtained by the model, respectively. These examples were generated using the best training configuration with simulated data only (dataset #8, trained with 100% simulated data). Figures 2.18 and 2.19 further illustrate the best and worst cases obtained after transfer learning, highlighting the improvement in reconstruction quality when experimental data were included.




Figure 2.16 Best correlation results for dataset #8 (100% simulated data). Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green




Figure 2.17 Worst correlation results for dataset #8 (100% simulated data). Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green




Figure 2.18 Best correlation results for dataset #10 after transfer learning. Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green




Figure 2.19 Worst correlation results for dataset #10 after transfer learning. Sequence illustrates : 1 model input, 2 superposition of the expected image in red, the AI-generated image in blue, and the conventional method image in green, 3 zoomed view showing the corrosion profiles : expected profile in red, reconstructed profile in blue, and conventional profile in green

2.5 Discussion

This section provides an analysis and interpretation of the obtained results. As highlighted in the previous sections, the acquisition system introduces a positioning error of approximately ± 1 mm. While such a deviation may be considered negligible from a technical perspective, in this context it can lead to horizontal or vertical offsets that significantly affect both the learning process and the final analysis. A horizontal offset, for instance, increases the Mean Squared Error (MSE) since the curves are no longer perfectly aligned. The same applies to the Hausdorff distance and the correlation coefficient, which are both highly sensitive to such misalignments. In contrast, the Structural Similarity Index (SSIM) is less impacted by a few-pixel displacement, and therefore maintains a higher degree of robustness under these conditions.

Another important point to address, which has not yet been discussed, concerns the dimensionality of the simulated data. The synthetic dataset was generated in 2D to reduce computational time during database construction. However, when performing Full Matrix Capture (FMC) measurements on real test blocks, true 2D acquisitions are not feasible. To mitigate this discrepancy, the corrosion profiles were averaged over half the transducer aperture. This strategy offers two main benefits : first, it allows the experimental acquisitions to better approximate the 2D simulated dataset ; and second, it reduces the impact of potential lateral offsets caused by the positioning uncertainty of the robotic system.

Hausdorff Distance

The comparative analysis of the Hausdorff distance results, presented in Fig. 2.11, highlights clear differences in precision and learning stability among the four imaging modalities. Although all techniques tended to converge to a similar value as the amount of simulated training data increases, the B-Scan proves to be the most challenging for the network to learn from, while the TFM consistently maintained a low Hausdorff distance. This indicates that the network was able to correctly reconstruct continuous profiles in the proper location even when trained with a limited number of samples. Conversely, with B-Scans, the smaller the acquisition window, the

slower the model converged, reflecting the lack of information in each image and the increased difficulty for the network to infer the correct profile.

Nevertheless, after approximately 55% of the total dataset was used, the network achieved similar results regardless of the imaging technique. Interestingly, the hybrid approach (combining simulated and experimental data) yields lower performance compared to training solely on simulated data. Finally, while the improvement was not as pronounced for this metric, transfer learning consistently achieved the best results. This advantage becomes much more evident when considering the other evaluation metrics.

The Mean Squared Error (MSE)

The MSE is used to quantify the vertical alignment between the predicted and reference corrosion profiles, providing a direct measure of the model's accuracy in estimating the specimen thickness.

Many of the observations reported in the previous section remain valid here. In particular, TFM continued to demonstrate the best performance compared to B-Scans, which show slower convergence toward stable results. However, unlike the previous analysis, the imaging techniques did not all converge to the same solution beyond 55%. Instead, each imaging method exhibits an individual convergence behavior, with TFM consistently providing the most accurate results across B-scans generated with window sizes of 8, 4, and 1. This again highlights the influence of the window size in B-Scan construction, as larger windows provide a more reliable interpretation.

In this case, combining simulated and experimental data had only a limited effect. TFM and B-Scans with window sizes of 8 and 4 achieved the best overall results. The most significant observation arose from transfer learning : in this scenario, all imaging techniques converged toward a similar value, outperforming any training conducted solely on simulated data. This suggested that the achievable precision limit of the proposed model was approximately 0.02 mm in estimating the specimen thickness.

