



HAL
open science

Développement de stratégies d'apprentissage et de leurs transferts pour le Contrôle de la Santé des Structures

Hadrien Postorino

► **To cite this version:**

Hadrien Postorino. Développement de stratégies d'apprentissage et de leurs transferts pour le Contrôle de la Santé des Structures. Acoustique [physics.class-ph]. HESAM Université; École Nationale Supérieure d'Arts et Métiers, 2022. Français. NNT : 2022HESAE066 . tel-04044791v1

HAL Id: tel-04044791

<https://hal.science/tel-04044791v1>

Submitted on 12 May 2023 (v1), last revised 24 Mar 2023 (v2)

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution 4.0 International License

ÉCOLE DOCTORALE SCIENCES DES MÉTIERS DE L'INGÉNIEUR
Laboratoire PIMM - Campus de Paris

THÈSE

présentée par : **Hadrien POSTORINO**

soutenue le : **5 Décembre 2022**

pour obtenir le grade de : **Docteur d'HESAM Université**

préparée à : **École Nationale Supérieure d'Arts et Métiers**

Spécialité : **Acoustique**

**DÉVELOPPEMENT DE STRATÉGIES
D'APPRENTISSAGE ET DE LEURS TRANSFERTS
POUR LE
CONTRÔLE DE LA SANTÉ DES STRUCTURES**

(Document provisoire)

THÈSE dirigée par :
M. MECHBAL Nazih

et co-encadrée par :
M. RÉBILLAT Marc et M. MONTEIRO Éric

Jury

M. Roger SERRA, Maître de conférence, INSA Val-de-Loire
M. Kamal MEDJAHER, Professeur des Universités, ENI Tarbes
M. Laurent BERTHE, Directeur de Recherche, PIMM, Arts et Métiers
M. Alain LHEMERY, Directeur de Recherche, CEA
M. Nazih MECHBAL, Professeur des Universités, PIMM, Arts et Métiers

Rapporteur
Rapporteur
Examineur
Examineur
Examineur

**T
H
È
S
E**

Remerciement

Je souhaiterais remercier chaleureusement mon directeur de thèse Nazih pour la confiance qu'il m'a accordé lors de ces années passées au PIMM et les grandes orientations qu'il a suggéré pour mes travaux. Je remercie également mes encadrants Marc et Éric pour leur suivi régulier m'ayant permis de progresser d'un point de vu scientifique et technique.

Je remercie les membres du jury pour avoir accepter la lecture de ce manuscrit et la participation à la soutenance.

Je remercie les différents acteurs du projet Monarque avec qui nos échanges réguliers m'ont permis de découvrir la réalisation avec succès d'un projet de R&D ambitieux. Je remercie plus spécifiquement Mathieu et Romain pour avoir fourni les structures nécessaires au travail expérimental et l'équipe laser - notamment Laurent, Yann et Marine - grâce à qui j'ai pu réaliser les campagnes expérimentales en sortant du premier confinement.

Je remercie les doctorants, stagiaires et post-doctorants de la Halle 3 - Nassim, Quentin, Hadrien, Juan, Mattias, Rafael, Florian, Vincent, Christophe, Marc, Arthur, Julie, Erika, Sebastian, Paul, et Thibault - avec qui nous avons pu partager des moments de détente et d'entraide pour faire face aux difficultés et aux doutes rencontrés. Je tiens à remercier plus généralement le PIMM dans son ensemble pour les moments chaleureux et conviviaux que ce laboratoire sait offrir et pour la disponibilité et la gentillesse de ses salariées.

Et surtout, je tiens à remercier ma famille pour son soutien indéfectible durant ces années de thèse et l'ensemble de ma scolarité.

Table des matières

Table des matières	v
Table des figures	vii
Liste des tableaux	ix
Introduction générale	1
1 Contrôle de la Santé des Structures	5
1.1 Les structures aéronautiques actuelles	6
1.1.1 La richesse des matériaux composites	6
1.1.2 Des dommages complexes	8
1.2 Assurer l'intégrité des structures avec les CNDs	9
1.2.1 Une large panoplie de contrôles	9
1.2.2 La Maintenance Préventive	12
1.2.3 La Maintenance Prédictive	13
1.3 Le Structural Health Monitoring	13
1.3.1 Les Structures Intelligentes	13
1.3.2 Panorama des technologies de SHM	14
1.3.3 Le SHM basé sur les ondes de Lamb	17
1.3.4 Verrous du SHM par ondes de Lamb	25
1.4 Un procédé d'endommagement innovant : le projet Monarque	27
1.4.1 Contexte du projet	27
1.4.2 Délaminages induits par des chocs lasers symétriques	28
1.4.3 Applications	30
1.5 Représentation du SHM par un système	31
1.6 Contributions	34
2 Endommagement de structures intelligentes et modélisation numérique	35
2.1 Introduction	36
2.2 Suivi de l'endommagement d'une structure intelligente	36
2.2.1 Description des structures avec leurs transducteurs	36
2.2.2 Mesures sur les structures X11 et X12 à l'état sain	39
2.2.3 Endommagements par des chocs lasers	40
2.2.4 Évaluation des méthodes classiques de SHM sur les dommages réels	41

2.2.5	Discussions sur l'approche expérimentale	43
2.3	Modélisation numérique des structures intelligentes	43
2.3.1	Description de la modélisation par éléments finis	43
2.3.2	Modèle de la Structure X11	46
2.4	Définitions des cas d'études pour les stratégies d'apprentissage	47
2.4.1	Poutre	48
2.4.2	Petite plaque - S2	49
2.4.3	Grande plaque - S11	51
2.4.4	Structure courbe - C	52
2.5	Conclusion	53
3	Approximation du problème direct par des métamodèles	55
3.1	Introduction	56
3.2	Apprentissage supervisé pour le SHM	57
3.2.1	Métamodèles direct et inverse	57
3.2.2	Généralités sur l'apprentissage supervisé	57
3.2.3	Exemples d'utilisations de l'apprentissage supervisé en SHM	58
3.3	Descriptions des méthodes retenues	62
3.3.1	Interpolation par des Fonctions Radiales de base	63
3.3.2	Proper Generalized Decomposition	65
3.3.3	Réseau génératif adverse maximisant l'information	66
3.4	Processus d'approximation du problème direct	74
3.4.1	Échantillonnage de l'espace paramétrique	77
3.4.2	Compression des signaux	78
3.4.3	Pré-traitement des données	83
3.4.4	Entraînement et prédiction du métamodèle	84
3.5	Évaluation des méthodes retenues	84
3.5.1	Évaluation de la RBF	84
3.5.2	Évaluation de la PGD	85
3.5.3	Évaluation des réseaux génératifs	86
3.6	Bilan des évaluations des métamodèles	87
3.7	Conclusion	88
4	Résolution du problème inverse	91
4.1	Introduction	92
4.2	Approche déterministe exploitant les métamodèles	93
4.2.1	Généralités sur la résolution inverse déterministe	93
4.2.2	Détermination d'une fonction de coût spécifique au SHM	94

4.2.3	Minimisation de la fonction de coût	94
4.2.4	Évaluation sur les structures numériques	94
4.3	Résolution inverse à l'aide d'un réseau de neurones convolutifs	98
4.3.1	Choix du CNN	98
4.3.2	Du modèle numérique de S11 aux dommages expérimentaux	98
4.3.3	Architectures proposées	100
4.3.4	Évaluation des CNNs	105
4.3.5	Discussions sur les approches directe et inverse	108
4.4	Conclusion	109
5	Apprentissage par transfert fondé sur la théorie du transport optimal	111
5.1	Introduction	112
5.1.1	Nécessité du transfert pour le SHM	113
5.2	État de l'art de l'apprentissage profond par transfert	115
5.3	Transfert d'apprentissage profond par transport optimal	120
5.3.1	Originalité de l'approche proposée	120
5.3.2	Introduction au transport optimal	122
5.3.3	Algorithme d'apprentissage par transfert profond à l'aide de potentiels de Kantorovich neuronaux	128
5.4	Application au SHM	129
5.4.1	Architecture détaillée du réseau	129
5.4.2	Évaluation des transferts	131
5.4.3	Discussions des évaluations	131
5.5	Conclusion	135
	Conclusion générale	137
	A Annexe A : liste des indicateurs d'endommagement	143
	B Annexe B : évaluations des prédictions des métamodèles directs	145
	C Annexe C : Évaluation des inversions avec des métamodèles	149
	D Annexe D : Évaluation des inversions par des CNNs	151
	Glossaire	153
	Bibliographie	157

Table des figures

1.1	Évolution du pourcentage en masse des matériaux composites dans les avions	6
1.2	Matériau composites avec la matrice et les renforts	7
1.3	Structure en matériaux composites pré-impregnés stratifiés composée d'un empilement de 8 plis	8
1.4	Dommages dans les matériaux composites	8
1.5	Comparaison entre la maintenance préventive et prédictive	13
1.6	Nombre d'articles contenant le mot clef SHM	14
1.7	Structure intelligente équipée d'un ensemble de transducteurs pour réaliser des mesures	17
1.8	Mode symétrique et antisymétrique dans une plaque	18
1.9	Exemple d'une courbe de dispersion des ondes de Lamb dans un matériau composite aéronautique	19
1.10	Structure intelligente équipée d'un réseau de PZTs	19
1.11	Dispositifs expérimentaux au laboratoire Procédé et Ingénierie en Mécanique et Matériaux (PIMM)	20
1.12	Différents placements des PZTs	21
1.13	Méthodes de localisation par le calcul des temps de vol	23
1.14	La plateforme Héphaïstos du PIMM	28
1.15	Schéma de principe du choc laser symétrique	29
1.16	Diagramme XT des chocs symétriques	30
1.17	Exemple d'un assemblage de matériaux composites et de métal : une aube de turbine de Safran	31
1.18	Schéma entrée sortie du problème direct, de son approximation par un métamodèle $\widehat{\mathcal{M}}$ et de la résolution du problème inverse par un modèle $\widehat{\mathcal{M}}^{-1}$	32
2.1	Courbes de dispersion du matériau	37
2.3	Caractérisation expérimentale du premier paquet d'ondes dans la structure X11 à 100kHz	40
2.4	Processus d'endommagement et d'inspection des structures	41
2.5	DI's retenus suite à leurs évaluations sur les délaminages réels	42
2.6	Dommages cibles	44
2.7	C-SCAN des endommagements réalisés	44
2.8	Évaluations des méthodes de localisation sur les structures X11 et X12	44

2.9	Comparaison des signaux numériques et expérimentaux avec le PZT2 en actionneur à 100kHz	47
2.10	Diagramme XT de propagation du premier mode dans la poutre	48
2.11	Évolution de l'amplitude et du temps de vol du premier parquet dans la poutre	50
2.12	Exemple caractéristique d'évolution d'un DI dans la poutre en fonction de la position et de la sévérité	50
2.13	DIs en fonction de la sévérité et de la position pour la poutre en réflexion (PZT 1 → PZT 1)	50
2.14	Signal de différence de la plaque S2 où le dommage est déplacé de 10mm.	52
3.1	Approximation du problème direct par un métamodèle	56
3.2	Exemple de graphe pour le calcul d'une fonction simple $\cos(x * b + b) - x$	68
3.3	Schéma du GAN classique	71
3.5	Chemin du PZT1 au PZT2 passant par le dommage	74
3.6	Architecture de l'Info-GAN	76
3.7	Processus d'entraînement d'un métamodèle	78
3.8	Processus de prédiction avec un métamodèle	78
3.9	Stratégies d'échantillonnage courantes : exemple pour un espace paramétrique à deux dimensions	78
3.10	Énergie cumulée de la SVD appliquée aux signaux temporels de la poutre	79
3.11	Comparaison des erreurs de prédictions de la RBF avec une compression par SVD sur les signaux dans le domaine fréquentiel et temporel	81
3.12	Exemple d'une observation de la poutre compressée par Poursuite de Correspondance (<i>Matching Pursuit</i> en anglais, MP) avec deux paquets.	83
3.13	Erreur en fonction de la largeur ε pour différentes fonctions Interpolation par Fonction de Base Radiale (RBF) pour la poutre avec MP	84
3.14	Erreur médiane de l'évaluation de la RBF	85
3.16	Évaluation de la Proper Generalized Decomposition (PGD) sur la structure poutre	86
3.17	Erreur médiane de l'évaluation de l'Réseau Neuronal Adverse Génératif maximisant l'information (InfoGAN)	87
3.18	Erreur moyenne (NRE) de prédictions des métamodèles sur les trois cas d'étude (Poutre, S2 et S11)	88
4.1	La résolution inverse vise à trouver les paramètres du dommages \mathbf{p}_d à l'aide des prédictions rapides $\hat{\mathbf{d}}$ du métamodèle $\hat{\mathcal{M}}$	92
4.2	Diagramme de l'algorithme de résolution inverse	95
4.3	Évaluation de la résolution inverse sur la Poutre avec RBF + MP	96

4.4	Évaluation de la résolution inverse sur S2 avec RBF et Décomposition en valeurs singulières (<i>Singular Value Decomposition</i> en anglais, SVD)	96
4.5	Évaluation de la résolution inverse sur S11 avec la RBF et SVD	96
4.6	Résolution inverse par un métamodèle dédié	98
4.7	Comparaison des signaux à l'état sain de la structure S11 et S12	99
4.8	Échantillonnage et placement des capteurs pour les structures S11 et S12	99
4.9	Architectures des CNNs	101
4.10	Vecteurs d'entrée des CNNs	103
4.11	Erreur moyenne des prédictions en fonction du TVDI sur le cas 1	103
4.12	Évolutions de la fonction coût lors de l'entraînement pour différentes valeurs des hyperparamètres du Réseau de Neurones Convolutifs (<i>Convolutional Neural Network</i> en anglais, CNN)	104
4.13	Évaluation de la résolution inverse sur la poutre avec CNN temporel	105
4.14	Évaluation de la résolution inverse sur S2 avec CNN temporel. Des figures équivalentes sont obtenues avec le CNN avec TVDI.	105
4.15	Évaluation du CNN temporel sur le cas 1	106
4.16	Évaluation du CNN TVDI sur le cas 1	106
4.17	Évaluation du CNN temporel sur le cas 2	106
4.18	Évaluation du CNN avec TVDI sur le cas 2	106
4.19	Évaluation du CNN temporel sur le cas 3	107
4.20	Évaluation du CNN TVDI sur le cas 3	107
4.21	Comparaison prédictions du CNN sur les différents cas de S11	107
4.22	Erreur de localisation sur les structures expérimentales du CNN temporel	107
4.23	Comparaison des méthodes de résolution inverse	109
5.1	Exemple simple d'apprentissage par transfert : ici la tâche source consiste à distinguer des carrés creux des cercles creux. L'apprentissage peut être transféré pour distinguer les cercles pleins des carrés pleins.	112
5.2	Structures étudiées	113
5.3	Signaux sains utilisés pour le calcul des Indice Structurel (<i>Structural Index</i> en anglais, SI)s (uniquement le signal du chemin PZT1 vers PZT3 est affiché). Pour les structures C_1 et C_3 , il y a plusieurs signaux sains, un pour chaque coupon.	115
5.4	Architecture du CNN initial	116
5.5	Apprentissage de transfert profond basé sur le transport de caractéristiques avec la dualité de Monge-Kantorovich	120
5.6	Transport entre deux distributions (μ, ν) par les transformations $T_{\#}$ et $T^{\#}$	122

5.7	Transport entre deux distributions (μ, ν) par les potentiels de Kantorovich φ et $\bar{\varphi}$	124
5.8	Schéma d'un Input Convex Neural Network (ICNN)	127
5.9	Erreur quadratique moyenne du transfert $C_0 \rightarrow C_1$	132
5.10	Évaluation du transfert $C_0 \rightarrow C_1$	132
5.11	Erreur quadratique moyenne du transfert $C_0 \rightarrow C_2$	133
5.12	Évaluation du transfert $C_0 \rightarrow C_2$	133
5.13	Erreur quadratique moyenne du transfert $C_0 \rightarrow C_3$	134
5.14	Évaluation du transfert $C_0 \rightarrow C_3$	134
5.15	Évolution de l'erreur de prédiction en fonction du SI	135
B.1	Évaluation du RBF avec MP sur la structure poutre	145
B.2	Évaluation du RBF avec SVD sur la structure poutre	145
B.3	Évaluation du RBF avec MP sur la structure S2	146
B.4	Évaluation du RBF avec SVD sur la structure S2	146
B.5	Évaluation du RBF avec MP sur la structure S11	146
B.6	Évaluation du RBF avec SVD sur la structure S11	147
B.7	Évaluation du S-InfoGAN sur la structure S2	147
B.8	Évaluation du S-InfoGAN sur la structure S11	147
C.1	Histogrammes des erreurs de la résolution inverse sur la Poutre avec RBF et MP	149
C.2	Histogrammes des erreurs de la résolution inverse sur S2 avec RBF et SVD	149
C.3	Histogrammes des erreurs de la résolution inverse sur S11 avec la RBF et SVD	149
D.1	Histogrammes des erreurs sur la poutre avec CNN temporel	151
D.2	Histogrammes des erreurs sur S2 avec CNN temporel	151
D.3	Histogramme des erreurs du CNN temporel sur le cas 1	152
D.4	Histogrammes des erreurs de la résolution inverse du CNN avec TVDI sur le cas 1	152
D.5	Histogrammes des erreurs de la résolution inverse du CNN temporel sur le cas 2	152
D.6	Histogrammes des erreurs de la résolution inverse du CNN avec TVDI sur le cas 2	152

Liste des tableaux

1.1	Tableau comparatif des différentes méthodes de CND	11
1.2	Tableau comparatif des différentes technologies de Contrôle de la Santé des Structures (<i>Structural Health Monitoring</i> en anglais, SHM)	18
1.3	Tableau comparatif des variabilités entre le SHM et les CNDs	27
2.1	Dénomination des structures étudiées	36
2.2	Position des capteurs sur la plaque X11 et X12	38
2.3	Propriétés mécaniques des structures	46
2.4	Structure Poutre	48
2.5	Structure S2	51
2.6	Structure S11 numérique	52
2.7	Structure courbe C	53
3.1	Utilisation des méthodes d'apprentissages en SHM	62
3.2	Comparaison des différentes méthodes d'apprentissage	63
3.3	Fonctions radiales usuelles	64
3.4	Architecture de l'Info-GAN	77
4.1	Durée de la résolution inverse pour une observation	97
4.2	Architectures des CNNs	102
5.1	Indicateur d'endommagement (DI)s utilisés pour le calcul des SI avec respectivement $d_{ij}^s(t)$ et $d_{ij}^t(t)$ les signaux sources et les signaux cibles pour le chemin de l'actionneur i au capteur j	114
5.2	Indices Structurels (SIs) entre la structure source et les structures cibles .	114
5.3	Propriété mécanique et géométrique des structures étudiées	116
5.4	Valeurs des hyperparamètres	131
5.5	Architectures du modèle en charge d'extraire les caractéristiques f_θ , du potentiel de Kantorovich φ_ω et du discriminateur g_θ	136
5.6	Évaluation du transfert	136
A.1	Indices d'endommagement implémentés dans SHM@PIMM (1/2)	143
A.2	Indices d'endommagement implémentés dans SHM@PIMM (2/2)	144

Introduction générale

L'ingénierie des structures est confrontée dans toutes les industries à des besoins croissants en termes de sûreté, de sécurité et de durabilité des installations. Que ce soient les nouvelles structures avec des matériaux innovants et des conceptions audacieuses, ou les structures plus anciennes dont la durée de vie a été prolongée par rapport à la conception initiale, la volonté de détecter et de caractériser en amont des dommages pouvant mener à des catastrophes est aujourd'hui une nécessité grandissante au regard des enjeux économiques, environnementaux et sociaux.

Dans le secteur aéronautique, les matériaux composites se sont imposés au cours des dernières décennies car ils combinent des propriétés mécaniques excellentes avec une densité massique relativement faible permettant un allègement des avions et une diminution de leur consommation. Ces nouveaux matériaux sont sujets à des endommagements complexes et insidieux qui peuvent s'initier à toutes les étapes de la fabrication et de l'exploitation des avions. Le Contrôle Non-Destructif (CND) regroupe un large panel de méthodes normalisées pour inspecter ces matériaux afin de s'assurer de l'intégrité d'une structure. Ils sont réalisés suivant des plans de maintenances préventifs programmés à l'avance et nécessitant souvent l'immobilisation des appareils pour mener en toute sécurité ces inspections dans des zones parfois difficiles d'accès. La maintenance prédictive constitue un changement de paradigme fort en adaptant les actes de maintenance à l'état réel de la structure et en anticipant la détérioration d'une structure à l'aide de données de capteurs et de modèles de dégradations.

Dans ce contexte, la recherche s'oriente vers le développement de structures intelligentes (ou *smart structure* en anglais) équipées de fonctionnalités auxiliaires en plus de leurs fonctionnalités structurelles. Le Contrôle de la Santé des Structures (*Structural Health Monitoring* en anglais, SHM) désigne un ensemble de technologies qui visent à implémenter au sein même des structures un réseau de capteurs et d'actionneurs capable de contrôler en temps réel et automatiquement l'intégrité d'une structure. Une large gamme de capteurs mesurant toutes sortes de variables est proposée en fonction de la structure à inspecter, des matériaux, des dommages à caractériser, des contraintes environnementales et opératoires, etc.

Dans ces travaux de thèse, ce sera l'inspection de matériaux composites pour les structures aéronautiques par des ondes de Lamb générées et mesurées à l'aide de PZT qui nous intéressera. Les ondes de Lamb parcourent de larges portions de structures avec une faible atténuation. Les modes se propagent à des hautes fréquences ce qui les rend particulièrement sensibles aux petits dommages. De plus, les PZTs s'intègrent à

la structure sans modifier ses propriétés mécaniques, facilitant la certification d'un tel dispositif pour l'aéronautique. De nombreux défis restent à relever avant le déploiement industriel de cette technologie pour laquelle la recherche a pourtant été prolifique.

Les difficultés pour valider les méthodes de SHM sur des endommagements réalistes et maîtrisés constituent un des freins majeurs à leurs déploiements. Ces travaux rentrent alors dans le cadre du projet collaboratif Monarque regroupant plusieurs partenaires académiques et industriels avec pour objectif principal de valider l'utilité d'un procédé de choc laser symétrique pour générer des délaminages réalistes et maîtrisés dans les matériaux composites pour le SHM. Les méthodes de SHM par ondes de Lamb peuvent être alors évaluées sur des vrais délaminages, un dommage courant au cœur des matériaux et jusqu'à présent difficile à reproduire.

En proposant d'inspecter en temps réel et automatiquement les structures, le SHM se prête particulièrement bien au développement de stratégies d'apprentissage pour entraîner des modèles à caractériser des endommagements à partir de données. La caractérisation d'un endommagement peut se voir comme une résolution d'un problème inverse où les paramètres du dommage doivent être identifiés à partir des signaux mesurés en exploitant un modèle. Les tâches fondamentales du SHM ((i) détecter, (ii) localiser, (iii) classifier et (iv) quantifier) ont cependant besoin de riches bases de données pour être correctement apprises par les modèles. Par ailleurs, tout changement structurel et toute modification des conditions environnementales ou opératoires entre la structure qui a servi pour l'apprentissage et la structure en opération détériorent les prédictions des modèles par apprentissage. L'apprentissage par transfert (ou *transfer learning* en anglais) permet de capitaliser les apprentissages construits sur un ensemble de données pour les transférer vers un autre ensemble relativement proche. Les méthodes les plus prometteuses d'apprentissage sont évaluées dans ces travaux et une méthode innovante de transfert est proposée. Une attention particulière est donnée à l'intégration des variabilités inhérentes à la technologie de SHM par des ondes de Lamb au sein des stratégies d'apprentissage.

Le Chapitre 1 présente les spécificités des matériaux composites, les différentes stratégies pour connaître leur santé structurelle et dresse un bilan des verrous du SHM à l'aide d'ondes de Lamb que ces travaux ont cherché à lever. Le Chapitre 2 démontre expérimentalement la pertinence du suivi d'un délaminage induit par choc laser par le SHM à base d'ondes de Lamb et la bonne maîtrise du procédé. Ces données sont utilisées pour valider un modèle par éléments finis d'une structure intelligente équipée d'éléments piézoélectriques. Dans le Chapitre 3 un métamodèle approxime la modélisation par éléments finis pour réduire le temps de prédiction des signaux pour de nouvelles configurations de dommage. Le Chapitre 4 propose deux méthodes de résolution du problème inverse pour caractériser des endommagements : une première méthode exploite les métamodèles

construits au chapitre précédent et une seconde méthode entraîne des Réseau de Neurons Convolutifs (*Convolutionnal Neural Network* en anglais, CNN)s pour ces tâches. Enfin, le Chapitre 5 propose une méthode innovante d'apprentissage par transfert combinant la théorie du transport optimale avec un CNN pour transférer un apprentissage entre deux structures voisines.

Ces travaux ont fait l'objet de trois communications internationales :

- H. Postorino, M. Rebillat, E. Monteiro, and N. Mechbal, *Towards an industrial deployment of PZT based SHM processes : A dedicated metamodel for Lamb wave propagation*, July 2020, <https://hal.archives-ouvertes.fr/hal-03023307>,
- H. Postorino, M. Rebillat, E. Monteiro, and N. Mechbal, *Transfer Learning to close the gap between experimental and numerical data in Lamb wave based SHM*, ICCBMA, May 2022,
- H. Postorino, E. Monteiro, M. Rebillat, and N. Mechbal, *Experimental Damage Localization and Quantification with a Numerically Trained Convolutional Neural Network*, European Workshop on Structural Health Monitoring, ISBN 978-3-031-07322-9, doi :10.1007/978-3-031-07322-941,

D'une communication internationale acceptée :

- H. Postorino, E. Monteiro, N. MECHBAL, and M. REBILLAT, *Cross-structures Deep Transfer Learning through Kantorovich potentials for Structural Health Monitoring of composite structures based on Lamb waves*, SPIE, <https://spie.org/>

Et d'un article soumis dans une revue internationale :

- H. Postorino, E. Monteiro, N. MECHBAL, and M. REBILLAT, *Cross-structures Deep Transfer Learning through Kantorovich potentials for Structural Health Monitoring of composite structures based on Lamb waves*, Journal of structural Dynamics.

1

Contrôle de la Santé des Structures

Résumé

Les matériaux composites ont révolutionné les conceptions des structures aéronautiques mais ils subissent des endommagements complexes, dont le délaminage est l'un des plus insidieux. L'ingénierie des structures cherche désormais à développer des structures intelligentes possédant des fonctions auxiliaires en plus de leurs fonctions structurelles. Les dispositifs de SHM visent à caractériser *in situ*, automatiquement et en temps réel les endommagements. Parmi une grande variété de technologies décrites dans ce chapitre, c'est l'inspection par des ondes de Lamb à l'aide d'un réseau de transducteurs piézo-électriques qui est retenue. La structure intelligente se modélise alors sous la forme d'un système interrogé par des sollicitations dont les signaux sont observés pour identifier les paramètres d'endommagement. Le procédé de choc laser du projet Monarque fournit des délaminages maîtrisés utiles aux développements de cette technologie qui tarde à se déployer industriellement malgré une recherche prolifique.

Sommaire

1.1	Les structures aéronautiques actuelles	6
1.1.1	La richesse des matériaux composites	6
1.1.2	Des dommages complexes	8
1.2	Assurer l'intégrité des structures avec les CNDs	9
1.2.1	Une large panoplie de contrôles	9
1.2.2	La Maintenance Préventive	12
1.2.3	La Maintenance Prédicative	13
1.3	Le Structural Health Monitoring	13
1.3.1	Les Structures Intelligentes	13
1.3.2	Panorama des technologies de SHM	14
1.3.3	Le SHM basé sur les ondes de Lamb	17
1.3.4	Verrous du SHM par ondes de Lamb	25
1.4	Un procédé d'endommagement innovant : le projet Monarque	27
1.4.1	Contexte du projet	27
1.4.2	Délaminages induits par des chocs lasers symétriques	28
1.4.3	Applications	30
1.5	Représentation du SHM par un système	31
1.6	Contributions	34

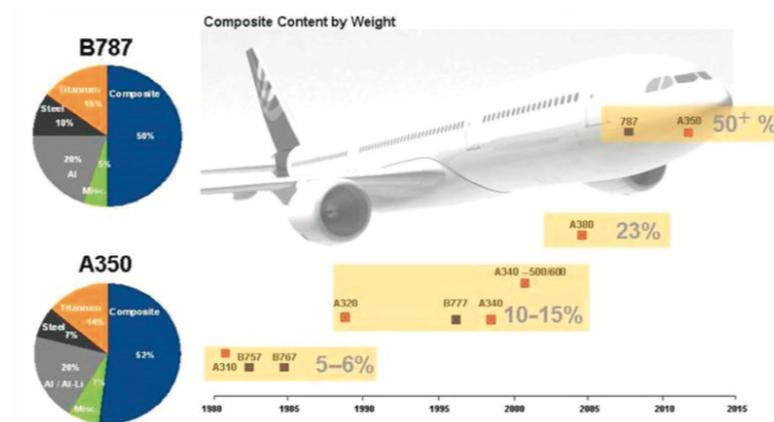


FIGURE 1.1 – Évolution du pourcentage en masse des matériaux composites dans les avions [1]

1.1 Les structures aéronautiques actuelles

1.1.1 La richesse des matériaux composites

Les matériaux composites suscitent depuis quelques décennies un intérêt croissant dans l'industrie aéronautique, automobile, spatiale et nautique [1] en remplaçant et en surpassant progressivement les structures métalliques. Le passage aux matériaux composites représente un saut technologique important pour les constructeurs qui donnent alors à leurs structures des caractéristiques inédites en termes de résistance mécanique, de résistance chimique, de forme ou de poids. Les méthodes de conception ont été intégralement repensées afin de s'adapter aux spécificités de ces nouveaux matériaux. Les changements sont encore plus importants lors de la production où le passage aux composites a entraîné l'arrivée de nouveaux métiers, moyens de production et techniques de contrôle. Le passage aux matériaux composites dans l'aéronautique a été entamé dès les années 1970 et leur utilisation n'a cessé de croître depuis. En 40 ans, la masse des composites dans les avions est passée de moins de 9 % de la masse totale à plus de 50% (Figure 1.1). L'A380 contenait près de 25% en masse de matériaux composites tandis que l'A350XWB est le premier avion d'Airbus à en contenir plus de 50%.

Les avantages offerts par les matériaux composites en font des outils de poids pour aider le secteur aéronautique à s'adapter aux enjeux environnementaux et énergétiques actuels. Ils sont au cœur des stratégies visant à réduire l'empreinte carbone du secteur en permettant un allègement des structures et ainsi une réduction de la consommation. De plus, les structures composites sont particulièrement optimisées par rapport aux exigences des constructeurs, offrant une amélioration de leur durabilité. La question de leur recyclage subsiste néanmoins car, contrairement aux matériaux métalliques, il n'existe pas encore de filière industrielle pour le réemploi de ces matériaux.

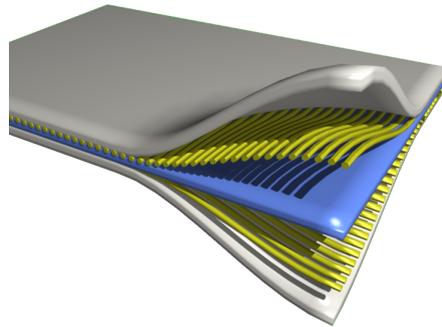


FIGURE 1.2 – Matériau composites avec la matrice et les renforts

Un matériau composite (Figure 1.2) se compose d'au moins deux composants : le **renfort** et la **matrice** [2]. Le rôle du **renfort** est d'assurer la fonction de résistance mécanique aux efforts du matériau composite. Il est constitué d'un ensemble de fibres continues ou discontinues. De nombreux types de renforts ont été développés sous des formes linéiques (fils, mèches), surfaciques (tissus) ou multidirectionnelles (tissus 3D, tresse, etc.). Les fibres peuvent être des fibres de verre, de carbone, de céramique, etc. Il existe également des fibres organiques issues de produits végétaux. En aéronautique, ce sont majoritairement des fibres de carbone qui équipent les structures ou des fibres céramiques pour certaines pièces des parties chaudes des moteurs. La **matrice** quant à elle assure la cohésion entre les fibres et la répartition des efforts. Il s'agit le plus souvent de résines en polymères classées en deux catégories : les thermodurcissables avec des propriétés mécaniques élevées et les thermoplastiques avec des propriétés mécaniques plus faibles. En aéronautiques, ce sont donc les matrices thermodurcissables avec des caractéristiques mécaniques et une masse volumique conformant aux exigences des constructeurs qui sont privilégiées. Cette très grande diversité de renfort et de matrice donne aux matériaux composites leurs propriétés uniques. Lorsqu'il n'y a pas de dommage au sein du matériau composite, la matrice et le renfort sont solidement liés sans glissement ni séparations dans des assemblages de différents types :

Les structures composites pré-imprégnés stratifiés Elles se composent de plusieurs couches successives de renforts imprégnés de résine (Figure 1.3). Les fibres sont longues et assurent la résistance mécanique tandis que la résine assure la cohésion entre les fibres. Les pièces sont réalisées par un empilement de plis en optimisant la direction des renforts en fonction des futures sollicitations. L'assemblage des plis se fait dans un moule afin de donner la bonne géométrie à la structure. La polymérisation a lieu lors de la cuisson de la matrice, donnant à l'assemblage ses propriétés. L'agencement des plis, le choix des fibres et de la matrice renforcent les propriétés mécaniques de la structure vis-à-vis des directions de sollicitation. Toutes ces libertés

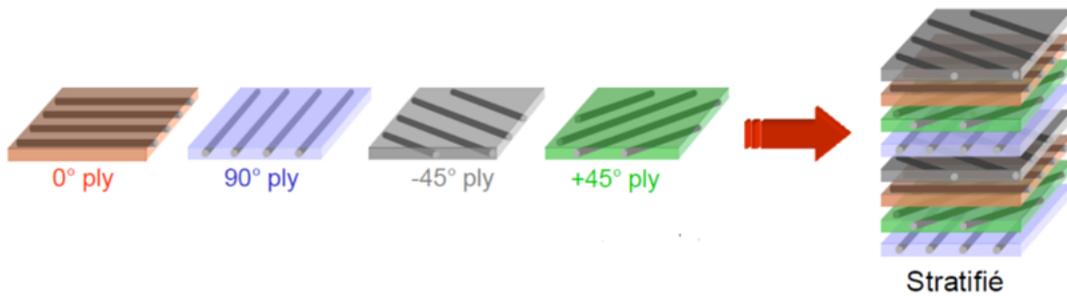


FIGURE 1.3 – Structure en matériaux composites pré-imprégnés stratifiés composée d'un empilement de 8 plis []

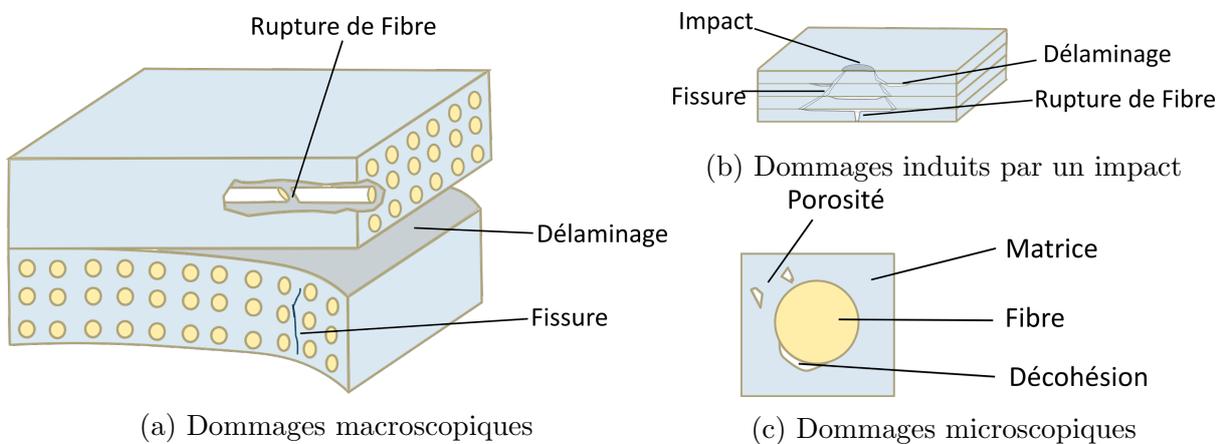


FIGURE 1.4 – Dommages dans les matériaux composites

permettent une fabrication adaptée aux besoins et la conception d'une structure avec des propriétés uniques.

Les structures sandwich Une âme, souvent en nid d'abeille, est insérée entre deux peaux en composites stratifiés et maintenue par une couche adhésive. Le nid d'abeille est généralement un alliage d'aluminium. Ce type de structures présente une très forte rigidité en flexion ou torsion et une faible masse.

Les structures composites tissées multidirectionnelles Les fibres sont entrelacées suivant des motifs plus complexes, les pièces ainsi obtenues acquièrent une résistance accrue aux chocs mécaniques. Elles sont notamment utilisées pour les aubes des moteurs, des réservoirs ou des turbines. Safran a par exemple développé une aube de turbine en composites tissés en 3D (Figure 1.17) ayant pour bord d'attaque un alliage métallique collé sur la structure.

1.1.2 Des dommages complexes

L'arrivée de ces nouveaux matériaux dans les structures s'est évidemment accompagnée de nouveaux dommages rarement visibles en surface. Alors que les matériaux

métalliques sont principalement victimes d'impacts, de fissuration par fatigue ou de corrosion, les mécanismes d'endommagement des matériaux composites sont à l'image des structures composites : plus complexes et plus variés. Leurs apparitions sont liées à des défauts de fabrication, à des problèmes d'usure ou à des impacts lors de l'exploitation. Pour les matériaux stratifiés, trois modes de dégradation sont principalement observés à l'échelle microscopique et mésoscopique (Figure 1.4) :

- la fissuration de la matrice,
- la dégradation de l'interface fibre/matrice avec une rupture d'adhérence,
- la rupture des fibres.

À l'échelle macroscopique, les structures stratifiées sont particulièrement sujettes à la séparation progressive des plis : **les délaminages** [3]. Ils sont d'abord initiés par des phénomènes microscopiques complexes, notamment des micro-fissurations de la matrice. Ces fissures peuvent être amorcées par des contraintes inter-laminaires trop importantes, des discontinuités fortes dans le champ des contraintes, des porosités dans la matrice ou bien lors de la fabrication. Leurs propagations sont amplifiées par les conditions opératoires (cycles de chargement et déchargement, variations de température, etc.) défavorables d'un aéronef en exploitation. Un autre type de dommage, le *Barely Visible Impact Damage* (BVID) préoccupe particulièrement les constructeurs. Il se présente dans le cas particulier d'un choc de faible énergie (chute d'un outil, manutention, etc.) sur une structure en matériaux composites. Une combinaison de l'ensemble des modes de dégradation dont des délaminages (Figure 1.4b) est alors présente au cœur du matériau avec une influence significative sur la tenue structurelle alors que ce dommage est peu visible en surface [4].

Ce nombre important de dommages probables, parfois complexes et difficiles à repérer, limite le potentiel d'innovation des matériaux composites lors de la conception des structures car des marges de sécurité importantes doivent être prises. En parvenant à contrôler en temps réel l'état d'une structure, il sera possible de réduire ces marges de sécurité tout en garantissant l'intégrité de la structure. Cela permettra des conceptions plus audacieuses, réduisant le poids de la structure et ainsi la consommation des aéronefs.

1.2 Assurer l'intégrité des structures avec les CNDs

1.2.1 Une large panoplie de contrôles

Malgré leurs qualités nombreuses, les matériaux composites ne sont pas épargnés par la présence d'endommagements. Il est alors absolument nécessaire de suivre l'état des structures composites afin de vérifier leur intégrité dès la fabrication et durant tout le cycle de vie. Ce suivi s'appuie le plus souvent sur le CND qui regroupe une très large

gamme de méthodes permettant de visualiser des dommages au sein des matériaux et des structures. Il s'appuie sur l'observation et l'analyse de la réponse d'une structure ou d'un matériau à une sollicitation de faible énergie. Ces contrôles normalisés se retrouvent dans l'ensemble des secteurs industriels et les plus courants sont décrits ci-dessous. Le Tableau 1.1 récapitule les principes généraux de ces contrôles avec leurs avantages et inconvénients.

Inspection Visuelle (VT) Cette méthode est la plus naturelle et la plus simple à mettre en place. Elle est très efficace pour repérer les dommages de surface, notamment ceux qui apparaissent suite à un impact sur la structure. Cependant, elle ne détecte pas les dommages qui se trouvent à l'intérieur de la structure ou au sein du matériau.

Contrôle par Courant de Foucault (ET) Un champ magnétique généré par une bobine dans une sonde traverse le matériau en y induisant des courants de Foucault. En présence d'un dommage, une modification du champ magnétique est mesurée par la sonde. La structure doit être conductrice pour que le champ puisse se propager. De plus, les effets de peau empêchent le contrôle à travers des grandes épaisseurs et l'interprétation des mesures est complexe.

Contrôle par Ultra-Son (UT) Une onde ultra-sonore est générée par une sonde et se propage dans la structure. La détection du dommage se fait en observant la propagation de l'onde, son atténuation, ses diffractions et ses réflexions. Les contrôles se font selon deux modes :

Pulse-écho Une seule sonde fonctionne en actionneur et en capteur simultanément,

Pitch-catch Une sonde agit en actionneur et une autre en capteur.

L'onde est émise à une fréquence comprise entre 100kHz et 25MHz. L'exploitation des mesures se fait en affichant les signaux sur un point en A-Scan, une ligne en B-Scan et une surface en C-Scan. Cette technique très répandue permet de s'assurer de l'intégrité de tous les types de structures à toutes les étapes de leurs vies pour des dommages allant en deçà du millimètre. Deux catégories d'ondes sont utilisées pour le contrôle par UT : les ondes volumiques pour un contrôle dans l'épaisseur et les ondes de Lamb pour un contrôle sur une plus grande portion de structure avec deux sondes distantes fonctionnant en mode *pitch-catch* [5]. Cette méthode a inspiré par la suite le SHM par des ondes de Lamb présenté dans la Section 1.3.3. Pour des structures de grandes tailles, difficiles d'accès ou en milieu dangereux, un dispositif robotisé peut être déployé pour réaliser le contrôle [6]. Il réduit également les variabilités liées aux opérateurs qui ont une influence importante sur la qualité du contrôle mais les variabilités liées à l'interprétation des signaux perdurent.

Nom	Symbole ^a	Principe physique	Trans - ducteurs	Portabilité	Vitesse contrôle	Contact structure	Matériaux	Défaut à cœur	Coût	Inter - prétation
Inspection Visuelle	VT	Observation	Vue	Très bonne	Rapide	Sans	Tous	Non	Faible	Facile
Radiographie	RT	Faisceau de Rayons X	Film ou Capteurs Plan	Moyen	Rapide	Sans	Tous	Oui	Élevé	Facile
Ultra-son	UT	Onde ultra-sonore	PZT	Bonne	Lent	Avec	Tous	Oui	Moyen	Moyen
Courant de Foucault	ET	Champs Magnétique	Bobine	Bonne	Lent	Avec	Conducteur	Non	Moyen	Difficile
Shearographie	ST	Interférométrie	Camera	Bonne	Rapide	Sans	Tous	Oui	Élevé	Moyen
Émission Acoustique	AT	Onde mécanique transitoire	Accéléromètre	Bonne	Rapide	Avec	Faible	Oui	Moyen	Difficile
Thermographie	TT	Diffusion de chaleur	Caméra Infrarouge	Bonne	Rapide	Sans	Tous	Moyen	Moyen	Moyen
Ressuage	PT	Diffusion de liquide	Vue	Bonne	Lent	Avec	Tous	Non	Faible	Facile

TABLE 1.1 – Tableau comparatif des différentes méthodes de CND

^a. Symboles provenant des normes NF EN ISO 9712 et EN 4179

Contrôle par Thermographie (TT) Un champ de température dans une pièce soumise à une excitation thermique est visualisé à l'aide d'une caméra infrarouge. La présence d'un éventuel dommage modifie localement la diffusion de la chaleur, les contrastes obtenus sur l'image thermique permettent alors de visualiser les dommages. Cette technologie, applicable pour de nombreux types de structures et facile à déployer bénéficie des progrès récents dans les caméras infrarouges. Elle suscite actuellement un intérêt important [7].

Contrôle par Shearographie (ST) Un champ de déformation est mesuré en exposant la pièce à une lumière cohérente et en la sollicitant mécaniquement. Cette méthode relativement nouvelle permet d'inspecter rapidement et sans contact des larges portions de structure.

Contrôle par Ressuage (PT) Les fissures de surface sont mises en valeur à l'aide d'un liquide pénétrant et suintant lors du séchage [8]. Cette technique est parfois difficile à mettre en œuvre mais s'applique sur tout type de matériau. Elle n'est cependant adaptée que pour les dommages débouchant en surface.

Contrôle par Radiographie (RT) Des photographies de l'intérieur des pièces sont réalisées en les exposant à des rayons X. L'exposition aux rayons ionisant en fait une méthode dangereuse et l'accès à la pièce avec le matériel de radiographie n'est pas toujours simple. Récemment, des progrès importants ont été fait avec l'arrivée de la radiographie numérique et de la tomographie permettant une visualisation en trois dimensions des pièces.

Contrôle par Émission Acoustique (AT) Une structure soumise à une sollicitation ou à un chargement est écoutée en permanence à l'aide d'accéléromètres. Lorsqu'une dégradation s'amorce et se propage, elle libère de l'énergie sous la forme d'ondes élastiques transitoires qui sont mesurées et analysées.

1.2.2 La Maintenance Préventive

Les CNDs occupent encore aujourd'hui un rôle prépondérant afin de s'assurer de l'intégrité d'une structure durant tout son cycle de vie. Les différentes méthodes de CNDs détectent efficacement les dommages qui peuvent être présents dans une structure composite. Dans l'aéronautique, une VT a lieu avant chaque vol d'un appareil pour y repérer d'éventuels impacts. En complément, des inspections par UT ont lieu lors de la fabrication de la structure puis à des intervalles réguliers en service suivant un plan de **maintenance préventive**. Si un dommage dépasse des seuils de détection, il est classé comme **indication**. Il sera alors suivi régulièrement et des actions correctives pourront être mises en place. Ces contrôles demandent l'immobilisation de l'appareil et l'accès à certaines structures est parfois complexe, augmentant alors la difficulté et le cout du

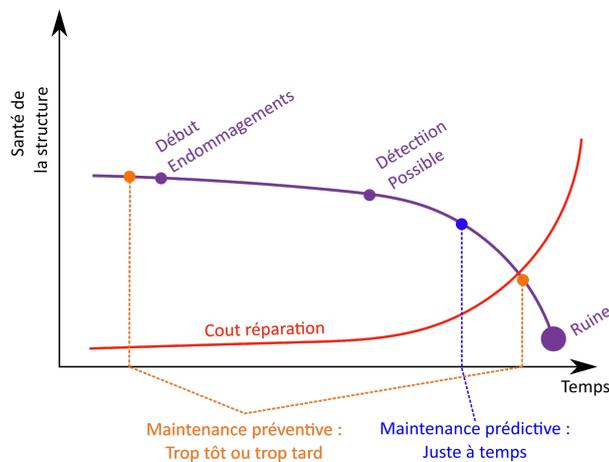


FIGURE 1.5 – Comparaison entre la maintenance préventive et prédictive

contrôle. Le contrôle peut aussi avoir lieu trop précocement ce qui augmente le coût des inspections ou trop tardivement ce qui augmente le coût de réparation (Figure 1.5).

1.2.3 La Maintenance Prédictive

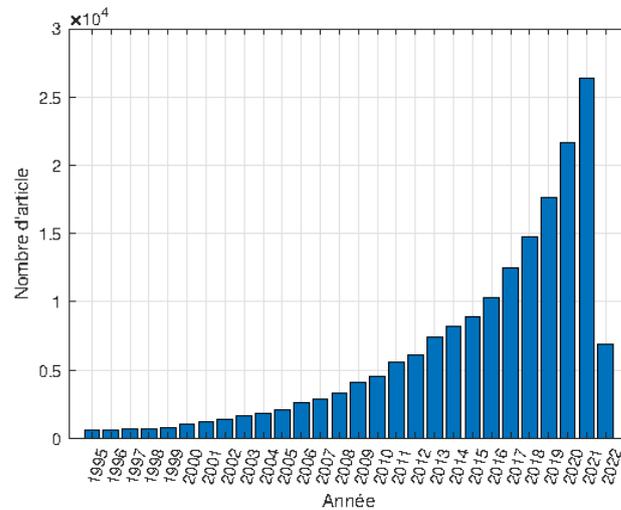
La **maintenance prédictive** constitue un changement de paradigme fort en anticipant les actes de maintenance bien avant la détérioration du bien en surveillance selon le franchissement de seuils de sévérité déterminés à l'avance. Cette démarche permet d'adapter les actes de maintenance à l'état réel de la structure. Elle parvient à estimer la durée de vie restante d'une structure à partir de mesures de capteurs et de modèles de dégradation. Pour illustrer ce concept, dans un cadre aéronautique, l'appareil sera mis à l'arrêt avant l'apparition d'un endommagement structurellement dangereux (Figure 1.5). Un nouveau type de structures équipées d'un système intégré de surveillance et d'alerte en temps réel est alors nécessaire pour exploiter au mieux cette nouvelle stratégie de maintenance.

1.3 Le Structural Health Monitoring

1.3.1 Les Structures Intelligentes

Les structures ont connu des évolutions technologiques considérables avec le déploiement des matériaux composites. Aujourd'hui, de nombreux travaux des milieux académiques et industriels cherchent à donner aux structures non seulement des fonctions structurelles, mais également des fonctions auxiliaires leurs permettant de mesurer leur environnement et de s'y adapter [9]. Ces nouvelles structures sont désignées par le terme **structures intelligentes** (ou *smart structures* en anglais).

Ainsi, dans le cadre du développement de la maintenance prédictive, la création de

FIGURE 1.6 – Nombre d’articles contenant le mot clef *SHM*¹

structures intelligentes capables de surveiller et de déterminer leur état de santé en temps réel est devenue au cours de ces dernières décennies un sujet de recherche et d’innovation important. Elle s’appuie sur la mise en commun de toutes les avancées en modélisation des structures, en caractérisation des dommages matériels, structurels et de leurs évolutions, des technologies des transducteurs, des méthodes de traitement et d’analyse du signal, etc. Exploités conjointement, ces développements technologiques et scientifiques offrent la possibilité de suivre en temps réel, automatiquement et *in situ* l’intégrité d’une structure. Ces nouvelles méthodes de contrôle et de surveillance automatisées et intégrées sont désignées par le terme SHM. La recherche a été prolifique sur ces technologies (Figure 1.6) car les enjeux pour intégrer ces systèmes aux structures sont complexes et variés. Les exigences auxquelles doivent répondre un système de SHM sont multiples et s’avèrent plus nombreuses que celles des CNDs [10] :

- Capable de faire des évaluations en continu,
- Sensible aux petits dommages,
- Sensible à différents types de dommage,
- Adapté aux conditions opératoires (chargement, déchargement),
- Robuste vis à vis au bruit de mesure,
- Adapté aux changements environnementaux (température, humidité, pression, etc.).

1.3.2 Panorama des technologies de SHM

Un nombre croissant de technologies est proposé pour le SHM dont certaines sont encore au stade de la preuve de concept en laboratoire tandis que d’autres sont exploitées industriellement. Un panorama des technologies regroupées dans des grandes

catégories est donné dans cette section afin de donner une vision générale des différents technologies, méthodes et applications proposées en SHM. Toutes les structures peuvent potentiellement être équipées d'un tel système : les immeubles [11, 12], les ponts [11, 13, 14, 15, 16, 17, 18, 19], des barrages [20, 21], les tunnels, les voies ferrées [22, 23], des éoliennes [12, 24], des stades [25], les structures aéronautiques [26], les pipelines [27], etc.