To provide a baseline, the conventional method was also evaluated under identical conditions. In comparison, the simple maximum-intensity image analysis yielded MSE values of 0.930 mm, 2.548 mm, 2.852 mm, and 3.138 mm for the TFM and B-Scan images with window sizes of 1, 4, and 8, respectively, substantially higher than the 0.02 mm obtained with the AI-based model. These results are illustrated in Fig. 2.12.

The Pearson Correlation

The Pearson correlation provides complementary insights compared to the previous metrics, although it allows for fewer detailed conclusions. The relative ranking of the different ultrasonic imaging techniques was still observable, but the differences were less pronounced, and the metric was not reliable for B-Scans with window sizes of 4 and 8. In practice, TFM reconstructions demonstrated higher correlation and more faithful corrosion profiles, whereas B-Scan-based methods generally failed to reach the same level of accuracy.

As with MSE, combining simulated and experimental data resulted in a reduction in overall performance, whereas transfer learning once again provided the best results. Interestingly, for B-Scans with window sizes of 4 and 8, transfer learning yielded convergence toward a similar value, while the window size of 1 performed significantly worse. This highlights the importance of defining an appropriate window size in B-Scan construction to maximize the amount of information available for accurate reconstruction.

Furthermore, the maximum-intensity method could not achieve a similarly accurate reconstruction of corrosion profiles.

The Structural Similarity Index (SSIM)

The SSIM is the last metric considered, but it provided the least informative insights. As can be observed in Figures 2.16–2.19, most results were predominantly white, leading to consistently high SSIM values. Nevertheless, certain configurations exhibited noticeable drops, which were mainly associated with the presence of significant noise in the reconstructed images, as illustrated

in Figure 2.16c. Importantly, this noise did not affect the estimation of thickness or the overall corrosion profile, as confirmed by previous analyses, but it does reduce the visual readability of the images.

In this case, the combination of simulated and experimental data had a noticeable impact, particularly in reducing the noise observed in B-Scan reconstructions, which were generally more sensitive to noise than TFM. As observed with other metrics, transfer learning again enabled convergence of all imaging techniques toward a common value, consistently outperforming training on simulated data alone.

Figure 2.15 presents the evolution of the SSIM computed only in the region surrounding the corrosion profile, allowing for a localized evaluation rather than one over the entire image. The first observation was that the focused SSIM values were lower than those computed on the whole image, which was expected given that most of the image area was white. However, the second key observation was that the variation trend of the focused SSIM differs from that of the global SSIM, highlighting the influence of local noise in the reconstruction. Despite these differences, transfer learning once again drove all imaging methods to converge toward a similar value.

Overall Analysis

The analysis of all four metrics confirms that, as expected, TFM represented the most sophisticated and accurate ultrasonic imaging technique, consistently yielding superior results compared to the other methods. The simplest B-Scan was the most challenging for AI to analyze and converged toward reliable results, although its fast acquisition partially compensates for this limitation.

Furthermore, only 1,000 simulated data samples were sufficient to obtain reasonably accurate results. By adding 280 experimental images and applying transfer learning, the best performance was achieved. The resulting model was sufficiently precise to reconstruct both the corrosion profile and the specimen thickness with minimal noise, demonstrating the capability of the AI to deliver high-fidelity reconstructions.

Beyond these observations, both the MSE and correlation metrics showed substantial improvement compared to traditional maximum-intensity–based estimation methods, further validating the effectiveness and robustness of the proposed approach. The Hausdorff distance, however, was less impacted by the use of AI, as the maximum-intensity method naturally maintains spatial consistency along the horizontal direction, an aspect that the AI model did not always preserve. Nevertheless, when trained with an adequate number of simulated and experimental samples, the proposed approach still achieves superior overall performance compared to conventional techniques.

2.6 Conclusion

This study introduces a robust AI-driven framework for reconstructing corrosion profiles from ultrasonic data using conditional GANs trained on both simulated and experimental datasets. By integrating realistic simulation, precise experimental acquisition, and advanced deep learning techniques, the proposed approach overcomes key limitations of traditional ultrasonic imaging, reducing reliance on manual interpretation and improving consistency. Quantitative evaluations confirm that TFM inputs delivered the highest reconstruction fidelity, while transfer learning significantly enhanced performance across all imaging modalities, including lower-resolution B-Scans. These findings highlight the potential of combining physics-based modeling with AI to achieve accurate, automated corrosion assessment. Beyond corrosion mapping, this methodology opens the door to broader applications in nondestructive testing and structural health monitoring, paving the way for faster, more reliable, and cost-effective industrial inspections. Furthermore, a comparison with the traditional maximum-intensity approach confirms that the proposed AI-based reconstruction achieves significantly higher accuracy, particularly for TFM inputs. This comparison, combined with the observed differences between TFM and B-Scan modalities, provides valuable insights into the respective strengths of conventional and AI-driven ultrasonic imaging.