Dans un premier temps, les approches globales et locales sont distinguées. Les **approches globales** surveillent des paramètres à grande échelle pour repérer d'éventuelles anomalies. Elles ne permettent pas immédiatement de faire un diagnostic précis ni de localiser ou caractériser le problème. En revanche, elles donnent des indicateurs cruciaux pour prévenir les risques de ruine. Elles exploitent le plus souvent des analyses modales à basse fréquence pour détecter un changement de raideur ou de masse, ou bien des mesures de grandes déformations. Ces méthodes sont déjà déployées et exploitées industriellement pour la surveillance de structures en génie civil. Les **approches locales** surveillent des endommagements de plus petites tailles qui demandent une densité plus importante de capteurs et des fréquences de mesures plus élevées. Ces approches sont donc plus difficiles à déployer mais sont bien plus ambitieuses scientifiquement car elles visent à caractériser précisément un endommagement.

Une distinction importante est également faite entre les méthodes passives et les méthodes actives. Les **méthodes passives** n'utilisent pas d'actionneur, une écoute de la structure est faite en permanence afin de repérer des anomalies. L'énergie de la mesure provient alors d'un impact [26], de l'ouverture d'un dommage, de cycles de chargement [22] ou de bruits ambiants [28, 29]. Les **méthodes actives** utilisent des actionneurs pour interroger la structure et mesurent sa réponse pour établir un diagnostic. En plus d'un réseau de capteurs, il est alors nécessaire d'implémenter des actionneurs (généralement un actionneur piézoélectrique ou un plot vibrant) avec toute une chaîne de transport d'énergie.

Les approches décrites précédemment s'appuient sur différentes technologies de capteurs implémentés dans les structures :

Les fibres optiques mesurent des déformations par une modification du spectre transmis et du spectre réfléchi [28, 29, 30, 31]. Elles résistent aux environnements difficiles et peuvent s'intégrer au sein des matériaux composites le long des fibres.

Les jauges de déformation mesurent des variations de la résistance électrique lors d'une déformation [30].

Les accéléromètres mesurent des accélérations [26]. Ils sont abordables, sensibles et faciles à implémenter

Les pastilles piézoélectriques mesurent des faibles déformations. La réversibilité des

matériaux piézoélectriques permet aux mêmes éléments d'être utilisés en tant que capteur ou en tant qu'actionneur. Leur forme peut être optimisée à la structure et aux sollicitations [22].

L'implémentation des capteurs au sein des structures est un enjeu d'ingénierie important avec un câblage et des dispositifs d'acquisition et de traitement du signal à prévoir. La question de la durée de vie des capteurs, de leur maintenance et leurs éventuels remplacements doit également s'étudier. À l'aide de ces capteurs, différentes variables sont observées [10] :

Analyse modale La surveillance de la structure se fait par la mesure de ses fréquences propres, de ses modes propres ou de l'amortissement à l'aide des accéléromètres [19, 26, 32, 33, 34, 35, 36] ou des PZTs [22]. Cette approche peut être active ou passive, globale ou locale. Elle reste cependant peu sensible aux dommages de petites tailles qui nécessitent des inspections à haute fréquence.

Déformation ou contrainte La surveillance se fait en mesurant des déformations à l'aide de jauges de déformation, de fibres optiques [37], de corrélation d'image [25, 36].

Propagation d'ondes [28] La surveillance se fait à l'aide de capteurs et d'actionneurs capables d'émettre et/ou recevoir une onde se propageant dans la structure, le plus souvent des ondes de Lamb. De manière analogue aux CNDs par UT le diagnostic se fait en analysant la propagation de l'onde dans le milieu. Ces méthodes locales sont sensibles aux endommagement de petites tailles.

Impédance électromécanique [38, 39, 40] Le collage des PZTs sur la structure induit un couplage électro-mécanique : l'impédance électromécanique du PZT est alors influencée par les propriétés mécaniques de la structure. La mesure de l'impédance permet aussi de vérifier l'état du capteur et de son collage.

Émission Acoustique L'énergie libérée par un dommage en formation se propage dans la structure sous la forme d'ondes élastiques transitoires. Cette approche uniquement passive exploite les mesures d'accéléromètres, de PZTs ou de fibres optiques.

Le Tableau 1.2 compare les différentes technologies de capteurs disponibles pour le SHM et la Figure 1.7 schématise les différents capteurs qui peuvent équiper une structure intelligente.

Une dernière classification des dispositifs de SHM est communément faite en définissant cinq tâches qui font appel à des niveaux croissants de maturité technologique [41] :

1. **Détection** : *Un dommage est-il présent ?*
2. **Localisation** de dommage : *Où est le dommage ?*
3. **Quantification** du dommage : *Quelle est la taille du dommage ?*

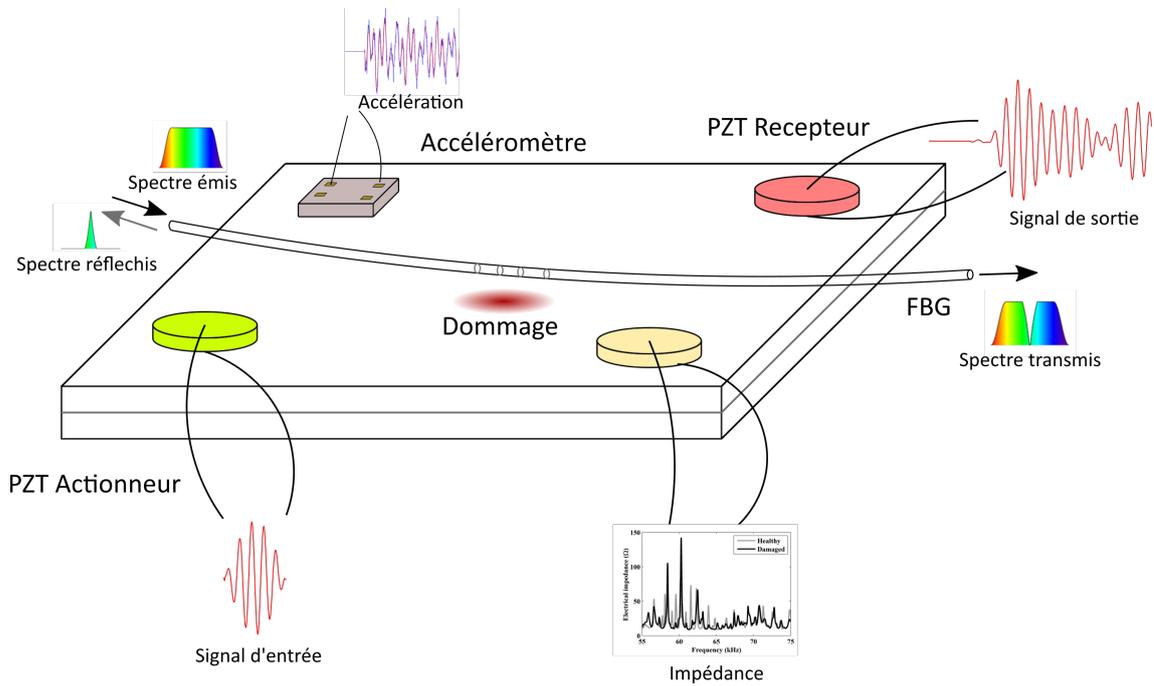


FIGURE 1.7 – Structure intelligente équipée d’un ensemble de transducteurs pour réaliser des mesures

4. **Caractérisation** du dommage : *De quel type de dommage s’agit-il ?*
5. **Pronostic** : *Quelle est la durée de vie de la structure ?*

Les techniques les plus avancées en SHM atteignent le niveau 2 avec satisfaction. En revanche, les niveaux 3, 4 et 5 sont encore des sujets actifs de recherche.

Ces travaux ont retenu l’inspection par la propagation d’ondes de Lamb générées et mesurées à l’aide d’un réseau de PZTs. C’est une méthode active et locale sensible aux dommages de petites tailles de différents types. L’implémentation des capteurs sur la structure ne modifie pas ses propriétés mécaniques et les mêmes éléments peuvent être utilisés en tant que capteur ou en tant qu’actionneur ce qui limite la masse supplémentaire. La certification d’un tel dispositif pour l’aéronautique sera plus simple que pour d’autres méthodes. La section 1.3.3 permet d’appréhender les principes généraux de cette technologie pour le SHM.

1.3.3 Le SHM basé sur les ondes de Lamb

1.3.3.1 Généralités sur les ondes de Lamb

Les structures en matériaux composites des avions rentrent dans la catégorie des **structures minces**, un type de structure dont l’épaisseur est négligeable par rapport à sa longueur et sa largeur. Deux catégories d’ondes mécaniques se retrouvent alors dans ce

TABLE 1.2 – Tableau comparatif des différentes technologies de SHM

Capteurs	Principe physique	Variables observées	Globale / Locale	Active / Passive	Intégration	Coût
PZT	Piézo-électricité	Ondes, Impédance	Locale	Active & Passive	Moyen	Moyen
Fibres Optique	Optique	Déformation, Onde	Locale	Passive	Facile	Élevé
Jauges	Résistance électrique	Déformation	Locale	Passive	Facile	Faible
Accéléromètre	Accélération	Onde, Modes	Globale ou Locale	Passive	Facile	Faible
Caméra	Corrélation d'image	Déformation	Globale	Passive	Facile	Faible

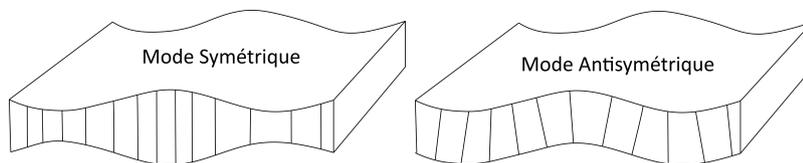


FIGURE 1.8 – Mode symétrique et antisymétrique dans une plaque

type de structures : les ondes de cisaillement dont le déplacement particulière est dans le plan de la couche mince et les **ondes de Lamb** [42] dont le déplacement particulière est transverse au plan de la couche mince. Elles ne doivent pas être confondues avec les ondes longitudinales (*ondes P*) et transverses (*ondes S*) qui sont des ondes volumiques se propageant dans un milieu infini, ni avec les ondes acoustiques de surfaces (ou ondes de Love) se propageant à la surface d'un solide semi-infini [43].

Lorsque les surfaces de la structure mince sont libres, elles créent un guide d'ondes qui autorise la propagation des ondes de Lamb. Ces ondes sont fortement **dispersives**, leurs vitesses de propagation dépendent de leurs fréquences (Figure 1.9). Deux formes d'ondes, une **symétrique** et une **antisymétrique** (Figure 1.8), coexistent et une infinité de modes sont possibles à une fréquence d'excitation donnée. Le i -ème mode symétrique et le j -ème mode antisymétrique sont notés respectivement S_i et A_j . En pratique, seuls les modes A_0 et S_0 sont ciblés lors de l'excitation pour faciliter l'interprétation des signaux mesurés. Ces ondes se propagent des vitesses élevées, de l'ordre de 1000 m/s pour le mode le plus lent S_0 dans un matériau composite aéronautique. Leur atténuation est faible ce qui les rend particulièrement adaptées pour l'inspection de larges portions de structures avec un nombre restreint de capteurs et d'actionneurs. En utilisant des actionneurs et des capteurs adaptés, il est possible d'utiliser ces ondes pour interroger la structure et espérer ainsi caractériser les endommagements.

Afin de mieux appréhender les phénomènes physiques qui entrent en jeu, le lecteur

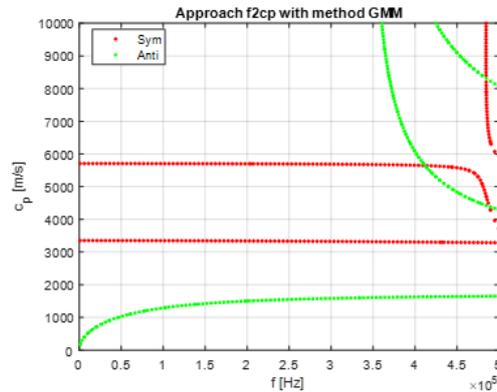


FIGURE 1.9 – Exemple d’une courbe de dispersion des ondes de Lamb dans un matériau composite aéronautique

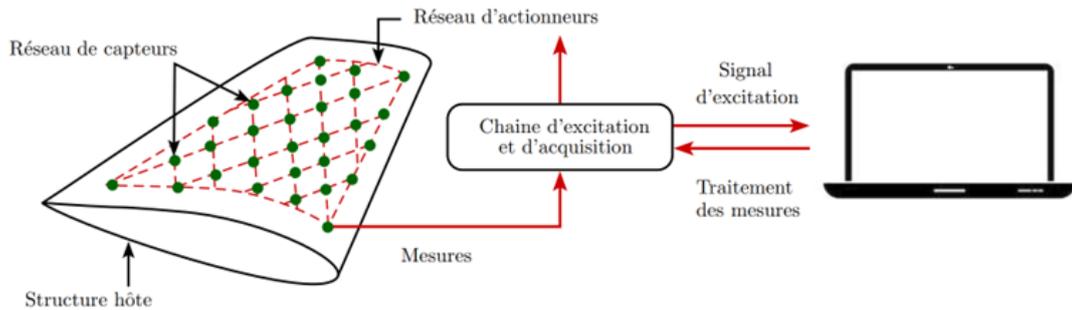


FIGURE 1.10 – Structure intelligente équipée d’un réseau de PZTs [8]

pourra se référer au Chapitre 6 de [1] où une démonstration des relations de dispersion de Rayleigh-Lamb des modes symétriques et antisymétriques est faite dans le cas d’une plaque mince isotrope et infinie avec des conditions de surface libres. La solution analytique de cette équation n’existe pas mais des résolutions numériques sont proposées. L’hypothèse d’un milieu homogène et isotrope n’est pas valide dans le cas des matériaux stratifiés car ils comportent plusieurs couches fortement anisotropes dont les propriétés mécaniques et les orientations varient en fonction du pli.

1.3.3.2 Choix des transducteurs

La technologie piézoélectrique est retenue pour la réalisation des éléments actifs et passifs car les **matériaux piézoélectriques** sont capables de mesurer des déformations faibles ainsi que de transmettre des efforts au système. Ils sont légers et peuvent être collés sur la structure formant alors un réseau de transducteurs (voir Figure 1.10). Leur intégration ne modifie pas les propriétés mécaniques de la structure ce qui facilite la certification d’un tel dispositif pour l’aéronautique. Le matériel d’acquisition associé à ces structures se compose généralement d’un **générateur** pour émettre un signal, d’un



(a) La nacelle équipée d'un réseau de PZT (b) Plaque en cours d'inspection au laboratoire Procédé et Ingénierie en Mécanique et Matériaux (PIMM) [45]

FIGURE 1.11 – Dispositifs expérimentaux au PIMM

multiplexeur pour sélectionner l'élément piézoélectrique actionneur, d'une **carte d'acquisition** et d'un **ordinateur** pour enregistrer et traiter les données. L'ensemble du matériel d'acquisition lors du contrôle d'une petite structure peut être observé sur la Figure 1.11b.

La **réversibilité** des matériaux piézoélectriques permet aux mêmes éléments de fonctionner en actionneur ou en capteur, offrant des configurations multiples d'utilisation, facilitant l'implémentation d'un tel système et réduisant les coûts. Généralement chaque PZT agit alternativement en actionneur. Le choix du signal d'excitation est important pour que les ondes émises aient des longueurs d'onde compatibles avec la taille du dommage. Il s'agit souvent d'une succession de sinus fenêtrés dont la fréquence centrale varie sur une plage déterminée en fonction des courbes de dispersion du matériau. Les mesures sont répétées une dizaine de fois afin de déployer des méthodes probabilistes. D'autres type de signaux comme des sinus balayés exponentiels [8, 44] permettent d'identifier des non-linéarités et de classifier des endommagement mais ces signaux multimodaux sont plus complexes à interpréter. Avant de déployer des algorithmes spécifiques au SHM, les signaux bruts doivent être débruités, filtrés et alignés temporellement.

Le déploiement industriel du SHM par des ondes de Lamb se fait encore attendre mais quelques exemples de structures à l'échelle 1 équipées de ce type de systèmes illustrent les possibilités de la technologie pour le secteur aéronautique. Dans [45] la surveillance de plusieurs éléments d'une nacelle d'un Airbus A380 (Figure 1.11a) est réalisée. Dans [46], un large panneau avec des raidisseurs est surveillé par des PZTs. Une démonstration en contexte industriel a été proposée en affichant la position du dommage sur la structure à l'aide d'un casque de réalité virtuelle², facilitant alors l'intervention pour valider le contrôle et potentiellement effectuer un acte de correction.

2. La vidéo dans le lien suivant est très démonstrative Vidéo

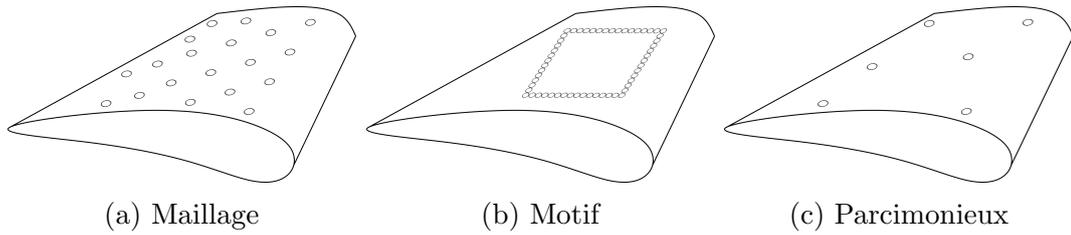


FIGURE 1.12 – Différents placements des PZTs

1.3.3.3 Placement des Transducteurs

Le placement des capteurs influence fortement la qualité des inspections du SHM basé sur des ondes de Lamb. En fonction des méthodes et des paramètres choisis, 3 types de placement apparaissent :

Répartition en motifs Le placement s’inspire des tomographies aux rayons X, la zone à inspecter est délimitée par les PZTs et le dommage est inspecté par des ondes provenant de toutes les directions. Ce placement est favorable au déploiement d’algorithmes de reconstruction d’image [29, 47, 48, 49]. Différents motifs sont possibles (circulaire, rectangulaire, ligne) pour réaliser les reconstructions tomographiques [50, 51]. Ce type de placement fait appel à un nombre important de capteurs, il n’est applicable que dans le cas d’études en laboratoire.

Répartition par maillage Le réseau de capteurs prend la forme d’un maillage afin de pouvoir inspecter la totalité d’une grande structure. Les mailles sont déterminées en optimisant la détectabilité [52, 53], en minimisant l’atténuation entre deux capteurs proches ou en minimisant le bruit de mesure [54, 55].

Répartition parcimonieuse Lorsque la structure est complexe (avec des courbures, des raidisseurs, des parties usinées, etc.) ou de petite taille, la géométrie limite les possibilités d’implémentation des PZTs qui sont disposés aux quelques emplacements disponibles. Cette approche doit être favorisée car dans un contexte industriel les structures sont dotées d’un nombre important d’éléments auxiliaires et les capteurs ne pourront être placés qu’en nombre limité. Ainsi [56] propose une méthode d’optimisation pour le placement des capteurs prenant en compte ces contraintes (nombre de capteurs, positions interdites et détectabilité).

1.3.3.4 Détection d’un dommage

Lors de la phase de détection, les signaux mesurés à un état quelconque sont comparés avec les signaux enregistrés précédemment à un état considéré comme sain à l’aide d’in-

dicateurs synthétiques appelés Indicateur d'endommagement (DI). Une variation des DI indique une modification dans la structure, et donc la présence probable d'un dommage. En considérant $y_{i,j}^h$ le signal de la structure saine pour l'actionneur i vers l'actionneur j et $y_{i,j}^d$ le signal pour la structure potentiellement endommagée, le DI global est alors :

$$DI_G = \sum_{i=1}^{N_{capt}} \sum_{j=1}^{N_{act}} DI_{ij} = \sum_{j=1}^{N_{act}} DI(y_{i,j}^h, y_{i,j}^d) \quad (1.1)$$

De nombreux DI sont implémentés dans le logiciel SHM@PIMM développé au sein de l'équipe Dynamique, Structure et Contrôle (DYSCO). Ils sont présentés dans le Tableau A.1 de l'Annexe A.

Pour que la comparaison entre une mesure à un état quelconque et une mesure dans un état de référence soit pertinente, les deux mesures doivent être réalisées dans les mêmes conditions environnementales et opératoires (pas de variation de température, de chargement, etc.) ce qui n'est pas facile pour un aéronef en exploitation. Des méthodes sans état de références ont alors été proposées exploitant la décomposition des modes des ondes de Lamb [40], un métamodèle avec une décomposition en dictionnaire [57] ou les fonctions Green [47, 58]. Ces approches restent limitées à la détection, l'utilisation d'une référence est le plus souvent nécessaire pour les tâches suivantes de SHM.

1.3.3.5 Localisation d'un dommage

Après l'étape de détection qui s'assure de la présence du dommage, les algorithmes de localisation cherchent à déterminer sa position. Les résultats de ces algorithmes prennent généralement la forme d'une carte de la structure où chaque pixel est associé à une probabilité de présence du dommage. Plus cette valeur est élevée, plus le dommage est susceptible d'être localisé à cette position. La quantité de méthodes proposées pour la localisation est vaste, il est difficile d'en faire une liste exhaustive. Les méthodes les plus courantes testées et validées sur un large éventail de cas d'étude et considérées comme classiques pour le SHM à base d'ondes de Lamb sont présentées ici.

Triangulation par temps de vol Les méthodes de triangulation (voir Figure ??) déterminent la position d'un dommage à l'aide du calcul des Temps de Vol (*Time of Flight* en anglais, TOF) des signaux de différence entre l'état sain et l'état endommagé. Cette différence permet d'isoler les informations liées à la présence du dommage. La transformée de Hilbert est appliquée aux signaux pour extraire le TOF du premier maximum local de l'enveloppe des signaux à la fréquence sélectionnée. Les vitesses de groupe dans le matériau sont déterminées pour chaque fréquence à l'aide des courbes de dispersion ou bien par des mesures expérimentales sur la structure.

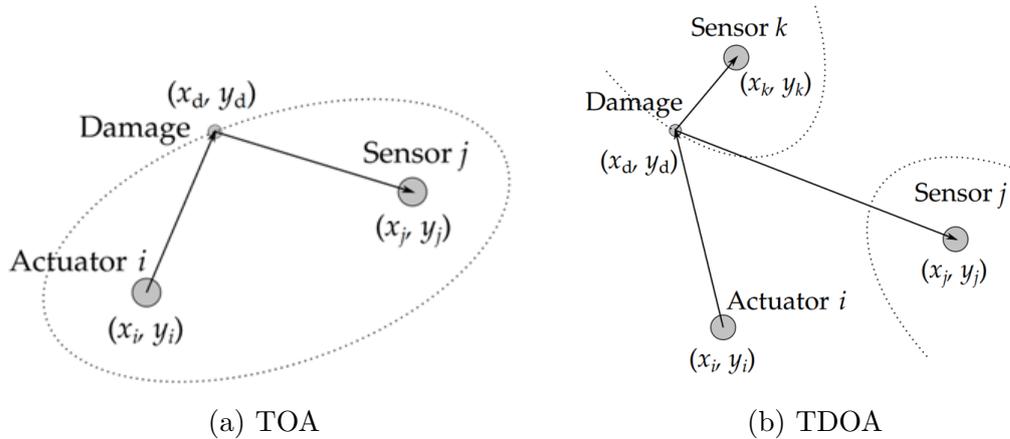


FIGURE 1.13 – Méthodes de localisation par le calcul des temps de vol [59]

La méthode **Temps d'Arrivée** (*Time Of Arrival* en anglais, **TOA**) repose sur le calcul du temps de vol de l'onde ayant effectué le trajet de l'actionneur vers le capteur en passant par le dommage. Pour les matériaux isotropes, le calcul de la position du dommage revient alors à déterminer une intersection d'ellipses dont les foyers sont les paires d'actionneur-capteur (Voir la Figure (a) ??). La **Différence de temps d'arrivée** (**Time Difference Of Arrival** (**TDOA**)) s'appuie sur la mesure de la différence de temps d'arrivée de l'écho de l'onde sur le dommage entre deux capteurs. Pour les matériaux isotropes, le calcul de la position du dommage revient à déterminer une intersection d'hyperboles dont les foyers sont des paires de capteurs (Voir la Figure (b) ??).

Ces méthodes de triangulations sont particulièrement adaptées pour des structures planes et isotropes. Elles sont simples à implémenter et nécessitent un nombre réduit de capteurs. Dans le cas de matériaux anisotropes, le problème de localisation est plus complexe et il est nécessaire de mettre en place une procédure de minimisation. Elles ne sont pas adaptées pour les structures avec des changements de propriétés des matériaux et des géométries complexes.

Excitelet Dans la méthode Excitelet [60], le calcul de la corrélation croisée permet de comparer un signal de différence avec un signal synthétique déterminé pour chaque position potentielle du dommage. Ce signal synthétique se compose d'un élément d'un dictionnaire dont le déphasage est déterminé par le calcul du TOF du chemin Actionneur-Dommage-Capteur. Cette méthode se montre valide avec un nombre réduit de capteurs.

Delay And Sum (DAS) Dans la méthode DAS [61], les signaux résiduels obtenus en soustrayant les signaux à l'état sains et les signaux à l'état d'intérêt de tous les chemins actionneur-capteur sont déphasés selon une règle de décalage temporel puis additionnés afin de produire un signal moyen qui est utilisé pour le calcul des figures de localisation.

Tensor La méthode **Tensor** [62] exploite les données sous la forme d'un tenseur à 3 dimensions : une pour le temps, une pour le capteur et une pour l'actionneur. La Décomposition Canonique Polyadique (CPD) du tenseur construit à partir de la phase et de l'amplitude du signal résiduel est liée à la distance entre les PZT et le dommage.

Algorithme de Reconstruction pour l'Inspection Probabiliste de Dommage (RAPID)

L'algorithme RAPID calcule un DI comparant l'état de référence avec l'état actuel et le localise par la méthode des ellipses [61]. Les figures de localisation des dommages pour chaque chemin sont ensuite additionnées afin de construire la figure de localisation finale.

1.3.3.6 Quantification du dommage

Les méthodes de quantification cherchent à déterminer la taille et le niveau de sévérité d'un dommage détecté et localisé. Différentes stratégies de quantification sont distinguées :

Approches par réduction de dimension Des méthodes de réduction de dimension sont appliquées aux DI. Quelques points sont utilisés pour l'apprentissage et une extrapolation est réalisée pour tenter de prédire la taille d'un endommagement qui aurait évolué [63]. La génération expérimentale des données d'apprentissage est un tâche complexe car il faut disposer d'un ensemble de coupons à endommager et maîtriser la taille et la sévérité de l'endommagement

Approche par l'analyse des images de localisation Les figures de localisation offrent une base intéressante pour déterminer la taille d'un dommage. Ainsi, [64] propose de calculer l'aire au dessus d'un seuil pour quantifier un dommage. Dans [47], un CNN analyse ces figures et détermine la taille du dommage.

Approche par modélisation physique Une compréhension fine de l'interaction du dommage avec les ondes permet d'évaluer la taille ou sa sévérité du dommage en déployant des stratégies de résolutions inverses s'appuyant sur des modèles analytiques [59].

1.3.3.7 Classification du dommage

Dans la plupart des méthodes de SHM, le type du dommage est supposé connu préalablement et les méthodes de détection, localisation et quantification sont optimisées pour ce type. L'identification du type de dommage est encore une question particulièrement ouverte et doivent également intégrer des connaissances fines sur le comportement des dommages. Quelques approches de classification par des méthodes d'apprentissage sont présentées dans la Section 3.2.3.

1.3.4 Verrous du SHM par ondes de Lamb

Le SHM fait l'objet d'une quantité importante de travaux depuis plusieurs décennies [65]. Des applications existent aujourd'hui en génie civil pour le contrôle de bâtiments, d'ouvrages d'arts, de routes ou de voies ferrées. En revanche, dans l'industrie aéronautique, le déploiement des avancées des laboratoires tarde à se faire. Le panorama des méthodes et des technologies met en lumière quelques verrous importants :

Validation sur des dommages artificiels Les dommages apparaissant dans les matériaux composites sont variés et ont des comportements complexes (voir la Section 1.1.2). Les systèmes SHM doivent être testés et validés sur des structures qui ont subis des endommagements réalistes avant d'envisager un déploiement industriel. Les dommages considérés dans ces travaux sont les délaminages car ce sont les principaux dommages repérés lors des CNDs usuels. Ils sont présents entre les couches des composites ce qui les rend particulièrement insidieux car ils sont indétectables par un simple contrôle visuel. La génération contrôlée de dommages dans les matériaux composites, et particulièrement de délaminage n'est pas facile ce qui limite considérablement le déploiement du SHM. En effet, de nombreux travaux contournent les difficultés pour générer des dommages dans les composites en utilisant des dommages artificiels dont le comportement reste éloigné des délaminages réels :

Aimants Positionnés de part et d'autre d'une structure, ils modifient localement ses propriétés, simulant un dommage [45, 66]. Très facile à mettre en place, réversible et peu coûteuse, cette méthode est répandue dans la littérature.

Ajouts de masse De manière similaire aux aimants, une masse est posée ou collée sur la structure [67].

Usinage Des trous, trous à fond plat et encoches sont réalisés par des opérations d'usinage pour modifier localement la structure [37, 68]. Ces opérations irréversibles peuvent s'avérer complexes et coûteuses pour des matériaux composites.

Inserts en téflon Une surface de téflon est insérée entre deux plis du composite lors du drapage [59, 69, 70]. Les plis n'adhèrent pas entre-eux localement, reproduisant l'effet d'un délaminage. Le téflon reste cependant entre les plis et peut interagir avec les ondes.

Impacts La structure subit un impact à l'aide d'une tour de chute proche des dommages réels, mais l'endommagement n'est pas totalement maîtrisé et il prend la forme d'une combinaison de dommages de différents types [45, 59, 71, 72].

Endommagement par fatigue La fatigue du matériau permet d'obtenir un dommage réel [59], mais dans ce cas l'endommagement n'est pas contrôlé et il est alors difficile de construire un plan d'expérience.

Le procédé de délaminages induits par des chocs lasers proposé dans le projet Monarque et présenté dans la Section 1.4 répond à ce verrou en permettant aux méthodes de SHM la possibilité d'être validées sur des délaminages maîtrisés et réalistes.

Évaluation des performances De manière analogue aux qualifications des CNDs, les procédures de SHM doivent être validées avant d'être déployées. L'évaluation des performances des systèmes de SHM est complexe. Il n'existe pas encore de méthodes ou de normes qui font consensus pour pouvoir comparer les différentes approches. De plus, contrairement aux CNDs, il n'existe pas de dommages de référence qui puissent être utilisés à la fois pour évaluer mais aussi calibrer les systèmes. Ce manque d'évaluation rigoureuse est un frein important au déploiement industriel des systèmes de SHM. Quelques indicateurs inspirés des CNDs connaissent aujourd'hui une relative popularité : la validation passe par le calcul de la Probabilité de Détection (*Probability of Detection* en anglais, PoD) pour la détection, de la Probabilité de Localisation (*Probability of Localisation* en anglais, PoL) [73] pour la localisation et de la Probabilité de Quantification (*Probability of Sizing* en anglais, PoS) pour la quantification [74]. À titre d'exemple, [67] fait une évaluation statistique d'une procédure de SHM par des ondes de Lamb : une plaque d'aluminium est équipée de 3 PZTs et un disque viscoélastique placé sur la plaque simule un dommage. La position de ce disque est modifiée suivant une grille fine ce qui permet d'obtenir une quantité importante de données pour déterminer la PoD et la PoL.

En raison du coût des approches expérimentales, l'obtention rigoureuse de ces probabilités est presque impossible. Une évaluation s'appuyant sur un plan d'expérience numérique est envisageable, mais le coût de calcul de ces modèles complexes reste un frein important. Il est alors proposé ici de faire appel à un métamodèle, une approximation d'un modèle numérique par des méthodes d'apprentissage s'appuyant sur des bases de données afin de prédire des signaux pour un grand nombre de configurations de dommage rapidement.

Une simulation complexe La simulation numérique d'une procédure de contrôle SHM est absolument nécessaire mais cela peut s'avérer complexe : des phénomènes multiphysiques apparaissent (piézoélectrique et vibratoire pour le cadre de la surveillance par des ondes de Lamb), les structures composites ont des comportements complexes et la modélisation du dommage est également un enjeu important. La modélisation analytique de la propagation des ondes de Lamb et de leur interaction avec le dommage est encore un problème scientifique ouvert. L'absence de modèle analytique fiable détériore les prédictions des méthodes de résolution inverse s'appuyant sur ces modèles. Là encore, un métamodèle précis construit à partir de données issues de simulations par éléments finis peut constituer une alternative intéressante. Le Chapitre 3 présente une approximation

Origine		CND	SHM
Vieillessement	Capteur	-	+
	Couplage	-	+
Domage	Forme	++	++
	Position	-	++
Conditions opératoires et environnementales	Chargement	-	++
	Chimique	+	++
	Humidité	+	++
	Pression	+	++
	Température	+	++
Facteur Humain	Interprétation	++	+
	Procédure de Contrôle	++	-
	Implémentation	-	+
Fabrication	Transducteurs	+	+
	Acquisition	+	+
	Cale étalon	+	+
Donnée	Transmission	-	+
	Stockage	-	+

TABLE 1.3 – Tableau comparatif des variabilités entre le SHM et les CNDs [74, 75]

du problème direct à l’aide de métamodèles tandis que le Chapitre 4 s’intéresse à la résolution du problème inverse.

Variabilités inhérentes à la technologie d’inspection par des ondes de Lamb Le réseau de PZTs collectant les données est implémenté sur la structure et le reste durant toute sa durée de vie. De nombreuses variabilités peuvent alors modifier la manière dont l’onde se propage dans la structure (Tableau 1.3). Une attention particulière a été donnée dans ces travaux à développer des méthodes prenant en compte les incertitudes sur les propriétés des matériaux et l’implémentation des capteurs. Cela garantit que les méthodes soient plus facilement réutilisables entre des structures similaires et tout au long de la vie d’une même structure.

1.4 Un procédé d’endommagement innovant : le projet Monarque

1.4.1 Contexte du projet

La validation des procédures et des dispositifs de SHM sur des dommages artificiels est un des principaux verrous identifiés en SHM (voir la Section 1.3.4). Les travaux de cette thèse s’inscrivent alors dans le cadre du projet FUI Monarque qui a pour objectif principal de fournir un démonstrateur industriel du procédé de délaminage induit par

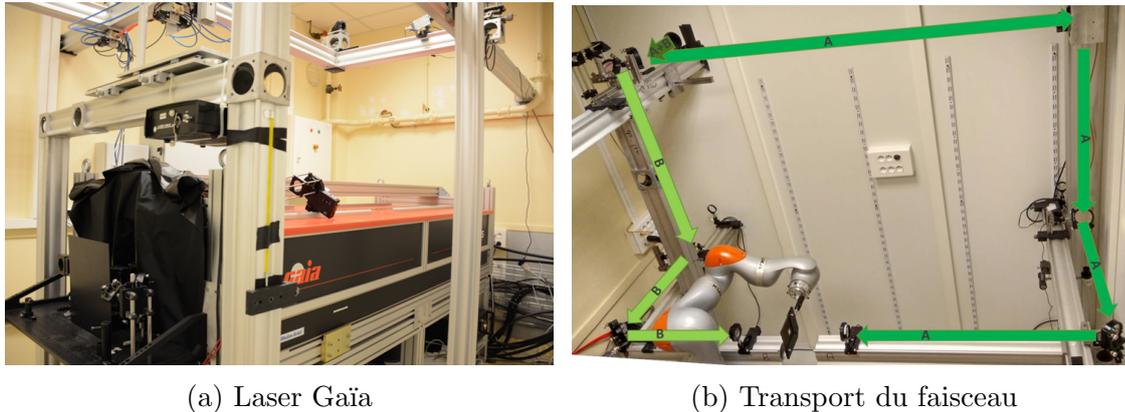


FIGURE 1.14 – La plateforme Héphaïstos du PIMM

des chocs lasers symétriques et suivi par ondes ultra-sonores. Ce projet fait suite à des travaux menés au PIMM qui ont montré l'efficacité de cette technique d'endommagement et les compétences du laboratoire pour sa mise en œuvre [8, 76]. Le choc laser a également été exploité pour développer une nouvelle méthode de CND des joints de colles [77]. Ces compétences permettent de regrouper un consortium de 8 partenaires industriels et académiques travaillant dans le secteur aéronautique :

Airbus et Safran Deux grands donneurs d'ordre de l'aéronautique européenne,

Testia France La filiale d'Airbus spécialisée dans les CND,

Thales Las France Le leader européen des lasers de puissance,

CEA DAM et PIMM (ENSAM) Deux laboratoires d'excellence internationale dans les thématiques d'interaction laser-matière et d'utilisation des ondes de choc,

RESCOLL et Imagine Optic Deux PME spécialisées dans les Composites à Matrice Organique (CMO) et les procédés de collage pour la première et dans la maîtrise des impulsions laser, de leur transport à leur mise en forme pour la seconde.

L'équipe DYSCO du PIMM est en charge du lot SHM du projet visant à valider l'utilité du procédé pour le SHM en fournissant des délaminages entièrement maîtrisés et les capacités du SHM par des ondes de Lamb pour suivre en temps réel un délaminage en cours de création par ce procédé.

1.4.2 Délaminages induits par des chocs lasers symétriques

La plateforme Héphaïstos du PIMM visible Figure 1.14 équipée d'un laser Gaïa de Thales et schématisée Figure 1.15 est prise en exemple afin d'illustrer la mise en place du procédé et les principes généraux qui permettent d'appréhender la physique du choc laser. Le procédé se décompose en trois phases distinctes où des phénomènes différents ont lieu :

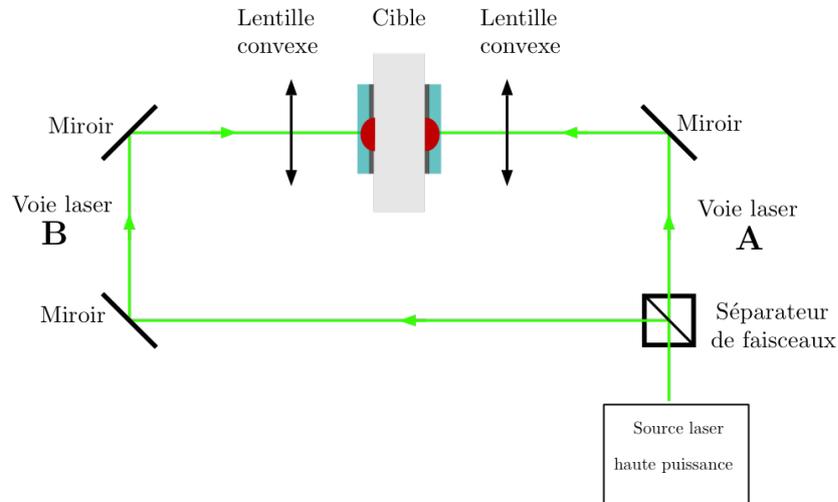


FIGURE 1.15 – Schéma de principe du choc laser symétrique

1. la génération d'un rayonnement laser,
2. l'interaction laser matière et la génération d'onde de choc,
3. la propagation d'onde de choc au sein de la cible et la génération du dommage.

Génération des rayonnements lasers Les rayonnements sont générés par le laser qui possède une énergie maximale de 14J pour un rayonnement vert. Le laser possède deux voix distinctes, deux rayons sont générés avec chacun une polarisation différente. La durée et la forme de l'impulsion sont déterminées au sein de la cavité laser. Les rayonnements sont alors fortement amplifiés à travers une série d'amplificateur qui leur donnent leurs énergies. En sortie du laser, les rayons sont dirigés à l'aide d'une série de miroir de part et d'autre de la cible. Leurs polarisations permet à un séparateur de dissocier les deux faisceaux. Un premier rayon emprunte la voie A et irradie la face avant de la cible, tandis qu'un second rayon emprunte voie B et irradie la face arrière. La Figure 1.15 illustre ce procédé. Un délai peut être imposé entre les deux voies au besoin. En fin de parcours, des lentilles convergentes focalisent les faisceaux sur des surfaces réduites, augmentant ainsi leurs intensités.

Interaction laser-Matière Un dépôt d'aluminium est préalablement déposé de part et d'autre de la cible afin d'être utilisé comme un milieu sacrificiel. Lorsque le faisceau arrive sur le dépôt, celui-ci est alors sublimé en plasma. Un milieu confinant liquide (de l'eau) ou solide (un adhésif transparent) assure l'augmentation de la pression du plasma. Cette augmentation rapide de pression sur les faces de la cible génère deux ondes de choc qui se propagent dans le matériau. Une fois le rayonnement terminé, le plasma se refroidit subitement générant deux ondes de détente qui se propagent à leur tour.

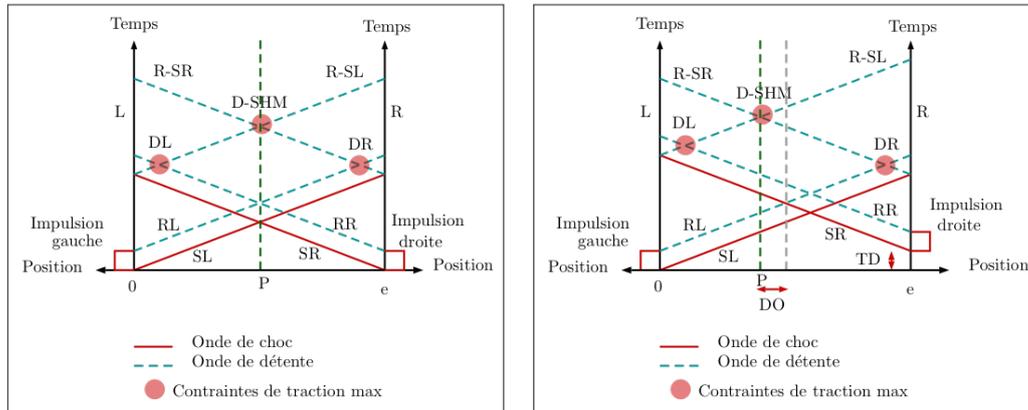


FIGURE 1.16 – Diagramme XT des chocs symétriques [8]

Propagation des ondes de choc Suite à la sublimation en plasma de l'aluminium sur chaque face de la cible, deux ondes de choc se déplacent dans l'épaisseur du matériau, dans des directions opposées. Elles sont converties en ondes de détente lors de la réflexion sur une face de la cible. Ces deux ondes de détente se croisent alors au cœur du matériau cible (Point D-SHM de la Figure 1.16) générant une forte contrainte en traction. Si l'énergie de l'impulsion laser est suffisante, cette concentration de contrainte peut rompre la couche de résine entre les plis, et ainsi être à l'origine d'un délaminage. L'onde de choc réfléchie croise également les ondes de détente du plasma sur l'extérieur de la cible (Point D-R et D-G de la Figure 1.16). Les contraintes de traction sont également importantes sur ces deux localisations, pouvant créer un délaminage que l'on appellera dommage de peau. Le seuil pour voir apparaître les dommages de peau est plus élevé que pour les dommages au cœur de la cible. En choisissant judicieusement l'énergie des impulsions lasers, il est alors possible d'avoir un délaminage uniquement au cœur. En imposant un délai de quelques nanosecondes entre les deux tirs, il est également possible de déplacer la localisation de l'intersection des ondes de détente, comme le montre la Figure 1.16. Ce procédé de choc laser par tir symétrique offre alors la possibilité de contrôler la profondeur du délaminage. La position du délaminage est contrôlée en positionnant le faisceau et son étendue en réalisant plusieurs tirs contigus.

1.4.3 Applications

Le procédé peut connaître des applications industrielles diverses :

Fabrication de cales étalon pour les CND Lors des procédures de CND, il est nécessaire d'utiliser des cales étalons afin de calibrer l'appareil de mesure. Ces cales comportent des dommages artificiels produits par usinage (trou, trou à fond plats, encoches ou insert

en téflon) peu représentatifs d'un vrai délaminage. Ce nouveau procédé propose alors de fournir des cales étalons possédant un délaminage réaliste qui pourront être utilisées dans des nouvelles procédures de CND mais aussi dans des formations.

Désassemblage des pièces aéronautiques À plus long terme, lorsque le procédé sera mieux maîtrisé, il sera envisageable d'utiliser le choc laser pour rompre la couche de colle qui lie un matériau composite avec un matériau métallique. Ces structures complexes sont de plus en plus présentes dans l'industrie aéronautique avec, par exemple, les bords d'attaque en alliage de titane collés sur les aubes de turbines (Figure 1.17). Il sera alors possible de décoller des pièces détériorées pour les remplacer sans utiliser de produit chimiques dangereux.



FIGURE 1.17 – Exemple d'un assemblage de matériaux composites et de métal : une aube de turbine de Safran³

Création de dommage maîtrisé pour le SHM La génération de délaminages entièrement maîtrisés au sein des matériaux composites permet de contourner le premier verrou du SHM identifié dans la Section 1.3.4 : la validation des procédures sur des dommages réels et non sur des dommages artificiels. Ces délaminages permettent de mieux comprendre leurs interactions avec les ondes de Lamb afin d'améliorer les modèles numériques et analytiques. Avec ce procédé, il est également possible de calibrer les algorithmes et les méthodes sur des coupons tests, à l'image des cales étalons utilisées dans les CNDs.

1.5 Représentation du SHM par un système

Le système SHM Un dispositif de SHM de surveillance par onde de Lamb implémenté sur une structure doit être vu comme une boîte noire avec de nombreuses inconnues [78] : il est difficile de savoir si le système est linéaire ou non, quels types de non-linéarités le décrivent, etc. La représentation du système par des relations entrées/sorties (Figure 1.18)

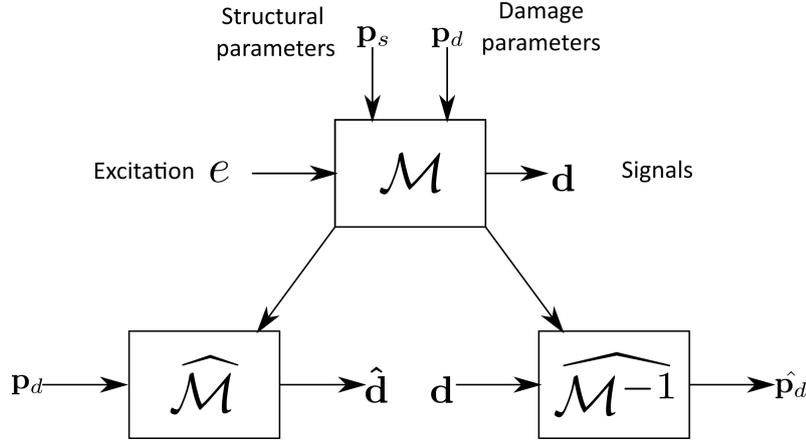


FIGURE 1.18 – Schéma entrée sortie du problème direct, de son approximation par un métamodèle $\widehat{\mathcal{M}}$ et de la résolution du problème inverse par un modèle $\widehat{\mathcal{M}}^{-1}$

est alors nécessaire pour répondre au besoin de métamodèle identifié dans les verrous de la Section 1.3.4. Il s'agit d'interroger un système modélisé mathématiquement par un modèle \mathcal{M} ayant pour paramètres structurels \mathbf{p}_s et paramètres d'endommagement \mathbf{p}_d à l'aide d'une excitation \mathbf{e} en observant les signaux \mathbf{d} . Le modèle mathématique \mathcal{M} remplace le système SHM réel. Les paramètres inconnus sont identifiés en interrogeant le système. À l'état sain, il est possible de déterminer les vitesses de groupes, l'atténuation de l'onde, la température de la structure, l'état des capteurs, etc. Les incertitudes sur les paramètres structurels sont alors réduites afin de se concentrer sur les paramètres qu'un système SHM cherche à identifier : les paramètres d'endommagement.

Le problème direct La prédiction des observations \mathbf{d} à partir d'une excitation \mathbf{e} du système \mathcal{M} et avec l'ensemble des paramètres est communément appelé résolution du **problème direct**. Le modèle \mathcal{M} est le plus souvent un modèle numérique par éléments finis, un modèle physique analytique ou bien un modèle appris à partir de donnée. On dit alors que \mathcal{M} est un jumeau numérique ou physique du système réel. La résolution du problème direct prend la forme mathématique suivante :

$$\text{Trouver } \mathbf{d} \in \mathcal{D} / \mathbf{d} = \mathcal{M}(\mathbf{e}, \mathbf{p}_d, \mathbf{p}_s), (\mathbf{e} \in \mathcal{E}, \mathbf{p}_d \in \mathcal{P}_d, \mathbf{p}_s \in \mathcal{P}_s) \quad (1.2)$$

La résolution du problème direct en SHM reste un sujet de recherche important et loin d'être entièrement résolu : les modèles analytiques de propagation des ondes de Lamb et d'interaction avec le dommage sont incomplets, ne prenant en compte qu'un ou deux modes et modélisant mal les réflexions des ondes sur les différents interfaces des structures [59]. Les modèles numériques par éléments finis sont plus fiables bien qu'il subsiste encore de nombreuses incertitudes sur la modélisation des endommagements (voir Chapitre 2) et des difficultés à recalibrer les modèles.

Le problème inverse Le principal objectif du SHM est de parvenir à identifier les paramètres du dommage à partir des signaux mesurés. Il s'agit là de la résolution d'un **problème inverse** : cette fois la sortie du système \mathbf{d}_{obs} est connue ainsi que sa sollicitation s mais certains de ses paramètres \mathbf{p} sont recherchés. En s'appuyant sur le modèle direct, la résolution inverse devient alors :

$$\text{Trouver } \mathbf{p}_d \in \mathcal{P}_d / \mathbf{d}_{\text{obs}} = \mathcal{M}(\mathbf{e}, \mathbf{p}_d, \mathbf{p}_s), (\mathbf{e} \in \mathcal{E}, \mathbf{p}_d \in \mathcal{P}_d, \mathbf{p}_s \in \mathcal{P}_s) \quad (1.3)$$

Il peut être également possible de trouver un modèle \mathcal{M}^{-1} qui résout le problème inverse tel que :

$$\text{Trouver } \mathbf{p}_d \in \mathcal{P}_d / \mathbf{p}_d = \mathcal{M}^{-1}(\mathbf{e}, \mathbf{d}^{\text{obs}}, \mathbf{p}_s), (\mathbf{e} \in \mathcal{E}, \mathbf{d}^{\text{obs}} \in \mathcal{D}, \mathbf{p}_s \in \mathcal{P}_s) \quad (1.4)$$

Une résolution du problème inverse à l'aide d'une modélisation par des éléments finis est envisageable mais le coût de calcul de ces simulations complexes est un frein important. Une autre approche consiste à utiliser des modèles analytiques [59, 79, 80] mais la faible précision de ces modèles détériore les prédictions des méthodes de résolution inverse.

Les niveaux du SHM, un problème bien posé ? Hadamard introduit dès 1902 la notion de problème bien posé et mal posé [81]. Un problème est dit bien posé si et seulement si :

- 1. Existence** Le problème a une solution,
- 2. Unicité** La solution est unique,
- 3. Stabilité** Des petites perturbations sur les données ne causent que des petites déviations de la solution.

Si l'une de ces trois conditions n'est pas satisfaite alors le problème sera dit mal posé. Dans la réalité, les problèmes sont souvent mal posés et il est alors nécessaire de faire appel à des méthodes de régularisation pour contraindre l'espace des solutions possibles et ainsi faciliter la résolution inverse. Les méthodes quadratiques ($L2$) furent les premières régularisations proposées et elles ont progressivement évolué. Aujourd'hui, des contraintes sous de nombreuses formes sont ajoutées pour régulariser le problème inverse et faciliter sa résolution. Lorsque des connaissances *a priori* sont connues sur les données, il est possible de les inclure dans la régularisation. Il est intéressant de se demander si le problème à résoudre en SHM est un problème bien ou mal posé. En SHM tout comme en CND il semble peu probable que le problème respecte les trois conditions précédentes et soit bien posé.