Future work will focus on extending the proposed framework to more complex inspection scenarios, such as the inspection of welds using angled wedges and other challenging geometries.

These cases introduce additional complexities in wave propagation and signal interpretation, requiring adaptations in both simulation fidelity and model architecture. Addressing these challenges will further demonstrate the versatility of AI-driven ultrasonic imaging for diverse industrial applications.

CONCLUSION ET RECOMMANDATIONS

Ce mémoire s'est intéressé à la reconstruction des profils de corrosion à partir d'images ultrasonores, un enjeu crucial pour l'évaluation de l'intégrité des composants métalliques dans des secteurs industriels variés. La corrosion, en affectant l'épaisseur et la structure des pièces, nécessite des méthodes de mesure précises pour garantir la sécurité des opérations et orienter les décisions de maintenance. Les techniques classiques de contrôle non destructif par ultrasons, telles que les B-Scans et les images TFM générées à partir de FMC, permettent d'inspecter les matériaux sans les endommager. Cependant, leur capacité à reconstruire fidèlement la géométrie des défauts reste limitée par la résolution des images et la dépendance à l'expertise humaine, tandis que la méthode conventionnelle d'intensité maximale des pixels, bien qu'utilisée pour estimer l'épaisseur des pièces, est sensible au bruit et aux fluctuations du signal.

Ce travail a proposé une approche basée sur les réseaux antagonistes génératifs conditionnels (cGANs), intégrant un générateur de type U-Net et un discriminateur convolutif, capable de traduire les images ultrasonores en représentations schématiques détaillées des surfaces avant et arrière des échantillons corrodés. L'entraînement sur des données simulées variées a permis au modèle de généraliser efficacement aux images expérimentales, tandis que l'utilisation des métriques MSE, SSIM, corrélation de Pearson et distance de Hausdorff a confirmé que la reconstruction par cGAN surpasse la méthode classique d'intensité maximale, tant en précision qu'en fidélité. Les résultats ont également montré que les images TFM offrent une meilleure qualité de reconstruction, et que le transfert d'apprentissage améliore les performances sur les images B-Scan de résolution inférieure.

Ce mémoire met ainsi en évidence le potentiel des méthodes d'IA pour réduire la dépendance à l'interprétation humaine, améliorer la cohérence des inspections et fournir des profils de corrosion fiables et détaillés. Pour aller plus loin, il serait intéressant d'explorer des modèles de diffusion, qui ont récemment montré des performances remarquables en génération d'images

et pourraient offrir une reconstruction encore plus précise et robuste. De plus, l'approche développée pourrait être étendue à d'autres types de défauts internes, tels que fissures, inclusions ou délaminations, élargissant ainsi le champ d'application de l'IA dans le contrôle non destructif.

En résumé, ce mémoire démontre que l'utilisation de cGANs pour la reconstruction des profils de corrosion constitue une avancée significative dans le domaine de l'inspection ultrasonore, offrant une combinaison unique de précision, de fiabilité et de généralisabilité, et ouvre la voie à de nouvelles applications de l'intelligence artificielle dans le contrôle non destructif.