L'existence de la solution ne pose pas de problème particulier. La question de l'unicité est moins évidente : il est envisageable que plusieurs configurations de dommage donnent

lieu aux mêmes signaux, rendant alors la résolution inverse impossible. En multipliant le nombre de capteurs, en enrichissant les sollicitations avec plusieurs types de signaux, en effectuant des mesures sur une large plage de fréquences, il devient possible de s'approcher d'une solution unique. La condition de stabilité de la solution dans le cadre du SHM par onde de Lamb est plus complexe : les signaux mesurés sont très sensibles aux propriétés mécaniques et aux conditions environnementales et opératoires. La vitesse rapide des ondes dans la structure implique qu'une petite variation modifie fortement le signal mesuré. Un bruit de mesure est toujours présent et des problèmes d'alignements des signaux temporels peuvent apparaître. Le déploiement de méthodes statistiques avec des répétitions des mesures permet tout de même de garantir plus de stabilité. L'utilisation de connaissances physiques sur la propagation d'onde comme dans certaines des méthodes décrites dans la Section 1.3.3 contribue également à mieux poser le problème.

1.6 Contributions

Les travaux présentés dans ce manuscrit ont donc cherché à développer des stratégies d'apprentissage permettant la localisation et la quantification d'un dommage malgré des incertitudes sur certaines des propriétés mécaniques et géométriques des structures, comme les modules d'Young des matériaux et la position des éléments piézoélectriques. Les contributions de ces travaux peuvent se regrouper en quatre catégories et seront détaillées dans les chapitres ultérieurs.

1. Génération de dommage Lors d'une campagne expérimentale restreinte, des structures intelligentes équipées de PZTs ont été endommagées par des chocs lasers dans le but de démontrer l'intérêt du choc laser pour le SHM, de sélectionner les méthodes les plus performantes parmi les méthodes usuelles de SHM à l'aide d'ondes de Lamb et de valider un modèle par éléments finis fidèle.

2. Métamodèle Ce modèle a servi à générer des bases de données numériques contenant des signaux pour une large gamme de configurations de dommage. À partir de ces données, des métamodèles sont proposés pour approximer la résolution du problème direct et prédire de nouvelles configurations d'endommagement instantanément.

3. Résolution inverse Ces mêmes bases de données ont servi à créer des modèles d'apprentissage profond robustes permettant la résolution du problème inverse en localisant et quantifiant des endommagements. Cette stratégie de résolution est comparée avec des résolutions inverses exploitant les métamodèles directs.

4. Transfert d'apprentissage Enfin, une stratégie originale d'apprentissage profond par transfert s'appuyant sur la théorie du transport optimal est proposée afin de compenser des variations structurelles et environnementales entre deux structures

voisines.

2

Endommagement de structures intelligentes et modélisation numérique

Résumé

Les structures en matériaux composites fournies par les partenaires du projet Monarque ont été équipées d'un réseau de transducteurs piézoélectriques puis endommagées par le procédé de choc laser symétrique. Une évaluation des méthodes classiques de SHM décrites dans le chapitre précédent sur ces délaminages réalistes et entièrement maîtrisés est proposée. Les données collectées sont utiles pour valider une modélisation par éléments finis des structures équipées de leurs transducteurs. Ce modèle permet alors de générer des bases de données numériques qui complètent les données expérimentales pour le développement de stratégies d'apprentissage.

Sommaire

2.1	Introduction	36
2.2	Suivi de l'endommagement d'une structure intelligente	36
2.2.1	Description des structures avec leurs transducteurs	36
2.2.2	Mesures sur les structures X11 et X12 à l'état sain	39
2.2.3	Endommagements par des chocs lasers	40
2.2.4	Évaluation des méthodes classiques de SHM sur les dommages réels	41
2.2.5	Discussions sur l'approche expérimentale	43
2.3	Modélisation numérique des structures intelligentes	43
2.3.1	Description de la modélisation par éléments finis	43
2.3.2	Modèle de la Structure X11	46
2.4	Définitions des cas d'études pour les stratégies d'apprentissage	47
2.4.1	Poutre	48
2.4.2	Petite plaque - S2	49
2.4.3	Grande plaque - S11	51
2.4.4	Structure courbe - C	52
2.5	Conclusion	53

2.1 Introduction

Contexte Les verrous identifiés dans la Section 1.3.4 mettent en lumière les limites des approches expérimentales usuelles pour valider les systèmes de SHM avec des endommagements des matériaux composites difficiles à maîtriser et peu représentatifs de la réalité industrielle. Le procédé de délaminage induits par chocs lasers proposé par le projet Monarque permet alors de répondre à ce besoin.

Objectifs L'objectif est double ici : montrer la bonne maîtrise du procédé de chocs laser pour générer des délaminages réalistes et l'efficacité des méthodes de SHM à base d'ondes de Lamb pour caractériser ces délaminages. Dans ce but, les industriels du projet ont fourni des structures à équiper de transducteurs et à endommager. En raison des contraintes liées à la pandémie de Covid-19, des retards et des problèmes d'approvisionnement ont imposé une diminution des ambitions de cette campagne expérimentale. Les résultats expérimentaux sont alors complétés par des structures numériques pour créer des bases de données nécessaires au déploiement de stratégies d'apprentissage (Tableau 2.1).

TABLE 2.1 – Dénomination des structures étudiées

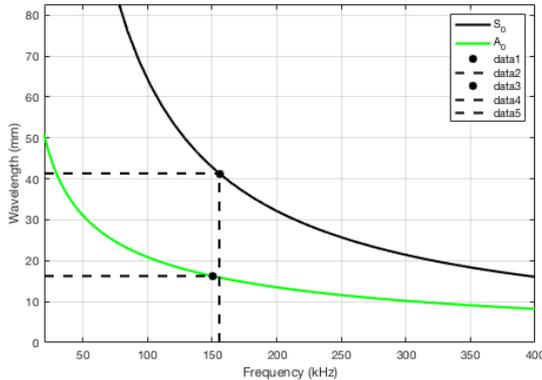
	Type	Géométrie	Dimensions	Nombre PZTs
X11	Exp	Plaque	$600 \times 600 \times 2.6mm^3$	5
X12	Exp	Plaque	$600 \times 600 \times 2.6mm^3$	5
Poutre	Num.	Poutre	$2000 \times 1 \times 2.6mm^3$	2
S2	Num.	Plaque	$300 \times 300 \times 2.6mm^3$	3
S11	Num.	Plaque	$600 \times 600 \times 2.6mm^3$	5
C	Num.	Coque	$500 \times 200 \times 2.6mm^3$	4

2.2 Suivi de l'endommagement d'une structure intelligente

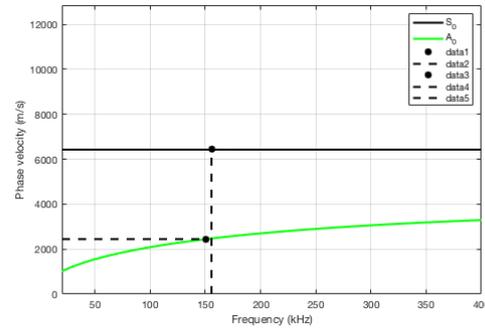
Le surveillance de deux plaques expérimentales similaires X11 et X12 fournies par Safran est proposée dans cette section pour évaluer les performances et les limites du SHM par des ondes de Lamb. L'implémentation des PZTs qui transforme une simple plaque en une structure intelligente doit se faire en prenant en compte sa géométrie, ses propriétés mécaniques et le dommage ciblé.

2.2.1 Description des structures avec leurs transducteurs

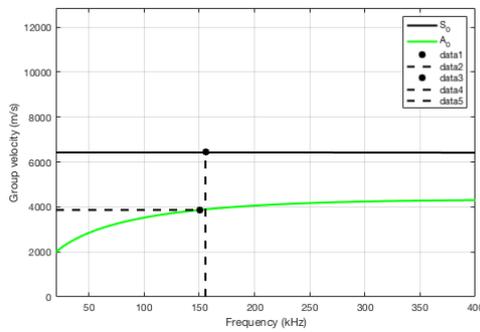
Géométrie et matériau Les deux plaques X11 et X12 ont des dimensions similaires $600 \times 600mm^2$ et une épaisseur de $2,4mm$. Elles sont fabriquées dans un composite



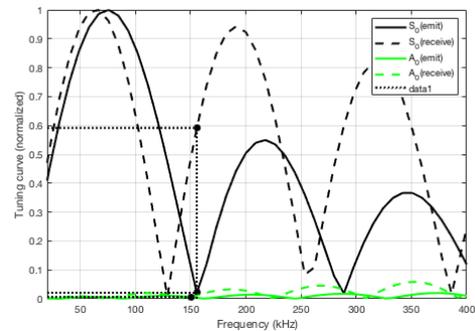
(a) Longueur d'onde en fonction de la fréquence



(b) Vitesse de phase en fonction de la fréquence



(c) Vitesse de groupe en fonction de la fréquence



(d) Tuning Curves

FIGURE 2.1 – Courbes de dispersion du matériau

stratifié de 8 plis d'un matériau tissé 2D (Hexcel AS4/8552 PW Satin de 5) courant dans l'industrie aéronautique avec un empilement équilibré $[0/45/0/45/45/0/45/0]$. Les propriétés mécaniques d'un pli sont visibles dans le Tableau 2.3.

Domage cible Un choc laser induit dans le matériau un délaminage approximativement de la même taille que la tâche focale du laser. Sur la plateforme Héphaïstos, la tâche focale a un diamètre avoisinant les 4mm, ce qui impose la limite inférieure de la taille du dommage ciblé. Pour des dommages de taille plus importante, plusieurs chocs contigus sont nécessaires. Les constructeurs aéronautiques détectent par UT les délaminages dont le diamètre est supérieur à 15mm lors de la fabrication. Les délaminages recherchés par le dispositif SHM à implémenter ont alors des tailles caractéristiques comprises entre 5mm et 15mm.

Courbes de dispersion Les courbes de dispersion calculées numériquement pour le matériau de ces structures permettent de visualiser les modes qui parcourent la plaque à une fréquence donnée et donnent une approximation des vitesses de groupe des ondes de

TABLE 2.2 – Position des capteurs sur la plaque X11 et X12

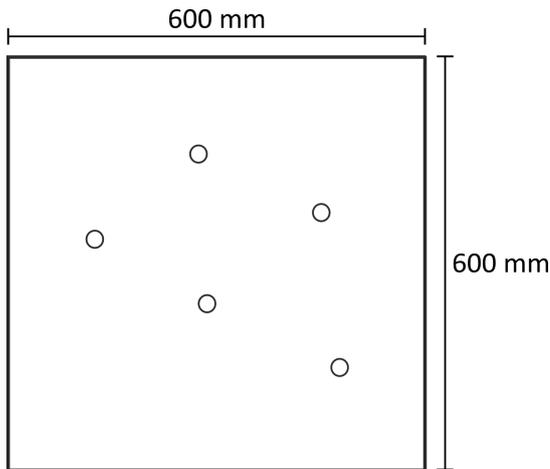
	PZT 1	PZT 2	PZT 3	PZT 4	PZT 5
Position x (mm)	473	286	103	456	265
Position y (mm)	166	251	331	376	456

Lamb (Figure 2.1). Le calcul s'appuie sur la résolution de l'équation de Rayleigh-Lamb [82]. Pour rappel, les ondes de Lamb sont dispersives (la vitesse de groupe dépend de la fréquence pour certains modes) et multimodales (plusieurs modes parcourent la structure à une fréquence donnée). Afin d'obtenir un signal plus facilement exploitable, il est souhaitable de limiter le nombre de modes qui se propagent dans la structure en cours d'inspection. Pour cela, les fréquences d'excitation sont choisies pour ne solliciter idéalement que le premier mode symétrique (noté S_0) et le premier mode antisymétrique (noté A_0). Les courbes de dispersion 2.1 montrent qu'une fréquence d'excitation inférieure à 400 kHz convient pour ne solliciter que ces deux modes. De plus, le mode S_0 est le plus rapide et n'est pas dispersif sur cette plage de fréquence (Figure 2.1c).

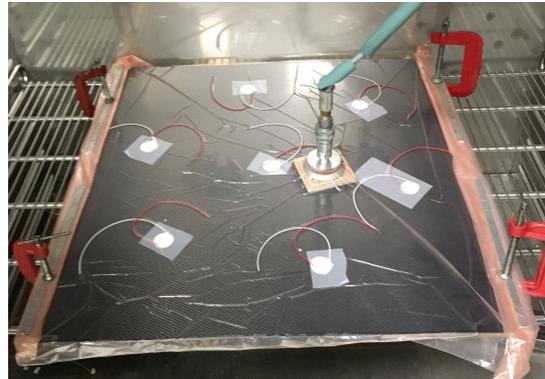
Choix des PZT et de la plage de fréquence Une règle empirique permet d'établir que les modes les plus sensibles aux dommages ont une longueur d'onde approximativement égale au double de la taille du dommage [83]. Les courbes de dispersion indiquent qu'une fréquence de l'onde comprise entre 50 kHz et 300 kHz convient pour interagir avec les dommages cibles. De plus, les transducteurs doivent avoir un diamètre du même ordre de grandeur que la longueur d'onde pour émettre et recevoir correctement un signal. Ainsi, les PZTs NCE51 de 25 mm de diamètre fournis par Noliac¹ conviennent comme éléments actifs et passifs. Les *tuning curves* (Figure 2.1d) permettent d'estimer les capacités du PZT à émettre et recevoir une onde à une fréquence donnée. Sur la plage de fréquence choisie, il n'y a pas de difficultés particulière.

Implémentation des transducteurs Les propriétés mécaniques du matériau et l'empilement équilibré induisent un comportement global quasi-isotrope des plaques. Les vitesses de propagation ainsi que l'atténuation de l'onde sont invariantes quelque soit la direction de propagation. La géométrie de la structure étant simple et la surface à couvrir faible, un réseau trapézoïdal de 5 PZTs permet d'obtenir un nombre important de données en parcourant le potentiel dommage dans toutes les directions. Un schéma de ce placement peut être vu Figure 2.2a et les coordonnées Tableau 2.2. Ce type de placement a montré précédemment son efficacité dans les travaux de [8, 40]. La distance entre les éléments piézoélectriques voisins est de 210 mm pour éviter une trop grande proximité avec les bords de la plaque et limiter l'amortissement entre deux transducteurs. Ces données

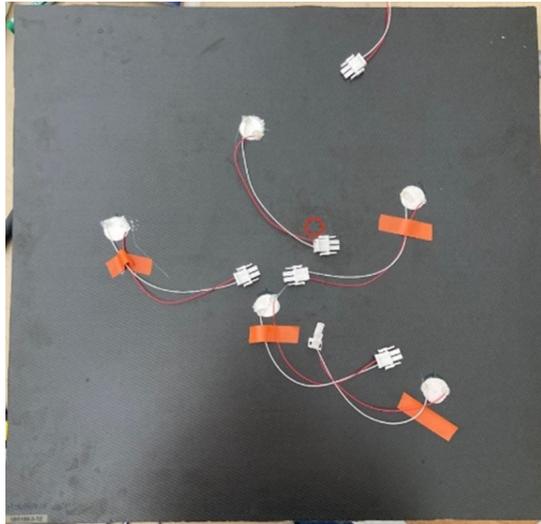
1. Les propriétés de ce matériau sont présentées sur le site de Noliac



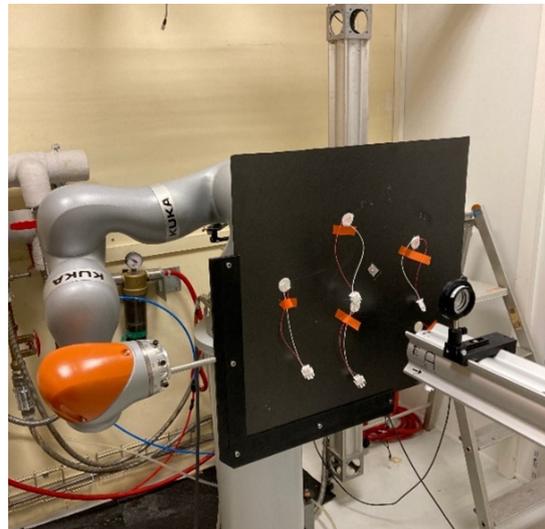
(a) Proposition de placement des PZTs sur la structure X11



(b) Collage des PZTs sous vide dans une étuve



(c) Structure X11 équipée de PZTs



(d) Structure X11 en cours d'endommagement dans la plateforme Héphaïstos

riches sont utiles pour bien caractériser le dommage et recalculer le modèle numérique de la plaque avec précision. Les PZTs sont intégrés sur la structure à l'aide de la colle Epoxy Loctite EA 9492 qui offre un bon couplage avec la plaque et résiste aux sollicitations des PZTs. Ils sont maintenus en position à l'aide d'une poche sous vide durant 3h pour la polymérisation dans un étuve à 80°C.

2.2.2 Mesures sur les structures X11 et X12 à l'état sain

Chaîne d'acquisition et d'excitation La structure équipée de ses transducteurs devient véritablement intelligente lorsqu'elle est reliée à la chaîne d'acquisition et d'actionnement décrite dans la Section 1.3.3.2 et visible Figure 1.11b. Le signal d'excitation est un sinus fenêtré de 5 cycles dont la fréquence centrale varie entre 50kHz et 300kHz avec

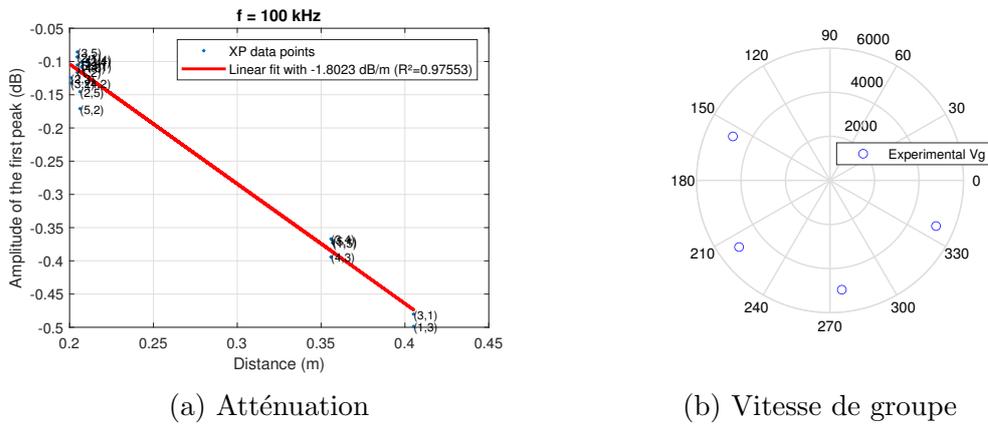


FIGURE 2.3 – Caractérisation expérimentale du premier paquet d’ondes dans la structure X11 à 100kHz

un pas de 10kHz. Chacun des PZTs est utilisé alternativement en actionneur et les mesures échantillonnées à 2MHz sont répétées 10 fois permettant de déployer des analyses statistiques.

Calcul des vitesses de groupe Les vitesses de groupe sont calculées en mesurant les temps de vol du premier paquet d’ondes. Lorsqu’il est utilisé en mode actionneur, la position du PZT central permet d’obtenir les vitesses de groupe dans chacune des directions du matériau. La vitesse de groupe dépend des propriétés mécaniques de la structure, plus particulièrement des modules d’Young et de la masse volumique. Les valeurs des vitesses de groupes sont visibles dans la Figure 2.3b. La vitesse de groupe est alors invariante suivant l’orientation de la propagation, à une valeur proche de 5000 m/s, le matériau étudié est bien quasi-isotrope mais cette valeur est inférieure à celle prédite par le calcul théorique des courbes de dispersion ce qui suggère un écart dans les propriétés mécaniques du matériau.

Calcul de l’atténuation L’atténuation est calculée en mesurant la valeur maximale du premier paquet d’ondes des signaux reçus sur chaque PZT. La Figure 2.3a montre la valeur de l’atténuation en dB pour chaque couple de PZT. Une régression linéaire estime l’atténuation à environ $1.9dB/m$. Cette valeur est relativement faible ce qui garantit un niveau de bruit acceptable pour les mesures et valide l’écart choisi entre les PZTs dans le Paragraphe 2.2.1.

2.2.3 Endommagements par des chocs lasers

Les deux plaques équipées de leurs transducteurs sont alors endommagées par des chocs laser symétriques (voir Section 1.4). Ce procédé offre une très grande liberté dans

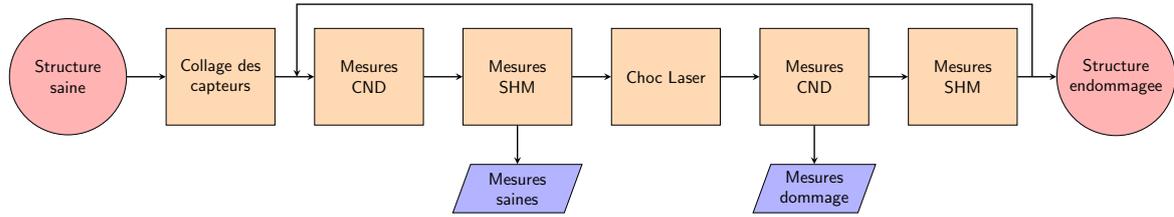


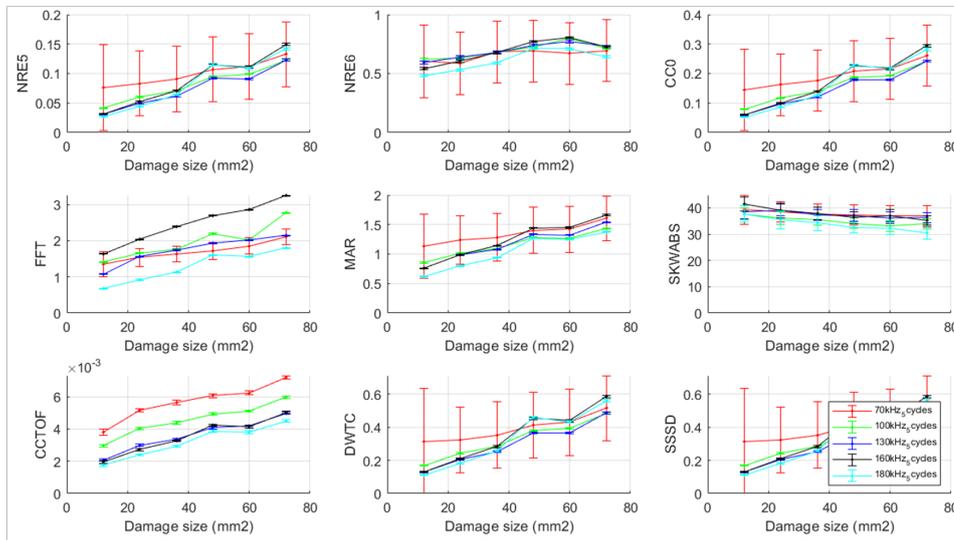
FIGURE 2.4 – Processus d’endommagement et d’inspection des structures

la création des délaminages, qui peuvent alors prendre des formes variées. La plaque X11 subit un endommagement de 6 tirs successifs et contiguës donnant au dommage une forme circulaire. Des mesures de SHM et de UT sont menées à l’état sain puis après chacun des tirs permettant de suivre l’évolution de l’endommagement. La procédure d’endommagement et de contrôle est schématisée Figure 2.4. La plaque X12 subit un dommage linéaire de 5 tirs avec un processus d’acquisition similaire. Les tirs sont réalisés de manière symétriques et synchrones afin de positionner le délaminage au niveau des plis centraux. L’énergie du laser est fixée à 4.5J pour chacun des tirs. Les UTs réalisés permettent de vérifier que l’endommagement a correctement eu lieu. Le délai entre chaque tir est d’environ une heure à cause des mesures SHM réalisées sur une large plage de fréquences d’excitation. Les résultats des C-SCANS sont présentés Figure 2.7. Les endommagements sont clairement visibles pour les deux plaques. Chacun des tirs apparait nettement : le dommage n’est pas uniforme mais prend la forme d’une grappe de délaminages proches les uns des autres.

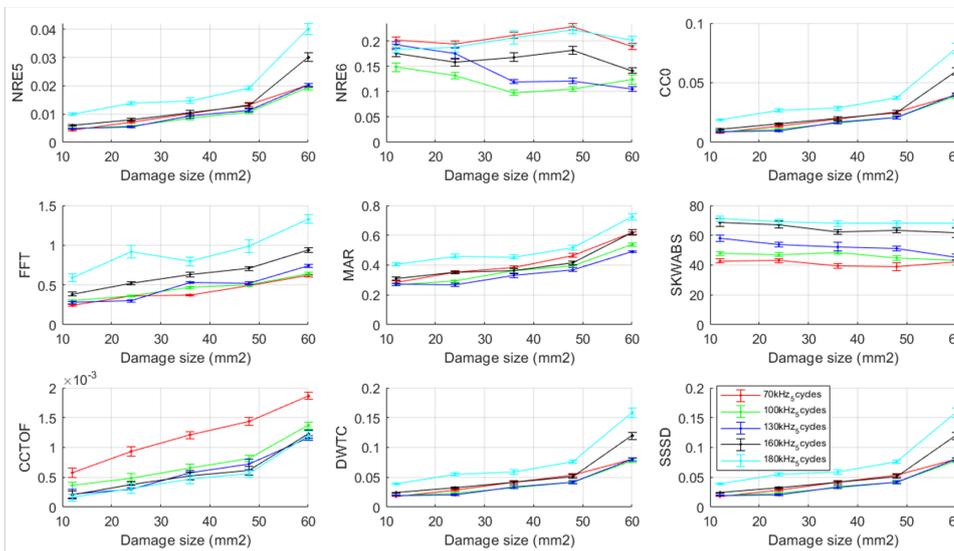
2.2.4 Évaluation des méthodes classiques de SHM sur les dommages réels

Détection Les DIs (dont les formules sont présentées en Annexe A) sont calculés après chacun des tirs pour les deux endommagements réalisés. Les DIs évoluant de manière monotone avec un faible écart type sont retenus (Figure 2.5). Sur ces figures, la taille du dommage est approximée en supposant que chacun des tirs génère un délaminage dont la surface est égale à celle de la tache focale du laser (4mm de diamètre). Cette hypothèse est validée par les C-SCAN des endommagements (Figures 2.7). Les évolutions monotones des DIs avec le nombre de tirs suggèrent que la structure intelligente est sensible à ces petits délaminages. Le choix des transducteurs, de leur placement et des plages de fréquence d’excitation est valide et l’exploitation des mesures de SHM est suffisante pour s’assurer qu’un endommagement a été induit par le choc laser.

Localisation Les algorithmes classiques de localisation en SHM décrits au chapitre précédent dans la Section 1.3.3.5 sont évalués sur ces dommages réalistes. Plusieurs jeux



(a) Structure X11



(b) Structure X12

FIGURE 2.5 – DIs retenus suite à leurs évaluations sur les délaminages réels

de paramètres sont testés pour chacun des algorithmes sur toutes les fréquences d'excitation utilisées lors des mesures. La Figure 2.8 montre que plusieurs algorithmes ne parviennent pas à localiser avec précision ces délaminages. La méthode DAS présente les résultats les plus défavorables. Quelques algorithmes obtiennent cependant de bons résultats pour la localisation, notamment le TOA et le TDOA dans des versions probabilistes qui parviennent à localiser les dommages avec une erreur moyenne de 25mm (Figure 2.8).

2.2.5 Discussions sur l'approche expérimentale

La détection est facile, plusieurs DIs sont retenus pour cette tâche. Leurs monotonies avec la croissance du dommage en font des indicateurs pertinents pour le développement de stratégies de quantifications. Concernant la localisation, beaucoup d'algorithmes sont proposés avec un nombre important de paramètres à déterminer. Sans connaître la position du dommage au préalable, il est difficile de savoir exactement quel jeu de paramètres est le plus adapté. Dans un contexte industriel, il sera donc nécessaire de faire appel à des dommages artificiels pour calibrer les algorithmes sur une structure équipée de PZTs.

Les C-SCANs des délaminages (Figure 2.7) obtenus lors des UTs montrent que les CNDs restent plus précis que les inspections menées par notre système SHM. En revanche, ce type de CNDs doit se faire en piscine par un système robotisé. Le SHM apporte alors une plus-value importante en proposant des contrôles automatisés sur une structure en cours d'endommagement.

2.3 Modélisation numérique des structures intelligentes

2.3.1 Description de la modélisation par éléments finis

Environnement de simulation L'ensemble du procédé d'inspection par des ondes de Lamb (du signal d'excitation produit par le générateur de tension aux signaux mesurés sur chacun des PZTs en passant par l'interaction entre le dommage et l'onde) est simulé. Ces simulations multi-physiques sont réalisées à l'aide du logiciel SDT développé par SDTools². Cette modélisation par éléments finis correspond au modèle \mathcal{M} du système décrit dans la Section 1.5 et schématisé Figure 1.18. La sollicitation prend la forme d'un signal envoyé au PZT fonctionnant en mode actionneur. Les paramètres \mathbf{p}_s permettent de décrire la structure (géométrie, propriétés mécaniques, etc) et les paramètres \mathbf{p}_d décrivent le dommage (taille, position, sévérité, etc). En sortie, la simulation fournit les signaux mesurés sur chacun des capteurs.

2. Voir le site de la société : <https://www.sdtools.com/>

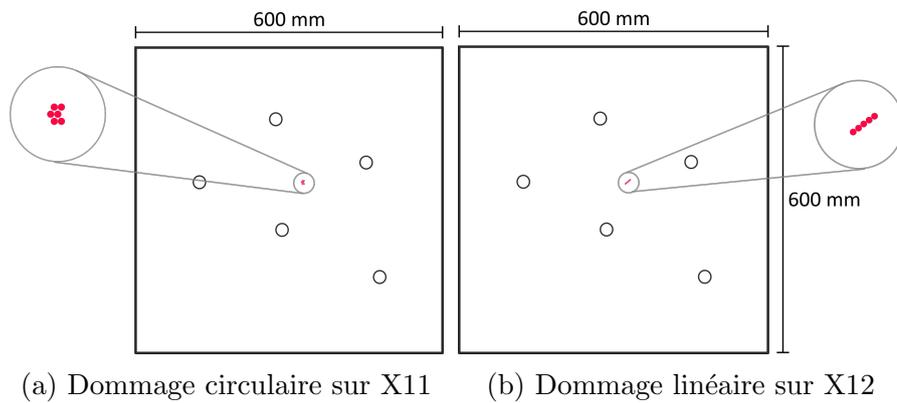


FIGURE 2.6 – Dommages cibles

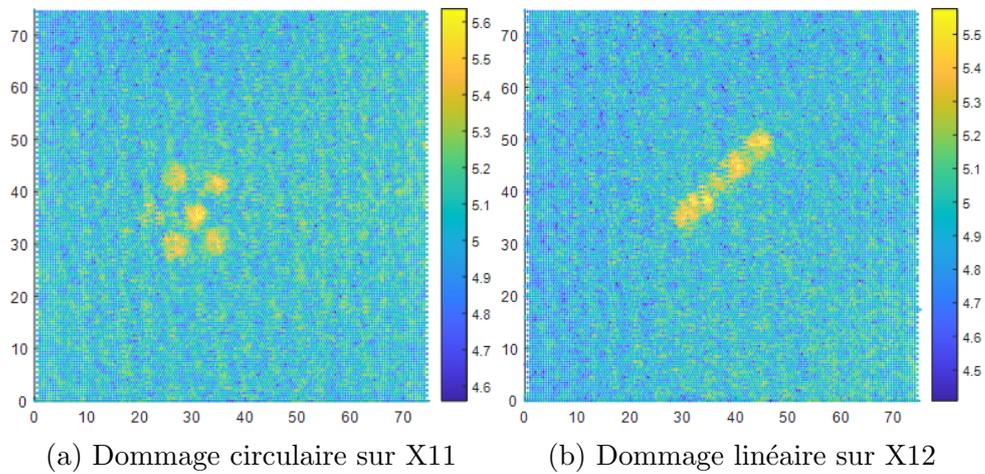


FIGURE 2.7 – C-SCAN des endommagements réalisés

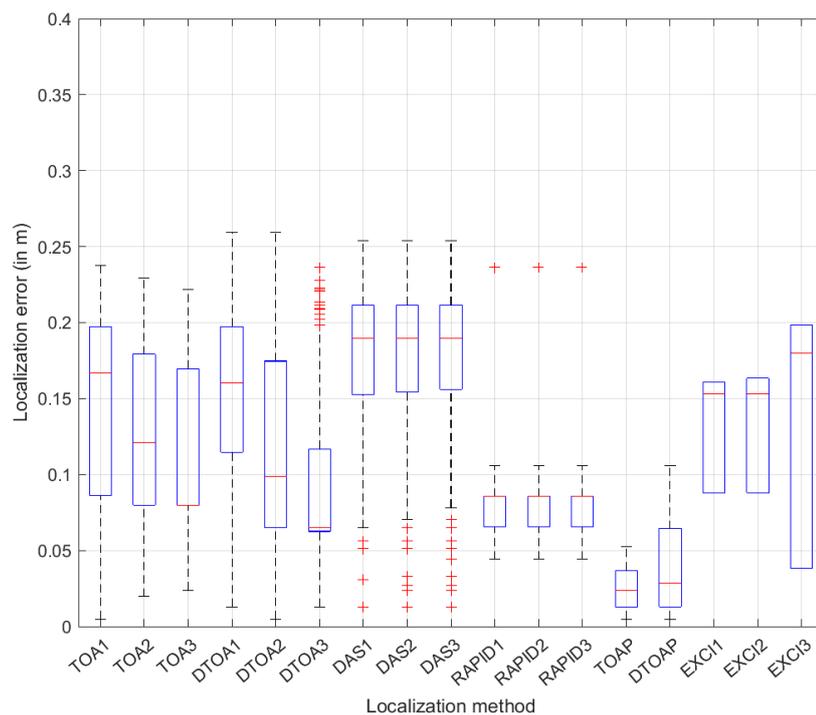


FIGURE 2.8 – Évaluations des méthodes de localisation sur les structures X11 et X12

Modèle de la plaque La plaque est maillée par des éléments coques quadratiques selon une grille régulière. La fréquence du signal d'excitation est de l'ordre de 100kHz, ce qui correspond à une longueur d'onde $\lambda \approx 20mm$ d'après les courbes de dispersion de ce matériau. Nous considérons que la taille de maille doit être inférieure à 10% de la longueur d'onde, soit une taille de 2 mm. Pour cette taille de maille, la simulation pour un actionneur dure 7min sur un ordinateur de bureau conventionnel. Sachant qu'il y a 5 éléments actifs sur la structure, il faut 35min de simulation pour obtenir une mesure SHM complète.

Pour toutes les simulations décrites dans ces travaux, des éléments coques avec un comportement linéaire élastique sont utilisés. Les propriétés sont celles fournies par le constructeur, parfois recalées sur des mesures expérimentales. Les conditions limites sont choisies libres, la plaque n'étant pas encastree lors des mesures expérimentales.

L'amortissement de Rayleigh introduit dans le modèle considère que la matrice d'amortissement C est proportionnelle à la matrice de raideur K et à la matrice de masse M avec des coefficients respectifs α et β tel que $C = \alpha M + \beta K$. Cet amortissement purement numérique ne s'appuie pas sur des connaissances, les coefficients α et β doivent être calibrés à l'aide de mesures expérimentales. Dans notre cas, un amortissement uniquement proportionnel à la raideur est déterminé avec $\beta = 3 \times 10^{-8}$ à une fréquence d'excitation de 100kHz. Ce modèle d'amortissement est incomplet et le recalage doit être réalisé pour chaque fréquence.

Éléments piézoélectriques Les éléments piézoélectriques reprennent les propriétés mécaniques et piézoélectriques du matériau NOLIAC NCE51 de diamètre 25mm et épaisseur 0.5mm et modélisés avec des éléments coques. Une couche intermédiaire correspondant à la colle est ajoutée entre la structure et les éléments piézoélectriques.

Domage La modélisation du domage, et plus spécifiquement des délaminages avec des non-linéarités dans les matériaux composites est encore un sujet de recherche actif [44]. Un modèle couramment utilisé et repris dans ces travaux modélise le domage par une réduction des modules d'élasticité sur un cylindre traversant la totalité de l'épaisseur de la plaque. Ce modèle est exploité dans la résolution analytique [59] ou numérique [8?]. Un facteur de réduction s tel que $0 < s < 1$ définit la sévérité du domage : plus il est faible, plus le domage est sévère.

$$E_i^{damage} = sE_i^{pristine} \quad (2.1)$$

TABLE 2.3 – Propriétés mécaniques des structures

Nom	Hexcel AS4/8552 PW	Recalé	Unité
E_1	64.5	67	MPa
E_2	62.5	68.5	MPa
ν_1	0.054	0.054	
ν_2	0.054	0.054	
ρ	1570	1570	kg/m^3
G_1	4.8	4.8	MPa
G_2	4.8	4.8	MPa

2.3.2 Modèle de la Structure X11

La modélisation décrite dans la section précédente est reprise en y intégrant les propriétés matériaux et géométriques de la structure X11.

2.3.2.1 Recalage avec les mesures expérimentales

Un recalage du modèle numérique avec les mesures expérimentales est nécessaire car les ondes de Lamb sont très sensibles aux propriétés mécaniques du matériau. La moindre variation entraîne une modification importante des vitesses de propagations des ondes dans la structure. Ce recalage empirique réalisé sur les plaques saines permet l'exploitation du modèle pour produire les données d'apprentissage du méta-modèle. Les nouvelles propriétés mécaniques du modèle sont regroupées dans le Tableau 2.3.

2.3.2.2 Comparaison expérience et simulation

Les Figures 2.9 comparent les signaux reçus expérimentalement sur chaque PZT avec les résultats de la simulation. Le modèle numérique parvient à reproduire correctement le comportement d'une plaque réelle suite au recalage. Le temps de vol et l'amplitude du premier paquet coïncident (voir la Figure 2.9) mais des différences apparaissent sur la suite des signaux. Notamment avec le PZT 2 utilisé en actionneur et le PZT 3 en récepteur, un paquet d'ondes supplémentaire est présent expérimentalement.

Ces différences peuvent s'expliquer par les incertitudes expérimentales nombreuses et difficiles à lever. Des incertitudes persistent sur la géométrie réelle, sur la position exacte des capteurs, sur l'épaisseur de la couche de colle, sur l'influence du câblage des capteurs, sur les conditions aux limites, etc. Toutes ces incertitudes induisent des différences qui peuvent être importantes entre les mesures réelles et la simulation malgré le travail de recalage. Lever la totalité de ces incertitudes est difficile et demande des moyens de métrologies importants. Les méthodes de SHM développées doivent alors prendre en compte ces incertitudes, y être insensibles ou bien être capables de les compenser.

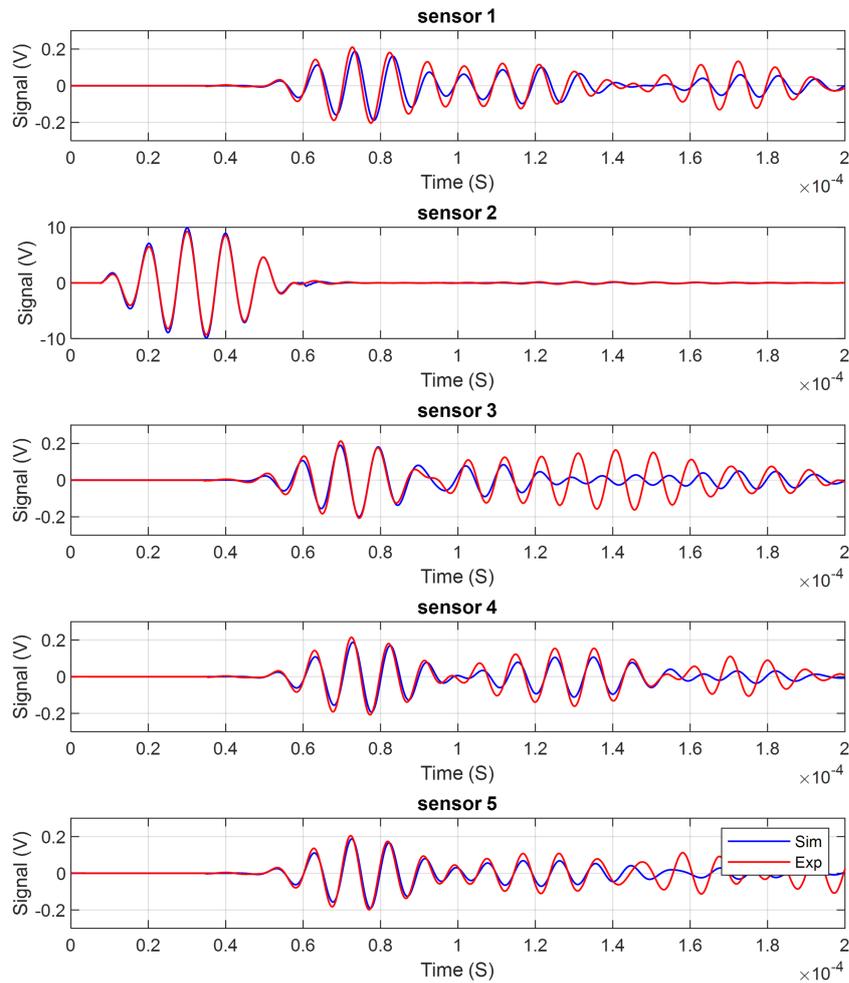


FIGURE 2.9 – Comparaison des signaux numériques et expérimentaux avec le PZT2 en actionneur à 100kHz

Des améliorations sont cependant possibles dans le recalage du modèle développé ici. Le logiciel SDTools propose des outils pour recaler les modèles éléments finis en s'appuyant sur les modes propres. Bien que le SHM par des ondes de Lamb utilise des fréquences plus élevées, il serait intéressant de recalibrer dans un premier temps les modes propres. De plus, des progrès doivent être faits dans la modélisation des endommagements qui reste un sujet ouvert.

2.4 Définitions des cas d'études pour les stratégies d'apprentissage

Des structures numériques dont la complexité augmente progressivement ont été définies pour évaluer les méthodes d'apprentissage les plus adaptées au SHM par des ondes de Lamb. Des larges plans d'expériences avec de nombreuses configurations d'endomma-

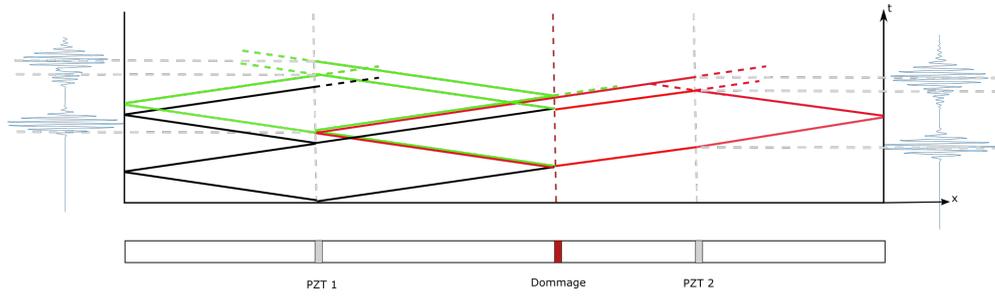


FIGURE 2.10 – Diagramme XT de propagation du premier mode dans la poutre

gement sont simulés pour construire des bases de données.

2.4.1 Poutre

TABLE 2.4 – Structure Poutre

Propriétés		Échantillonnage	
Dimensions	2000 × 20 × 2.6	mm^3	
Position PZT 1	500	mm	
Position PZT 2	1500	mm	
Dimensions PZTs	25 × 20 × 0.5	mm^3	
Matériau	Safran		
Taille maille	1	mm	
Nombre d'éléments	2012		
Nombre de Nœuds	4012		
Échantillonnage	Grille Régulière		
\mathbf{p}_d	x, y		
Taille dommage	20 × 20	mm^2	

Afin de mieux appréhender les phénomènes physiques qui entrent en jeu, un premier cas d'étude simple est envisagé s'appuyant sur une poutre équipée de deux PZTs avec un dommage dont la position et la sévérité varient. Le plan d'expérience de cette poutre contient 129 points d'apprentissage répartis suivant une grille régulière (Tableau 2.4). 18 points supplémentaires tirés aléatoirement en dehors de la grille ont été simulés pour construire le jeu de validation. Dans le cas de la poutre, il y a deux modes de fonctionnement à distinguer, un **mode en transmission** (actionneur vers capteur) et un **mode en réflexion** (actionneur vers actionneur). Le diagramme XT (Figure 2.10) permet de visualiser la propagation d'un mode dans la poutre.

Mode Réflexion Une fonctionnalité nouvelle sur SDT fait basculer lors de la simulation l'actionneur en mode capteur après l'émission du signal d'excitation. Cette fonctionnalité correspond à ce qui est fait lors des mesures expérimentales avec le matériel du laboratoire. Le premier paquet du signal de différence correspond à la première réflexion de

l'onde sur le dommage qui est alors mesurée par le PZT actionneur. Le temps d'arrivée du premier paquet est directement lié à la position du dommage. L'amplitude de ce paquet dépend de la sévérité du dommage mais aussi de sa position (Figure 2.11). En comparaison des signaux en mode transmission, ceux-ci semblent alors porteurs d'une information sur la position du dommage plus facile à extraire, rendant le développement de stratégies d'apprentissage plus aisé avec ces mesures.

Mode Transmission L'onde est émise par le PZT actionneur puis captée par le PZT récepteur. Dans le cas particulier de la poutre, l'onde passe toujours par le dommage quand il est situé entre les deux PZTs et le récepteur capte alors l'onde transmise. La différence des signaux mesurés entre l'état sain et l'état endommagé a alors toujours l'allure suivante :

- Un premier paquet arrive sur le récepteur. Son amplitude dépend directement de la sévérité du dommage
- Un second paquet se réfléchit sur le dommage puis sur l'actionneur avant de traverser le dommage et d'atteindre le récepteur. L'amplitude de ce paquet dépend alors de la sévérité alors que son temps d'arrivée dépend de la position.
- Un troisième paquet, d'amplitude importante, correspond au premier paquet qui a poursuivi sa propagation après le passage sur le récepteur pour se réfléchir sur l'extrémité de la poutre et atteindre à nouveau le récepteur.

L'amplitude du signal de différence est liée à la valeur de la sévérité. En revanche, l'information sur la position du dommage est contenue dans le temps de vol d'un paquet de faible amplitude. Il sera alors plus difficile de revenir à la position du dommage à partir de ces signaux. A titre d'exemple, l'évolution d'un indicateur d'endommagement est tracée Figure 2.13 : la variation du DI est monotone avec la sévérité, tandis que le DI varie très peu et oscille avec la position. Les DI s'appuyant sur le calcul d'énergies de signaux ne semblent donc pas être des descripteurs pertinents pour déterminer la position du dommage.

2.4.2 Petite plaque - S2

La structure S2 également modélisée par des éléments finis est une plaque en un matériau composite identique à celui des plaques expérimentales X11 et X12 de dimensions $300 \times 300 \times 2.4mm^3$ et équipée de 3 PZTs. Pour cette plaque, seules les mesures en mode transmission (actionneur vers récepteur) ont été simulées. Sa dimension réduite permet de diminuer le temps de calcul pour générer des bases de données riches utiles à la sélection des méthodes d'apprentissage. Le plan d'expérience suit un échantillonnage par Latin Hypercube Sampling (LHS) (décrit dans la Section 3.4.1) et contient 197

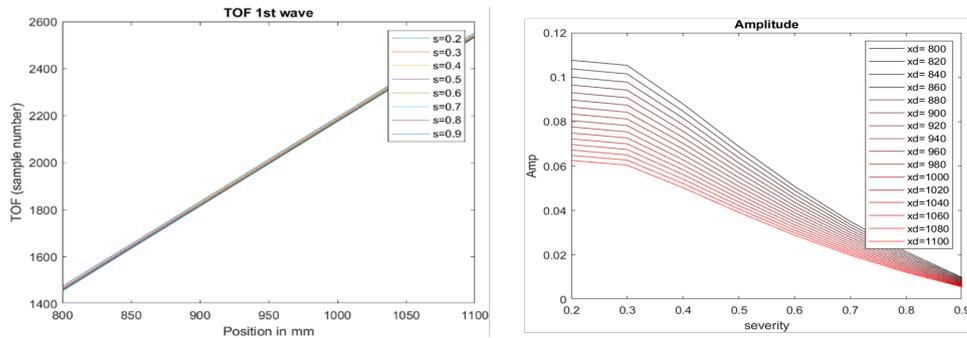


FIGURE 2.11 – Évolution de l'amplitude et du temps de vol du premier paquet dans la poutre

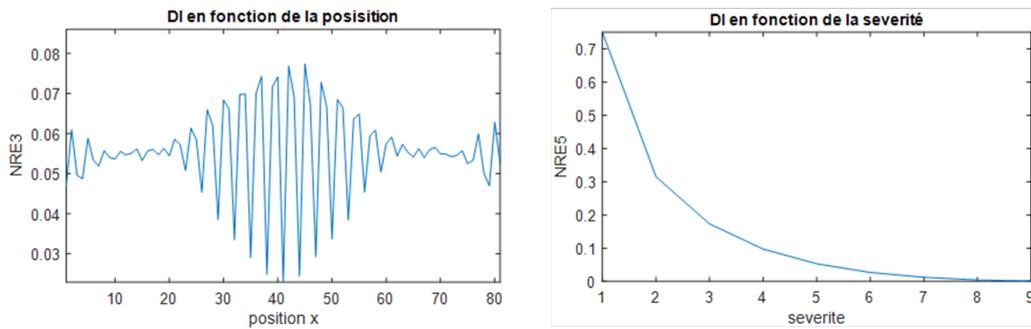


FIGURE 2.12 – Exemple caractéristique d'évolution d'un DI dans la poutre en fonction de la position et de la sévérité

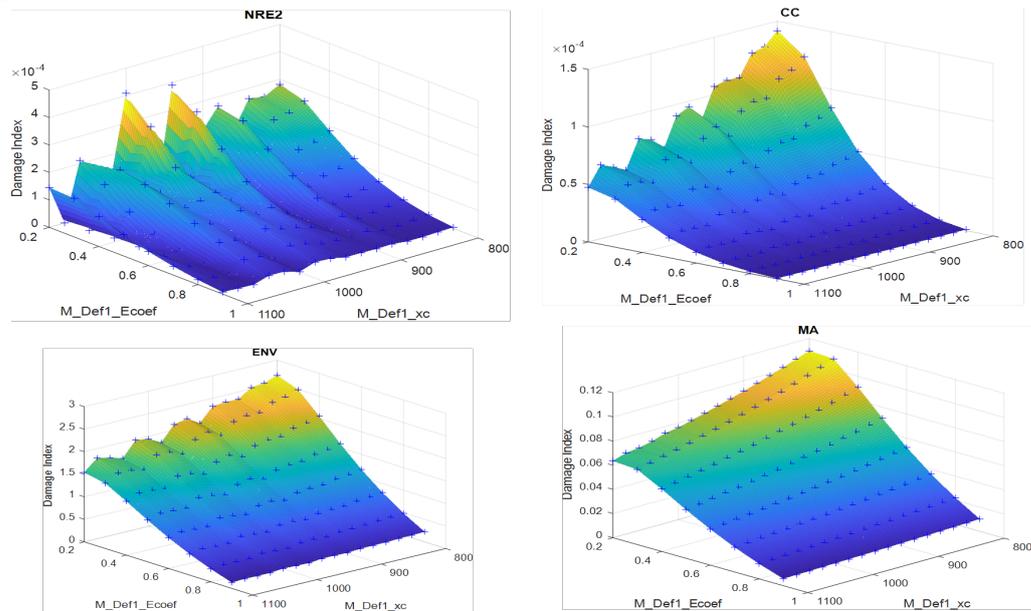
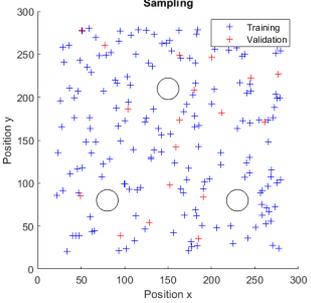
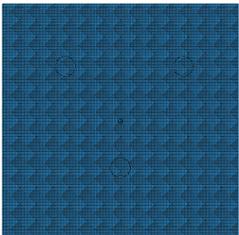


FIGURE 2.13 – DIs en fonction de la sévérité et de la position pour la poutre en réflexion (PZT 1 → PZT 1)

TABLE 2.5 – Structure S2

(a) Propriétés			(b) Échantillonnage
Dimensions Plaque	$300 \times 300 \times 2.6$	mm^3	
Position PZT 1	8080	mm	
Position PZT 2	80220	mm	
Position PZT 3	220150	mm	
Diamètre et épaisseur PZTs	$\%0.25 \times 0.5$	mm^2	
Matériau	Safran		
Excitation	100kHz 5 cycles		
Taille maille	2	mm	
Nombre d'éléments	22561		
Nombre de Nœuds	22804		
Échantillonnage	LHS		
\mathbf{Pd}	x, y		
Diamètre dommage	10	mm	
Nombre Dommage	196		
Temps par échantillon	4	min	(c) Maillage
			

échantillons où les positions x et y du dommage varient (Tableau 2.5). La sévérité et le diamètre du dommage sont fixés respectivement à 50% et 5mm.