BIBLIOGRAPHIE

- Abu-Srhan, A., Abushariah, M. A. & Al-Kadi, O. S. (2022). The effect of loss function on conditional generative adversarial networks. *Journal of King Saud University - Computer and Information Sciences*, 34(9), 6977–6988. doi : 10.1016/j.jksuci.2022.02.018.
- Agarap, A. F. [arXiv :1803.08375 [cs]]. (2019). Deep Learning using Rectified Linear Units (ReLU). arXiv. Repéré le 2025-06-10 à <http://arxiv.org/abs/1803.08375>.
- Cantero-Chinchilla, S., Simpson, C. A., Ballisat, A., Croxford, A. J. & Wilcox, P. D. (2023). Convolutional neural networks for ultrasound corrosion profile time series regression. *NDT & E International*, 133, 102756. doi : 10.1016/j.ndteint.2022.102756.
- Cheeke, J. D. N. & Cheeke, J. D. N. (2002). *Fundamentals and Applications of Ultrasonic Waves*. Boca Raton : CRC Press. doi : 10.1201/9781420042139.
- Chiao, R. & Thomas, L. (1994). Analytic evaluation of sampled aperture ultrasonic imaging techniques for NDE. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 41(4), 484–493. doi : 10.1109/58.294109.
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B. & Bharath, A. A. (2018). Generative Adversarial Networks : An Overview. *IEEE Signal Processing Magazine*, 35(1), 53–65. doi : 10.1109/MSP.2017.2765202.
- Denton, E. L., Chintala, S., szlam, a. & Fergus, R. (2015). Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks. *Advances in Neural Information Processing Systems*, 28. Repéré à https://proceedings.neurips.cc/paper_files/paper/2015/hash/aa169b49b583a2b5af89203c2b78c67c-Abstract.html.
- Dubey, A. K. & Jain, V. (2019). Comparative Study of Convolution Neural Network's Relu and Leaky-Relu Activation Functions. *Applications of Computing, Automation and Wireless Systems in Electrical Engineering*, pp. 873–880. doi : 10.1007/978-981-13-6772-4_76.
- Gauthier, J. (2014). Conditional generative adversarial nets for convolutional face generation.
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139–144. doi : 10.1145/3422622.
- Holmes, C., Drinkwater, B. & Wilcox, P. (2004). The post-processing of ultrasonic array data using the total focusing method. *Insight - Non-Destructive Testing and Condition Monitoring*, 46(11), 677–680. doi : 10.1784/insi.46.11.677.52285.

- Holmes, C., Drinkwater, B. W. & Wilcox, P. D. (2005). Post-processing of the full matrix of ultrasonic transmit–receive array data for non-destructive evaluation. *NDT & E International*, 38(8), 701–711. doi : 10.1016/j.ndteint.2005.04.002.
- Huthwaite, P. (2014). Accelerated finite element elastodynamic simulations using the GPU. *Journal of Computational Physics*, 257, 687–707. doi : 10.1016/j.jcp.2013.10.017.
- Huttenlocher, D., Klanderman, G. & Rucklidge, W. (1993). Comparing images using the Hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(9), 850–863. doi : 10.1109/34.232073.
- Ioffe, S. & Szegedy, C. Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift.
- Isola, P., Zhu, J.-Y., Zhou, T. & Efros, A. A. (2017). Image-to-Image Translation with Conditional Adversarial Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 5967–5976. doi : 10.1109/CVPR.2017.632.
- Kingma, D. P. & Ba, J. [arXiv :1412.6980 [cs]]. (2017). Adam : A Method for Stochastic Optimization. arXiv. Repéré le 2025-06-20 à <http://arxiv.org/abs/1412.6980>.
- Krautkrämer, J. & Krautkrämer, H. (2013). *Ultrasonic Testing of Materials*. Springer Science & Business Media.
- Lau, M. M. & Hann Lim, K. (2018). Review of Adaptive Activation Function in Deep Neural Network. *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, pp. 686–690. doi : 10.1109/IECBES.2018.8626714.
- Li, D., Chen, Z., Zhang, Y., Zhao, S. & Liu, W. (2023). Separation of multi-echo overlapping ultrasonic signals for increasing the axial resolution using a neural network. *Measurement Science and Technology*, 34(12), 125009. doi : 10.1088/1361-6501/acefee.
- Li, J., Huo, H., Li, C., Wang, R. & Feng, Q. (2021). AttentionFGAN : Infrared and Visible Image Fusion Using Attention-Based Generative Adversarial Networks. *IEEE Transactions on Multimedia*, 23, 1383–1396. doi : 10.1109/TMM.2020.2997127.
- Lian, M., Liu, H., Bo, Q., Zhang, T., Li, T. & Wang, Y. (2019). An improved matching pursuit method for overlapping echo separation in ultrasonic thickness measurement. *Measurement Science and Technology*, 30(6), 065001. doi : 10.1088/1361-6501/ab03ba.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B. & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. doi : 10.1016/j.media.2017.07.005.