L'analyse des signaux montre que les petites dimensions de la plaque combinées aux vitesses de groupe élevées des ondes de Lamb empêchent les paquets d'ondes de se distinguer nettement. Les ondes se propagent rapidement, se réfléchissent sur les bords de la plaque et interagissent plusieurs fois avec le dommage. Les signaux diffèrent fortement du cas de la poutre où les paquets étaient distinguables. De plus, un petit décalage du dommage de 10mm entraîne une différence importante sur les signaux (Figure 2.14). Cela implique qu'une interpolation des signaux par une méthode d'apprentissage ou bien le développement de stratégies de résolution du problème inverse sont des tâches complexes car la condition de stabilité d'un problème bien posé (Paragraphe 1.5) n'est pas validée sur cette structure. L'apprentissage doit alors faire appel à un grand nombre d'échantillons pour contourner ce problème (Tableau 2.5).

2.4.3 Grande plaque - S11

Le modèle recalé de la structure expérimentale X11 est repris pour construire un plan d'expérience déterminé par LHS contenant 368 configurations d'endommagement différentes où la position et la sévérité fluctuent. Il permet de montrer la pertinence du développement de stratégies d'apprentissage avec des données numériques pour la caractérisation de dommages expérimentaux dans le Chapitre 4. Dans ce plan d'expérience,

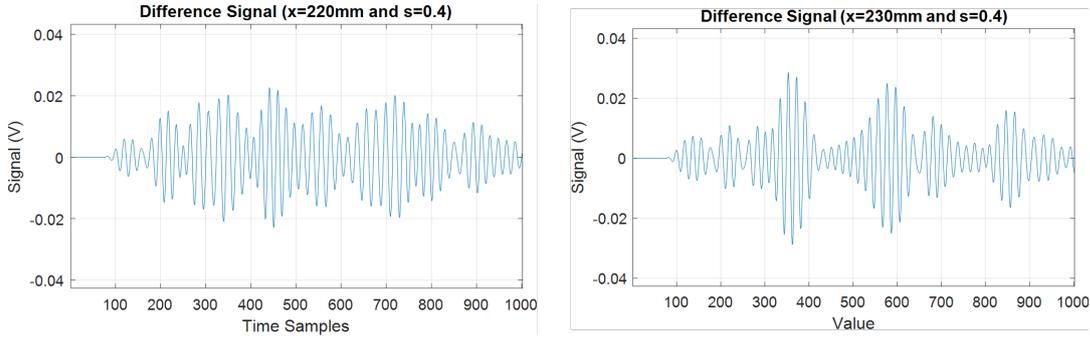


FIGURE 2.14 – Signal de différence de la plaque S2 où le dommage est déplacé de 10mm.

l'endommagement se situe entre les PZTs et son diamètre est fixé à 10mm. La Figure (c) Tableau 2.6 montre la position des endommagements pour le jeu d'entraînement et le jeu de validation. Le diamètre des cercles y est proportionnel à la sévérité du dommage. Une densité importante d'échantillons est également nécessaire pour cette en raison de l'instabilité des mesures de propagation d'ondes lorsque la position du dommage varie même faiblement.

TABLE 2.6 – Structure S11 numérique

(a) Propriétés			(b) Échantillonnage	
Dimensions Plaque	$6000 \times 600 \times 2.6$	mm^3		
Position PZT 1	[473, 166]	mm		
Position PZT 2	[287, 252]	mm		
Position PZT 3	[103, 331]	mm		
Position PZT 4	[456, 376]	mm		
Position PZT 5	[265, 456]	mm		
Diamètre et épaisseur PZTs	$\%025 \times 0.5$	mm^2		
Matériau	Safran			
Excitation	100kHz 5 cycles			
Taille maille	2	mm		
Nombre d'éléments	89989			
Nombre de Nœuds	89485			
Échantillonnage	LHS			
\mathbf{P}_d	x, y, s			
Diamètre dommage	$\%010$	mm		
Nombre Dommages	368			
Temps par échantillon	7	min		

2.4.4 Structure courbe - C

Une dernière structure courbe est exploitée pour l'étude du transfert d'apprentissage entre deux structures voisines. Les propriétés mécaniques et sa géométrie nominale sont présentées dans le Tableau 2.7. Celles-ci seront modifiées dans Chapitre 5 en introdui-

TABLE 2.7 – Structure courbe C

(a) Propriétés			(b) Schéma
Dimension L	500	mm	
Dimension l	200	mm	
Rayon R	150	mm	
Angle θ	50	°	
Position PZT 1	[100 160]	mm	
Position PZT 2	[400 40]	mm	
Position PZT 3	[400 160]	mm	
Position PZT 4	[100 40]	mm	
Diamètre et épaisseur PZTs	$\%25 \times 0.5$	mm ²	
Matériau	Safran		
Excitation	100kHz 5 cycles		
Taille maille	2	mm	
Nombre d'éléments	30872		
Nombre de Nœuds	31213		
Échantillonnage	LHS		
\mathbf{p}_d	l, z, s		
Diamètre dommage	10	mm	
Nombre Dommages	105		
Temps par échantillon	3	min	

sant des biais et des incertitudes dans le modèle afin de tester la sensibilité des méthodes proposées aux changements structurels et aux modifications des conditions environnementales et opératoires.

2.5 Conclusion

La génération de délaminages dans les structures en matériaux composites par le procédé de chocs lasers symétriques permet de valider les algorithmes les plus usuels de SHM sur des délaminages réalistes et entièrement maîtrisés. La détection ne pose pas de problèmes particuliers et le SHM peut être utilisé pour suivre en temps réel la création d'un délaminage par ce procédé. Quelques méthodes parviennent à localiser avec précision les délaminage mais le grand nombre de paramètres à déterminer rend leur usage difficile. Il sera nécessaire de penser à développer des méthodes de calibration des algorithmes de SHM pour augmenter la fiabilité des prédictions et faciliter le paramétrage des algorithmes.

Les modèles développés sur le logiciel SDTools pour la simulation d'une structure en matériaux composites équipées de PZTs sont valides. Ils prédisent correctement la propagation des ondes de Lamb dans une structure saine, l'amplitude et le temps de vol du premier paquet d'ondes sont particulièrement proches des mesures expérimentales. La modélisation du dommage reste cependant encore un sujet ouvert. Ces modèles permettent de générer des bases de données riches pour développer des stratégies d'appren-

tissage innovantes. La complexité de la physique des ondes de Lamb nécessite cependant de réaliser un grand nombre de simulation, ce qui représente un temps de calcul non négligeable.

3 Approximation du problème direct par des métamodèles

Résumé

L'approximation du problème direct par des stratégies d'apprentissage réduit considérablement le temps de calcul pour de nouvelles configurations de dommage. Plusieurs approches sont évaluées et comparées : une méthode à noyau une méthode à base réduite et une méthode d'apprentissage profond. Un processus d'entraînement et de prédiction est configuré pour adapter ces méthodes aux spécificités du SHM par des ondes de Lamb. La recherche d'une compression pertinente des données pour les méthodes à noyau a permis de mettre en avant les spécificités et les difficultés liées à ce type de données. L'approximation du problème direct est complexe en raison des non-linéarités qui sont mieux prises en compte par les méthodes d'apprentissage profond.

Sommaire

3.1	Introduction	56
3.2	Apprentissage supervisé pour le SHM	57
3.2.1	Métamodèles direct et inverse	57
3.2.2	Généralités sur l'apprentissage supervisé	57
3.2.3	Exemples d'utilisations de l'apprentissage supervisé en SHM	58
3.3	Descriptions des méthodes retenues	62
3.3.1	Interpolation par des Fonctions Radiales de base	63
3.3.2	Proper Generalized Decomposition	65
3.3.3	Réseau génératif adverse maximisant l'information	66
3.4	Processus d'approximation du problème direct	74
3.4.1	Échantillonnage de l'espace paramétrique	77
3.4.2	Compression des signaux	78
3.4.3	Pré-traitement des données	83
3.4.4	Entraînement et prédiction du métamodèle	84
3.5	Évaluation des méthodes retenues	84
3.5.1	Évaluation de la RBF	84
3.5.2	Évaluation de la PGD	85
3.5.3	Évaluation des réseaux génératifs	86
3.6	Bilan des évaluations des métamodèles	87
3.7	Conclusion	88

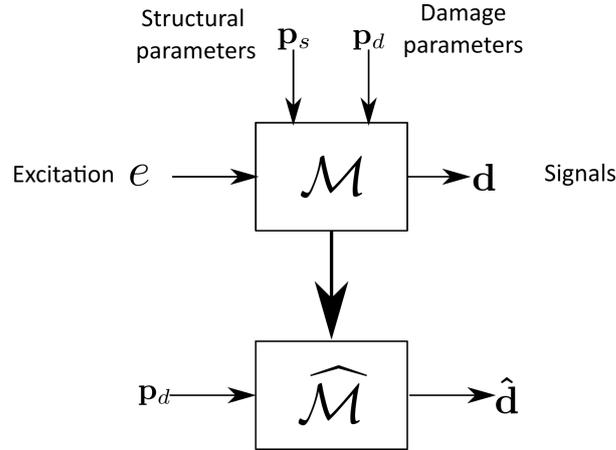


FIGURE 3.1 – Approximation du problème direct par un métamodèle

3.1 Introduction

Contexte La simulation d'un modèle par éléments finis d'un procédé de SHM par des ondes de Lamb présentée au Chapitre 2 est longue et coûteuse, mais nécessaire afin de développer et évaluer rigoureusement les algorithmes de SHM. En s'appuyant sur les résultats de simulations numériques, il est cependant possible de construire une seconde approximation de la réalité, un modèle réduit du modèle numérique appelé **métamodèle** ou modèle de substitution (*surrogate model* en anglais). Cette nouvelle approximation doit prédire avec précision et rapidité de nouvelles données pour présenter un intérêt par rapport à la simulation. Sa construction, la métamodélisation, s'appuie sur un ensemble de données simulées au préalable. La physique du système est décrite lors de la construction du modèle numérique, souvent un modèle par éléments finis. En revanche, elle n'intervient plus lors de la construction du métamodèle mais elle reste sous-jacente dans les données utilisées. Le métamodèle s'apparente alors à une boîte noire présentée sur la Figure 3.1 qui reprend la formulation sous forme de système (Section 1.5) et tisse une relation entre des entrées et des sorties.

Objectifs Ce chapitre propose un processus pour construire et pour utiliser un métamodèle dans le cadre du SHM par des ondes de Lamb. Les différentes étapes des processus reposent sur des algorithmes et des méthodes génériques qui doivent être adaptées aux spécificités des données afin d'intégrer efficacement les stratégies d'apprentissage aux procédures du SHM par des ondes de Lamb. Ces adaptations sont déterminées par une analyse fine des données, par une compréhension de la théorie derrière chaque algorithme et par une démarche empirique.

3.2 Apprentissage supervisé pour le SHM

3.2.1 Métamodèles direct et inverse

Deux approches différentes sont considérées : le métamodèle direct $\widehat{\mathcal{M}}$ et le métamodèle inverse $\widehat{\mathcal{M}}^{-1}$ (Figure 1.18). Pour une structure donnée et des conditions opératoires maîtrisées, les paramètres liés à la structure (géométrie, propriétés mécaniques, etc) \mathbf{p}_s peuvent être considérés comme constants. Cette hypothèse simplificatrice sera notamment discutée au cours du Chapitre 5. L'excitation \mathbf{e} est imposée lors de l'inspection, elle est donc connue et fixée pour l'ensemble des simulations. Ainsi, les quantités d'intérêts sont les sorties \mathbf{d} et les paramètres du dommage \mathbf{p}_d .

Le **métamodèle direct** prend alors en entrée les paramètres du dommage \mathbf{p}_d et en sorties les observations \mathbf{d} . Il prédit un nouveau résultat de simulation avec un coût très faible. Il se substitue au modèle numérique lorsqu'il est nécessaire de faire appel à un grand nombre de simulations, notamment pour la résolution du problème inverse avec des méthodes déterministes ou probabilistes de type Monte Carlo Markov Chain (MCMC) [84]. Le **métamodèle inverse** $\widehat{\mathcal{M}}^{-1}$ quant à lui résout directement le problème inverse. Il prend en entrée des signaux mesurés \mathbf{d}^{obs} (numériques ou expérimentaux) et en déduit les paramètres du dommage \mathbf{p}_d qui leurs sont associés. En fonction du métamodèle étudié (inverse ou direct), les formats des données d'entrée et de sortie diffèrent fortement, les méthodes de métamodélisations sont donc différentes. Ce chapitre s'étend uniquement sur l'approche directe tandis que l'approche inverse est décrite dans le Chapitre 4.

3.2.2 Généralités sur l'apprentissage supervisé

La construction d'un métamodèle revient à résoudre un problème d'apprentissage supervisé en construisant une relation entre des variables d'entrée dites explicatives et des variables de sortie appelées labels. Pour la description générale de ce type d'apprentissage, nous considérons les variables d'entrée $\mathbf{p}_d \in \mathcal{P} \subset \mathbb{R}^q$ et les variables de sorties $\mathbf{d} \in \mathcal{D} \subset \mathbb{R}^m$. Dans le cas présenté dans ce chapitre, \mathcal{M} correspond à un modèle par des éléments finis d'une structure intelligente, \mathbf{p}_d aux variables d'intérêt paramétrant le dommage et \mathbf{d} aux signaux prédits par le modèle \mathcal{M} .

L'apprentissage supervisé cherche à trouver une relation $\widehat{\mathcal{M}}(\mathbf{p}_d) = \mathbf{d}$ en s'appuyant sur un ensemble de n couples entrée-sorties $S = (\mathbf{p}_d^i, \mathbf{d}^i)_{i=1}^n \in (\mathcal{P} \times \mathcal{D})^n$. L'hypothèse fondamentale de l'apprentissage supervisé est que tous les couples sont générés indépendamment et identiquement selon une distribution de probabilité inconnue mais fixe notée \mathcal{S} . La fonction de coût mesure le désaccord entre la sortie désirée \mathbf{d} et la prédiction $\widehat{\mathcal{M}}(\mathbf{p}_d)$ à l'aide d'un coût instantané défini par $\ell : \mathcal{D}, \mathcal{D} \rightarrow \mathbb{R}^+$. L'apprentissage supervisé vise alors à trouver un fonction $\widehat{\mathcal{M}}$ dans un espace de fonctions \mathbb{M} qui minimise la

fonction de coût tel que :

$$\hat{\mathcal{M}} = \operatorname{argmin}_{\mathcal{M} \in \mathbb{M}} \mathcal{L}(\mathcal{M}) \quad (3.1)$$

$$= \operatorname{argmin}_{\mathcal{M} \in \mathbb{M}} \mathbb{E}_{(\mathbf{d}, \mathbf{p}_d) \sim \mathcal{S}} [\ell(\mathbf{d}, \mathcal{M}(\mathbf{p}_d))] \quad (3.2)$$

En pratique \mathcal{S} est inconnu, l'espérance \mathbb{E} ne peut donc pas être estimée exactement et elle est approximée sur l'ensemble des couples S :

$$\hat{\mathcal{M}} = \operatorname{argmin}_{\mathcal{M} \in \mathbb{M}} \mathcal{L}(\mathcal{M}) \quad (3.3)$$

$$= \operatorname{argmin}_{\mathcal{M} \in \mathbb{M}} \frac{1}{n} \sum_{i=1}^n \ell(\mathbf{d}^i, \mathcal{M}(\mathbf{p}_d^i)) \quad (3.4)$$

Cette minimisation se retrouve sous le nom *d'entraînement* ou *d'apprentissage*. L'ensemble des données utilisées durant l'entraînement constitue le *jeu d'entraînement*. D'autres données également indépendamment et identiquement distribuées selon \mathcal{S} sont conservées pour constituer le *jeu d'évaluation* et estimer la capacité de généralisation du modèle entraîné. Les données sont consignées dans des matrices P et D tel que :

$$P = \begin{pmatrix} p_1^1 & \cdots & p_1^n \\ \vdots & \vdots & \vdots \\ p_j^1 & \cdots & p_j^n \\ \vdots & \vdots & \vdots \\ p_q^1 & \cdots & p_q^n \end{pmatrix}, \quad D = \begin{pmatrix} d_1^1 & \cdots & d_1^n \\ \vdots & \cdots & \vdots \\ d_j^1 & \cdots & d_j^n \\ \vdots & \cdots & \vdots \\ d_m^1 & \cdots & d_m^n \end{pmatrix} \quad (3.5)$$

avec : p_j^i la valeur prise par le j -ème paramètre lors de la i -ème simulation,
 d_j^i la valeur prise par la j -ème observation lors de la i -ème simulation,
 n le nombre d'échantillons,
 q la dimension des paramètres \mathbf{p}_d ,
 m la dimension des observations.

3.2.3 Exemples d'utilisations de l'apprentissage supervisé en SHM

La dynamique complexe des structures endommagées combinée aux coûts élevés des calculs et des expériences pour mener des études complètes rendent attractif l'utilisation de méthodes d'apprentissage supervisé en SHM. Elles visent à palier le manque de connaissances sur les phénomènes physiques tout en offrant des résultats rapides permettant l'utilisation de ces méthodes en temps réel (en contrepartie du temps de création des bases de données et du temps d'apprentissage). De nombreux exemples d'utilisation de ces méthodes sont présents dans la littérature et peuvent se regrouper en trois catégories : les méthodes à noyau, les méthodes à base réduite et les méthodes d'apprentissage profond.

3.2.3.1 Méthodes à noyau

Les méthodes à noyau se montrent rapides et efficaces pour l'entraînement sur des petites bases de données mais des connaissances préalables sur les données sont requises pour construire manuellement des caractéristiques descriptives. La plupart des méthodes cherche à résoudre le problème inverse identifié précédemment. Dans le contexte de la surveillance des structures, le Krigeage (KRG) est utilisé dans [34] pour localiser une fissure dans une pale d'une éolienne à partir des mesures des décalages spectraux. Une variante du KRG est utilisé sur une structure similaire pour calculer une relation entre les DIs et la sévérité dans [33]. Le KRG est également utilisé dans [85] pour localiser et quantifier un délaminage à partir des mesures de potentiel électrique et dans [39] pour localiser un dommage à partir des mesures d'impédance électromécanique. La Machine à Vecteur de Support (*Support Vector Machine* en anglais, SVM), une autre méthode à noyau très courante, est utilisée pour quantifier des endommagements dans [8].

L'utilisation de ces méthodes pour approximer le problème direct par des métamodèles est plus rare mais a pourtant donné des résultats prometteurs. Dans [69], le KRG prédit un décalage de fréquence propre à partir des paramètres géométriques (position, taille, profondeur) d'un délaminage dans une structure courbe en matériaux composites. Le métamodèle est entraîné avec données issues de simulations numériques et les données expérimentales sont acquises à l'aide d'un vibromètre laser. Une optimisation par essaim utilisant le métamodèle retrouve les paramètres du délaminage avec une réussite supérieure à celle d'un Réseau de Neurones Artificiels (*Artificial Neural Network* en anglais, ANN) pour la résolution inverse. Le KRG prédit également les décalages des fréquences propres d'une structure composite en fonction de la position d'un dommage dans [86]. Ce métamodèle est alors utilisé pour la résolution inverse pour retrouver la position d'un dommage à partir de mesures de fréquences propres à l'aide d'un algorithme génétique. Là aussi, la résolution du problème inverse se montre plus efficace que l'utilisation d'un réseau de neurones. Une métamodélisation par KRG estime la PoD des dommages pour des nouvelles positions des capteurs afin d'optimiser le positionnement des PZTs dans [87]. Combinée à un algorithme génétique, cette approche permet de trouver la position optimale des capteurs. En combinant également le KRG et un algorithme génétique, une mise à jour dynamique d'un modèle par éléments finis s'appuyant sur des mesures de corrélation d'image est déployée dans [13].

3.2.3.2 Méthodes à base réduite

Les méthodes à base réduite calculent une base dans laquelle les projeter projeter les données. Il n'est alors pas nécessaire de concevoir au préalable des représentations. Ces méthodes restent peu utilisées en SHM en raison des coûteux plans d'expérience

qu'elles exigent, de la difficulté à traiter les phénomènes non-linéaires et de leur intrusivité dans les solveurs par éléments finis. La Proper Orthogonal decomposition (POD) est la méthode la plus courante : combinée avec un ANN pour construire un métamodèle, elle permet d'inférer la localisation et l'épaisseur d'un dommage dans [88]. Elle est également utilisée dans [89] pour réduire un modèle numérique et parvenir à y localiser un dommage. Dans un contexte différent de celui du SHM par des ondes de Lamb, [90] a mis en œuvre des approches innovantes pour la résolution de problèmes inverses : la Proper Generalized Decomposition (PGD) réduit le modèle et la résolution inverse se fait par une approche bayésienne. Des méthodes de transport optimal sont utilisées pour réduire le temps de calcul par rapport à des méthodes de type MCMC [91, 92]. Cette approche permet de correctement estimer les distributions marginales des paramètres d'une fissure dans une poutre en béton en flexion à partir de déplacements mesurés par de la corrélation d'image.

3.2.3.3 Méthodes d'apprentissage profond

L'utilisation des CNNs a explosé ces dernières années pour résoudre toutes sortes de problèmes et ils se sont démocratisés dans le cadre du SHM avec de plus en plus d'applications. Cela reste un défi important car les méthodes d'apprentissage profond nécessitent beaucoup de données lors de l'entraînement alors que leurs obtentions sont très coûteuses en SHM. Ces raisons ont probablement détourné pendant un temps la communauté du SHM de ces méthodes mais désormais de plus en plus de travaux les utilisent avec des performances excellentes dont quelques exemples sont présentés dans les paragraphes suivants.

Modèles discriminatifs Les modèles discriminatifs en apprentissage profond attribuent une valeur à une entrée dont la dimension peut être très importante. Ils ont connu des grands succès pour le traitement d'image ou de sons. Les CNNs qui combinent des filtres de convolutions avec les ANNs sont les modèles discriminatifs les plus courants.

En transformant les signaux sous la forme de matrices, les CNNs conçus pour le traitement d'image peuvent être rapidement déployés en SHM. Ainsi, [47] utilise un CNN pour déterminer la taille d'un dommage à partir des figures de localisation obtenues par l'algorithme Excitlet. Son approche prenant en compte des données expérimentales et numériques obtient de bons résultats. En s'appuyant sur des mesures d'impédance électromécanique mises sous la forme d'une image, [38] parvient à identifier 4 scénarios d'endommagement (1 sain et 3 dommages) avec un CNN sur une plaque d'aluminium équipée de 4 PZTs. Le CNN surpasse d'autres méthodes de classification et s'approche des 100% de réussite. Pour un problème différent, [93] utilise deux CNNs pour localiser et quantifier des impacts sur un fuselage équipé de PZTs. Des images sont créées à partir

des signaux mesurés, un CNN est entraîné pour estimer la localisation et un autre pour estimer l'énergie de l'impact. Cette méthode donne de très bons résultats, avec plus de 95% de réussite.

L'analyse de signaux temporels est également une tâche aisée pour les CNNs qui peuvent être déployés pour les données collectées en SHM. Une des premières stratégies d'apprentissage profond dans le cadre du SHM par onde de Lamb propose une méthode de classification de différents scénarios d'endommagement d'une plaque d'aluminium équipée de deux PZTs à l'aide d'un CNN [94]. Des approches de détection et de classification se retrouvent dans [95, 96] où des CNNs à une dimension identifient des défaillances dans un train d'engrenage à partir de signaux mesurés avec des accéléromètres. Il s'agit de surveillance de système plutôt que de structure mais le format des données collectées est similaire à celui des données SHM. Dans [97], un CNN à une dimension ayant pour entrée un vecteur regroupant plusieurs DI parvient à détecter mais aussi à quantifier la taille d'une fissure. La méthode est testée avec des éprouvettes en aluminium ayant subies de la fatigue. Récemment, les Indicateur d'endommagement Variant Temporellement (TVDI)s ont été introduits par [98] pour localiser un dommage. Les données sont acquises expérimentalement par un réseau de 4 PZTs sur une plaque d'aluminium. Dans [99], une masse sur une plaque composite équipée de 4 PZTs est localisée et quantifiée par un CNN entraîné avec des données expérimentales. Un autre CNN est utilisé par [98] pour détecter et localiser un dommage sur un raidisseur en matériau composite.

De nouvelles architectures neuronales de complexité croissante sont proposées régulièrement et comparées avec les CNNs qui se montrent souvent plus performants en SHM. Ainsi dans [100] un premier CNN détecte le dommage puis un second détermine la taille et la position du dommage. Lors de cette seconde phase, 3 types d'architecture sont testés : CNN à une dimension, CNN à deux dimensions et un Long Short Term Memory network (LSTM). Ces architectures obtiennent des résultats similaires mais le CNN à une dimension s'entraîne bien plus rapidement. Une comparaison avec les méthodes classiques d'apprentissage machine (SVM, Ridge Regression, Lasso Regression) montre la supériorité des approches d'apprentissage profond. Un Residual Neural Network (ResNet) est comparé à un CNN dans [11] pour détecter et localiser un dommage sur une structure simulant un immeuble de quelques étages. Dans cette approche, le ResNet obtient des résultats légèrement meilleurs que le CNN.