- Liu, Z., Chen, L., Zhu, Y., Liu, X. & He, C. (2025). Multi-mode high resolution TFM imaging of microdefects based on laser ultrasonic full matrix capture. *Optics & Laser Technology*, 181, 111913. doi : 10.1016/j.optlastec.2024.111913.
- Luijten, B., Cohen, R., de Bruijn, F. J., Schmeitz, H. A. W., Mischi, M., Eldar, Y. C. & van Sloun, R. J. G. (2020). Adaptive Ultrasound Beamforming Using Deep Learning. *IEEE Transactions on Medical Imaging*, 39(12), 3967–3978. doi : 10.1109/TMI.2020.3008537. Conference Name : IEEE Transactions on Medical Imaging.
- Ma, Y., Wei, B., Feng, P., He, P., Guo, X. & Wang, G. (2020). Low-Dose CT Image Denoising Using a Generative Adversarial Network With a Hybrid Loss Function for Noise Learning. *IEEE Access*, 8, 67519–67529. doi : 10.1109/ACCESS.2020.2986388.
- Mirza, M. & Osindero, S. [arXiv :1411.1784 [cs]]. (2014). Conditional Generative Adversarial Nets. arXiv. Repéré le 2025-02-10 à <http://arxiv.org/abs/1411.1784>.
- Molinier, N., Painchaud-April, G., Le Duff, A., Toews, M. & Bélanger, P. (2023). Ultrasonic imaging using conditional generative adversarial networks. *Ultrasonics*, 133, 107015. doi : 10.1016/j.ultras.2023.107015.
- Murphy, K. P. (2012). *Machine Learning : A Probabilistic Perspective*. MIT Press.
- Radford, A., Metz, L. & Chintala, S. [arXiv :1511.06434 [cs]]. (2016). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv. Repéré le 2025-10-24 à <http://arxiv.org/abs/1511.06434>.
- Ronneberger, O., Fischer, P. & Brox, T. (2015). U-Net : Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pp. 234–241. doi : 10.1007/978-3-319-24574-4_28.
- Rosenblatt, F. (1958). The perceptron : A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. doi : 10.1037/h0042519. Place : US Publisher : American Psychological Association.
- Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., Chen, X. & Chen, X. (2016). Improved Techniques for Training GANs. *Advances in Neural Information Processing Systems*, 29. Repéré à https://proceedings.neurips.cc/paper_files/paper/2016/hash/8a3363abe792db2d8761d6403605aeb7-Abstract.html.
- Santurkar, S., Tsipras, D., Ilyas, A. & Madry, A. (2018). How Does Batch Normalization Help Optimization? *Advances in Neural Information Processing Systems*, 31. Repéré à https://proceedings.neurips.cc/paper_files/paper/2018/hash/905056c1ac1dad141560467e0a99e1cf-Abstract.html.

- Shull, P. J. (Éd.). (2002). *Nondestructive evaluation : theory, techniques, and applications*. New York Basel : Dekker.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. Dropout : A Simple Way to Prevent Neural Networks from Overfitting.
- Uhlig, S., Alkhasli, I., Schubert, F., Tschöpe, C. & Wolff, M. (2023). A review of synthetic and augmented training data for machine learning in ultrasonic non-destructive evaluation. *Ultrasonics*, 134, 107041. doi : 10.1016/j.ultras.2023.107041.
- van Sloun, R. J. G., Cohen, R. & Eldar, Y. C. (2020). Deep Learning in Ultrasound Imaging. *Proceedings of the IEEE*, 108(1), 11–29. doi : 10.1109/JPROC.2019.2932116. Conference Name : Proceedings of the IEEE.
- Wang, Z., Bovik, A., Sheikh, H. & Simoncelli, E. (2004). Image quality assessment : from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. doi : 10.1109/TIP.2003.819861.
- Wilcox, P. D. (2013). Ultrasonic arrays in NDE : Beyond the B-scan. *AIP Conference Proceedings*, 1511(1), 33–50. doi : 10.1063/1.4789029.
- Xu, B., Wang, N., Chen, T. & Li, M. [arXiv :1505.00853 [cs]]. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network. arXiv. Repéré le 2025-06-10 à <http://arxiv.org/abs/1505.00853>.