Dans une approche originale, les résultats des détections d'un 1D-CNN par une méthode d'Intelligence Artificielle Explicable (*eXplainable Artificial Intelligence* en anglais, XAI) sont expliqués par [101]. Les résultats de l'algorithme de XAI sont ensuite utilisés pour localiser l'endommagement. Dans [102], les couches de convolution d'un CNN sont modifiées pour y intégrer quelques connaissances physiques afin de détecter et localiser un dommage.

TABLE 3.1 – Utilisation des méthodes d’apprentissages en SHM

Tâche	Noyau	Base réduite	ANN	CNN	GAN, ResNet, etc.
Métamodèle	[34, 86, 87, 106]	[57, 88, 89, 90]	[69]	[97]	[103, 104, 107]
Détection	[39, 108]	[57, 88, 89, 90]	[38, 108]	[11, 20, 38, 68, 94, 95, 96, 98, 101, 109]	[11, 20, 110]
Localisation	[34, 39]	[57, 88, 89]	[68, 69]	[11, 93, 98, 98, 99, 100, 101]	[11]
Classification	-	-	[38, 111]	[38, 94, 95, 96]	-
Quantification	[8]	[88, 90]	[69]	[93, 99, 100, 112?]	[110]
Transfert	[106]	[57]	[111]	[20, 109]	[20, 110]

Modèles génératifs Les modèles génératifs sont capables de synthétiser des nouvelles données imitant celles de la base de données d’entraînement. Ces outils qui permettent de construire un métamodèle direct tel que nous l’avons défini dans la Section 3.1. En raison des difficultés à être entraîné, ce type de modèle reste encore peu déployé en SHM. Récemment, un Réseau Neuronal Adverse Génératif (GAN) a été proposé pour synthétiser des signaux de propagation d’ondes [103, 104] en reprenant l’architecture définie dans [105].

Le tableau 3.1 recense les différentes méthodes d’apprentissage déployées en SHM. Ces différents exemples montrent que les CNNs obtiennent des résultats très prometteurs et méritent d’être déployés en SHM.

3.3 Descriptions des méthodes retenues

Les différents exemples bibliographiques montrent la très grande diversité de méthodes pour la construction de métamodèle. Il en ressort plusieurs grandes familles ayant chacune leurs avantages et leurs inconvénients (Tableau 3.2). Il est bien évidemment impossible de tester toutes ces méthodes de manière exhaustive. Celles qui ont semblé les plus pertinentes pour nos cas d’études sont retenues ici : la Interpolation par Fonction de Base Radiale (RBF) représente les méthodes à noyaux, la PGD représente les méthodes à base réduite, le Réseau Neuronal Adverse Génératif maximisant l’information (InfoGAN) les méthodes d’apprentissage profond génératives et les CNNs les méthodes

TABLE 3.2 – Comparaison des différentes méthodes d'apprentissage

	Noyau	PGD	S-PGD	CNN	GAN	Info-Gan
Calcul des caractéristiques	Manuel	Auto	Auto	Auto	Auto	Auto
Dimension Entrée	<10	<10	<10	>1e3	0	
Dimension Sortie	1	1e3	1e 3	1e3	1e3	1e3
Prétraitement	Scaling	Scaling	Scaling	MinMax	MinMax	MinMax
Interpolation	+	+	+	+	-	+
Généralisation	++	-	+	++	-	+
Durée d'entraînement	1s	1min	1min	1h	10h	10h
Interprétabilité	+	+	+	-	-	+
Nombre hyperparamètre	1	1	1	10000	1000	1000

d'apprentissage profond discriminatives. Les CNNs sont utilisés pour la résolution du problème inverse et sont présentés dans le Chapitre 4.

3.3.1 Interpolation par des Fonctions Radiales de base

Les méthodes à noyau sont des outils très génériques et polyvalents de métamodélisation qui se retrouvent sous de nombreuses formes tel que la RBF, la SVM [113], le Processus Gaussien (GP) ou le KRG [114]. L'utilisation des méthodes à noyau s'appuie sur l'hypothèse forte que la sortie du système ne varie pas brusquement autour d'un point d'observation. Cette hypothèse est une des conditions pour qu'un problème soit bien posé (voir la Section 1.5). En d'autres termes, si les paramètres d'entrée varient légèrement, la sortie variera également légèrement. Cette hypothèse se justifie par l'aspect continu des grandeurs physiques étudiées. Par exemple en SHM, nous pouvons supposer qu'une variation faible de la sévérité du dommage entrainera une faible modification de l'amplitude du signal de différence. Une sortie observée en un point de l'espace paramétrique renseigne alors sur les valeurs des sorties à proximité de ce point.

L'influence mutuelle des observations voisines est déterminée par une fonction symétrique et décroissante par rapport à un centre appelée noyau. Il prend le plus souvent la forme d'une fonction radiale tel que :

$$\forall \mathbf{p} \in \mathbb{R}^q, \mathbf{p}_d^0 \in E, k(\mathbf{p}_d, \mathbf{p}_d^0) = \varphi(\|\mathbf{p}_d - \mathbf{p}_d^0\|) \quad (3.6)$$

avec : k le noyau,
 \mathbf{p}_d^0 le centre,
 ε la largeur de la fonction,
 $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ la fonction radiale.

La valeur d'une fonction de base radiale ne dépend que de la distance séparant son paramètre d'entrée \mathbf{p}_d à son centre \mathbf{p}_d^0 modulée par la largeur ε . Il existe une infinité de fonction radiale, son choix doit être adapté aux données à interpoler. Les plus usuelles

TABLE 3.3 – Fonctions radiales usuelles

Nom	Formule
Gaussienne	$\varphi(r) = e^{-(\varepsilon r)^2}$
Multiquadrique	$\varphi(r) = \sqrt{1 + (\varepsilon r)^2}$
Quadratique inverse	$\varphi(r) = \frac{1}{1 + (\varepsilon r)^2}$
Multiquadrique inverse	$\varphi(r) = 1/(\sqrt{1 + (\varepsilon r)^2})$

sont présentées Tableau 3.3. L'utilisation d'une norme dans la définition du noyau permet de traiter efficacement les fonctions dépendant de plusieurs variables. Dans certains cas, les paramètres d'entrée ont chacun une influence très différente sur la sortie, il peut alors être envisagé que la largeur du noyau possède plusieurs composantes avec une norme adaptée afin de prendre en compte cette anisotropie.

Peu de paramètres doivent être déterminés par l'utilisateur avant l'apprentissage, il n'y a donc peu de connaissance *a priori* à avoir sur la forme de l'équation qui relie les entrées P aux sorties D . En revanche, les méthodes à noyaux ont été développées pour des sorties scalaires (la dimension de D vaut 1). Si les données de sorties sont multidimensionnelles, un métamodèle sera entraîné indépendamment pour chacune des dimensions de sorties. Une méthode à noyau ne peut pas s'appliquer directement sur les données brutes, entraîner un métamodèle pour chaque échantillon d'un signal temporel n'aurait par exemple pas beaucoup de sens en SHM. Il est nécessaire de trouver au préalable une représentation adaptée des données permettant d'en extraire des caractéristiques descriptives et parcimonieuses. Par soucis de clarté, la sortie du métamodèle est supposée avoir une unique dimension ($m = 1$) dans la description mathématique de ces méthodes.

La RBF a été initialement déployée pour l'interpolation de surfaces multi-quadratiques [115]. Une interpolation implique le passage de la réponse par chacune des valeurs des échantillons d'entraînement. Nous cherchons $\hat{\mathcal{M}}$, un interpolateur des sorties \mathbf{d}^j aux points \mathbf{p}^j avec $1 \leq j \leq n$ à l'aide d'un noyau φ supposé défini positif sous la forme d'une fonction radiale. La RBF calcule une combinaison linéaire de fonctions radiales φ centrées sur chaque point de l'échantillonnage \mathbf{p}^j pondérées par les poids ω_j tel que :

$$\forall \mathbf{p}_d \in \mathbb{R}^q, \hat{\mathcal{M}}(\mathbf{p}_d) = \sum_{j=1}^n \omega_j \varphi(\|\mathbf{p}_d - \mathbf{p}_d^j\|) \quad (3.7)$$

avec : φ la fonction radiale ou noyau,

$\|\cdot\|$ une norme sur l'espace des paramètre d'entrée. Dans la plupart des cas, il s'agit de la norme \mathcal{L}^2 .

ϵ_i l'erreur identiquement distribuée et indépendante d'interpolation associée à chacune des observations de la sortie du métamodèle.

Dans ce contexte, l'apprentissage consiste à déterminer les poids ω_i du métamodèle

lui permettant de passer par les points d'apprentissage. En imposant une largeur ε fixe, les poids ω_i se calculent en appliquant la condition d'interpolation suivante :

$$\forall i \in [1 : n], d^i = \sum_{j=1}^n \omega_j \varphi(\|\mathbf{p}_d^i - \mathbf{p}_d^j\|) + \epsilon_i \quad (3.8)$$

Ce qui donne le système linéaire d'équations suivant :

$$\mathbf{D} = \Phi \mathbf{\Omega} + \epsilon \quad (3.9)$$

avec : \mathbf{D} un vecteur contenant les valeurs à interpoler,

$\mathbf{\Omega}$ le vecteur à déterminer contenant les poids de la fonction radiale,

$$\Phi \text{ la matrice de Gram } \Phi = \begin{pmatrix} \varphi(\|\mathbf{p}_d^1 - \mathbf{p}_d^1\|) & \cdots & \varphi(\|\mathbf{p}_d^n - \mathbf{p}_d^1\|) \\ \vdots & \ddots & \vdots \\ \varphi(\|\mathbf{p}_d^1 - \mathbf{p}_d^n\|) & \cdots & \varphi(\|\mathbf{p}_d^n - \mathbf{p}_d^n\|) \end{pmatrix},$$

ϵ le vecteur d'erreur,

Les poids $\mathbf{\Omega}$ sont calculés par une inversion de la matrice Φ , $\mathbf{\Omega} = \Phi^{-1} \mathbf{D}$, ou en utilisant une décomposition **QR** si les matrices sont de très grandes dimensions. Les paramètres principaux pour la RBF sont le choix de la fonction noyau $\varphi(\cdot)$ et la valeur de la largeur du noyau ε déterminé l'aide de la Figure 3.13.

3.3.2 Proper Generalized Decomposition

Les méthodes à base réduite que l'on retrouve également sous le nom de réduction de modèle existent sous de nombreuses variantes tel que la POD [116], la CPD [117], Low Rang Multilinear Approximation (LMLRA), etc. Elles trouvent leur origine mathématique dans la Décomposition en valeurs singulières (*Singular Value Decomposition* en anglais, SVD) [116] et cherchent une décomposition en variables séparées des observations du modèle initial. Nous appliquerons ici la PGD [118] dans une formulation *a posteriori* qui exploite les données sous la forme d'un tenseur multidimensionnel. La formulation *a priori* de la PGD nécessite de modifier les solveurs de simulation par éléments finis, ce qui la rend difficile à utiliser avec un logiciel de simulation commercial. Conçu initialement pour décomposer et compresser des tenseurs, ces méthodes permettent la visualisation rapide de données multidimensionnelles et le tracé d'abaques dynamiques. La PGD propose de décomposer le tenseur des observations de la forme suivante :

$$\widehat{\mathcal{M}}(\mathbf{p}_d) = \widehat{\mathcal{M}}(p_1, \dots, p_q) = \sum_{i=0}^r F_1^i(p_1) \dots F_m^i(p_q) \quad (3.10)$$

avec : p_1, \dots, p_q les variables du système,

q le nombre de variables,

F_j^i le i -ème mode du j -ème paramètre,

r le nombre de modes sélectionnés.

Afin d'estimer les valeurs des observations en dehors des points de la grille, il est nécessaire de réaliser une interpolation pour chacun des modes [119]. Cette interpolation est alors facile et rapide à calculer puisque les modes ne dépendent que d'une seule variable. L'interpolation se fait ici à l'aide de la RBF.

3.3.3 Réseau génératif adverse maximisant l'information

3.3.3.1 Introduction à l'apprentissage profond

Les méthodes d'apprentissage profond sont capables de traiter des données à très grandes dimensions comme des images ou des signaux temporel. Les CNNs et les architectures qui s'en inspirent sont devenus des outils incontournables pour ce type d'apprentissage. Ils ont été initialement introduits par [120] et ont obtenu des résultats excellents pour la classification d'image, la reconnaissance de voix, la compréhension du langage naturel, le traitement d'analyse bio-médicale, etc. Au delà des applications purement numériques, ces développements menés en parallèle d'études en neurosciences ont permis de mieux comprendre le traitement des images par le cerveau [121]. Quelques architectures ont obtenues des résultats remarquables :

VGG16 [122] La faible taille des filtres de convolution utilisés et la profondeur importante de ce réseau permettent d'identifier et localiser des objets dans des images,

ResNet [123] Ce réseau obtient également de très bons résultats pour la reconnaissance d'images avec une architecture plus complexe et très profonde (jusqu'à 150 couches),

GAN [124] Deux réseaux sont entraînés conjointement pour de générer des images ou des signaux dont le réalisme est saisissant.

3.3.3.2 Fonctions élémentaires

Les réseaux d'apprentissage profond sont formés par une succession de couches qui appliquent chacune une transformation à leur entrée et calcule une sortie. Plus le réseau possède de couches, plus il est profond et les caractéristiques extraites sont abstraites. Les couches usuelles sont listées ci-dessous :

Entrée du réseau Il peut s'agir d'un ensemble de vecteur dans le cas de séries temporelles, de matrices ou bien de tenseurs à trois dimensions pour l'analyse d'images.

Convolution Des filtres de convolution (appelés également matrices de convolution, noyau ou masque) sont appliqués à l'entrée de la couche. Les filtres sont optimisés lors de l'apprentissage mais leurs tailles et leurs nombres sont des hyperparamètres à déterminer. Dans le cadre de traitement d'image, ces filtres peuvent par exemple

détecter des contours mais il n'est pas toujours possible d'interpréter les informations qu'ils cherchent à extraire.

Activation Une fonction d'activation non-linéaire est appliquée sur chacune des entrées de cette couche. Elle introduit des non-linéarités dans le modèle et facilite la généralisation du réseau à des données qui ne font pas partie du jeu d'entraînement. La fonction *Leaky ReLu* couramment utilisée est définie par :

$$\sigma(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha x, & \text{if } x < 0 \end{cases} \quad (3.11)$$

Mise en commun La dimension des caractéristiques extraites par les convolutions est réduite par une couche de mise en commun (*Pooling* en anglais) qui calcule le maximum ou la moyenne des caractéristiques sur une fenêtre dont la taille doit être définie. La mise en commun des caractéristiques réduit la durée d'apprentissage en sélectionnant les informations les plus pertinentes pour les couches suivantes.

Normalisation par lot L'entrée de cette couche (Normalisation du lot (*Batch Normalization* en anglais, BN)) est centrée et réduite (espérance nulle et variance égale à un) pour chaque lot augmentant la vitesse et la stabilité de l'entraînement [125].

Décrochage Le décrochage (*drop-out* en anglais) évite le surapprentissage et facilite la généralisation en supprimant aléatoirement et temporairement quelques neurones avec toutes leurs connexions entrantes et sortantes. Le taux de neurones à supprimer est généralement fixé autour de 10%. Lors de l'entraînement, à chaque itération, certains neurones sont décrochés puis rétablis à l'itération suivante.

Upsampling Cette couche peut s'interpréter comme l'effet inverse de la mise en commun puisqu'elle vise à augmenter la taille des données en les ré-échantillonnant.

Couche entièrement connectée Les caractéristiques extraites des données par les convolutions sont traitées par un réseau de neurones entièrement connectées de plusieurs couches pour résoudre le problème de classification ou de régression posé. Alors que la partie convolutive du réseau n'ajoute qu'une quantité relativement faible de poids à entraîner, la partie entièrement est à l'origine de nombreux poids supplémentaires.

3.3.3.3 Entraînement d'un modèle d'apprentissage profond

Les architectures complexes des modèles d'apprentissage profond induisent plusieurs milliers voire millions de variables à optimiser lors de l'entraînement. Cet enjeu considérable a notamment été résolu par le développement des algorithmes de rétro-propagation du gradient [120, 126]. La phase d'entraînement vise à minimiser une fonction de coût

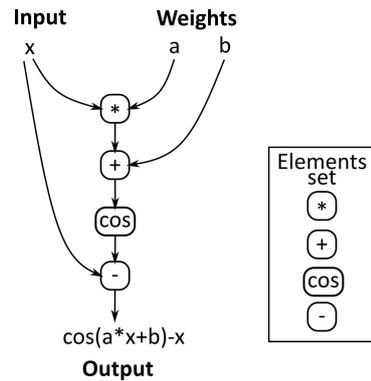


FIGURE 3.2 – Exemple de graphe pour le calcul d'une fonction simple $\cos(x * b + b) - x$

(Équation 3.2) par une approche stochastique. Pour des problèmes de régression, la fonction de coût est souvent l'erreur quadratique moyenne, tandis que pour des problèmes de classification elle dérive souvent du calcul de l'entropie. L'algorithme d'optimisation Adam s'est imposé par ses très bonnes performances et surpasse les méthodes de descente de gradient stochastique [127]. Le calcul du gradient pour une fonction de plusieurs centaines de milliers de variables est une tâche complexe. L'API Keras [128], utilisée dans ces travaux, exploite la différentiation automatique pour le calcul des dérivations. Cette approche s'appuie sur des décompositions des calculs en opérations mathématiques élémentaires facilement dérivables [129]. L'ensemble des opérations appliquées aux entrées par le réseau est alors représenté sous la forme d'un graphe d'opérations élémentaires (Figure 3.2). La dérivation de chacune de ces opérations est facile et la dérivée de l'ensemble est obtenue par le calcul de la dérivée de compositions.

L'optimisation d'un modèle d'apprentissage profond se fait par une approche stochastique : à chaque itération (*epoch*), le jeu de données d'entraînement est divisé en plusieurs lots (*batch*) dont la taille (*batch size*) est un hyperparamètre. L'erreur de la prédiction sur chaque lot ainsi que son gradient sont ensuite calculés. L'algorithme d'optimisation choisi propose alors une modification des poids du réseau en fonction du gradient de l'erreur. Lorsque la fonction de coût converge, il peut être considéré que l'entraînement est terminé. En pratique, le nombre d'itérations (*epochs*) est déterminé à l'avance. Le pseudo-code de la boucle d'entraînement est visible ci-dessous (Algorithme 8) et des modifications sont proposées dans la suite du document pour l'adapter à des problèmes plus spécifiques (Algorithme 2 et Algorithme 5).

3.3.3.4 Réseau de neurones génératif adverse maximisant l'information guidé

Version classique Les CNNs ont connu des succès fulgurants pour faire les liens entre des données d'entrée à très grande dimension et des données de sortie de dimension réduite. Les modèles génératifs, qui permettent de générer une image ou un signal à partir

Algorithm 1: Boucle d'entraînement d'un modèle d'apprentissage profond

Input: Model \mathcal{M}_{ω_0} with weights ω_0
 Training set (x_{train}, y_{train})
 Hyper parameters n_{epoch}, n_{batch}
Output: Trained model \mathcal{M}_{ω} with weights ω
Data: Testing set (x_{test}, y_{test})

```

1 while  $i_{epoch} \leq n_{epoch}$  do
2   Divide training data set  $(x_{train}, y_{train})$  in  $n_{batch}$  batches
3   for  $i_{batch} = [1 : n_{batch}]$  do
4     Compute model outputs for the batch  $\hat{y}_{batch} = \mathcal{M}_{\omega}(x_{batch})$ 
5     Compute loss values for the batch  $\mathcal{L}(y_{batch}, \hat{y}_{batch})$ 
6     Compute the gradient of the loss  $\nabla_{\omega} \mathcal{L}$ 
7     Compute the new weights  $\omega'$  with the gradient according to the chosen
      optimizer
8     Set  $\omega \leftarrow \omega'$ 

```

d'une entrée, ont connu plus de difficultés avant leur déploiement. C'est pourtant ce qui nous intéresse ici : un modèle capable de prédire des signaux à partir des paramètres d'un endommagement. Une approche astucieuse pour entraîner un réseau génératif a été proposée dans [124] : deux réseaux profonds de neurones, un **générateur** et un **discriminateur** sont entraînés de manière adverse (Figure 3.3). Le générateur noté G prend en entrée un vecteur \mathbf{z} de variables latentes. Ce sont des variables abstraites générées aléatoirement selon un bruit $\mathbf{z} \sim P_{noise}$ que le générateur transforme en une prédiction $G(\mathbf{z})$. Le discriminateur prend en entrée un tenseur \mathbf{d} et cherche à déterminer la probabilité d'un échantillon d'être issu de la base de données initiale notée $D(\mathbf{d})$. Lors de l'entraînement, le générateur est optimisé de manière à leurrer le discriminateur en produisant des échantillons les plus ressemblants possible à ceux des données d'entraînement. Il s'agit de minimiser la probabilité de classer les prédictions du générateur comme fausses, c'est-à-dire minimiser $1 - D(G(\mathbf{z}))$. À l'inverse, le discriminateur est optimisé pour catégoriser le mieux possible les données. Le problème d'optimisation est formulé dans l'équation 3.12 :

$$\min_G \max_D \mathcal{L}_{Adv}(D, G) = \mathbb{E}_{\mathbf{d} \sim P_{data}} [\log D(\mathbf{d})] + \mathbb{E}_{\mathbf{z} \sim P_{noise}} [\log(1 - D(G(\mathbf{z})))] \quad (3.12)$$

avec : G le générateur,

D le discriminateur,

$\mathbf{d} \sim P_{data}$ les données à imiter,

$\mathbf{z} \sim P_{noise}$ le bruit d'entrée du générateur.

L'entraînement de ce type de réseau est particulièrement difficile à cause de sa formulation Minimax. Chaque itération se divise en deux étapes qui entraînent successivement

le discriminateur puis le générateur. Dans un premier temps, un lot d'échantillons aléatoires est prédit par le générateur et concaténé avec un lot d'échantillons réels. Ce lot est ensuite utilisé pour entraîner le discriminateur : l'erreur de classification est calculée ainsi que son gradient et une modification des paramètres ω du est proposée suivant l'algorithme d'optimisation choisi. Cette étape correspond à la tâche de maximisation de l'équation 3.12. La seconde étape vise à entraîner le générateur pour ses prédictions soient catégorisées comme vraies par le discriminateur. Pour cela, des vecteurs aléatoires \mathbf{z} sont tirés, le générateur G les transforme en signaux $G(\mathbf{z})$ et le discriminateur évalue la probabilités de ces prédictions d'être vraies $D(G(\mathbf{z}))$. Dans cette phase, les poids du discriminateur ω sont fixés. L'erreur de classification est retro-propagée à travers le discriminateur puis le générateur pour calculer le gradient de l'erreur par rapport aux poids θ et une modification de ces poids est alors proposée par l'algorithme d'optimisation. Ces deux étapes sont répétées suivant le nombre d'itération défini au préalable. Chacune des étapes améliore successivement les performances du discriminateur et du générateur. Cela permet *in fine* d'obtenir un réseau génératif capable de prédire des données extrêmement proches des données d'entraînement.

Ce type d'architecture en tandem a été notamment utilisé pour générer des images ressemblants à des photographies d'objets avec des résultats remarquables : il est souvent impossible de faire une distinction entre les images générées et celles utilisées pour l'entraînement [130, 131]. Plusieurs écueils sont récurrents lors de l'apprentissage :

Non convergence La fonction coût ne converge jamais vers une valeur stable.

Effondrement des modes Le générateur ne prédit que quelques solutions quelque soit le vecteur d'entrée [132].

Disparition du gradient Le gradient de la fonction de coût devient nul lors de sa rétro-propagation, empêchant tout entraînement.

Sur-apprentissage Le discriminateur dépend trop des données d'apprentissage [133].

Quelques variantes de GAN ont été proposées pour améliorer leur efficacité et les adapter à d'autres problèmes : le RepGan [134] modifie un GAN pour trouver des représentations pertinentes des données. Le Réseau Neuronal Adverse Génératif de Wasserstein (WGAN) intègre la distance de Wasserstein issue de la théorie du transport optimal (voir Chapitre 5) dans la fonction de coût.

Ajout d'information Dans la formulation classique des GANs décrite précédemment, l'entrée du générateur est un bruit aléatoire qui ne contient pas d'informations spécifiques sur les données d'apprentissage. La dimension du vecteur d'entrée est déterminée avant l'entraînement, mais rien ne garantit que cette dimension soit pertinente pour représenter correctement les données. De plus, il est impossible de donner un sens physique aux

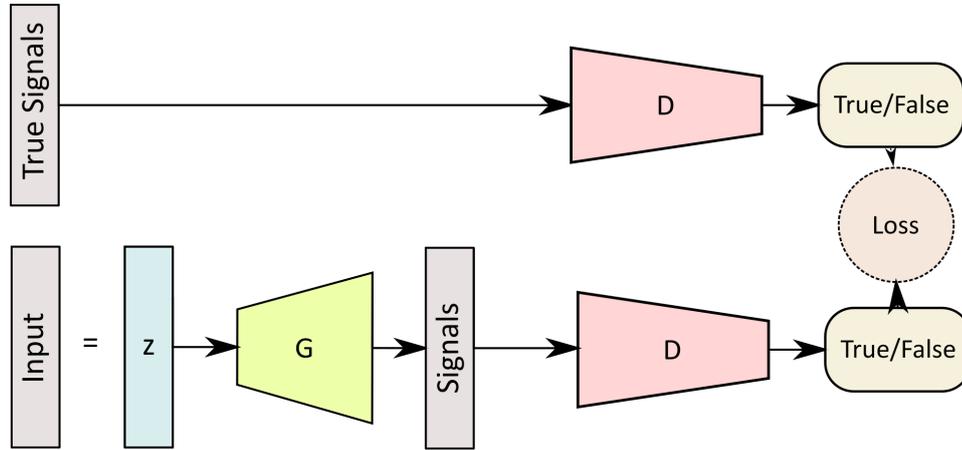
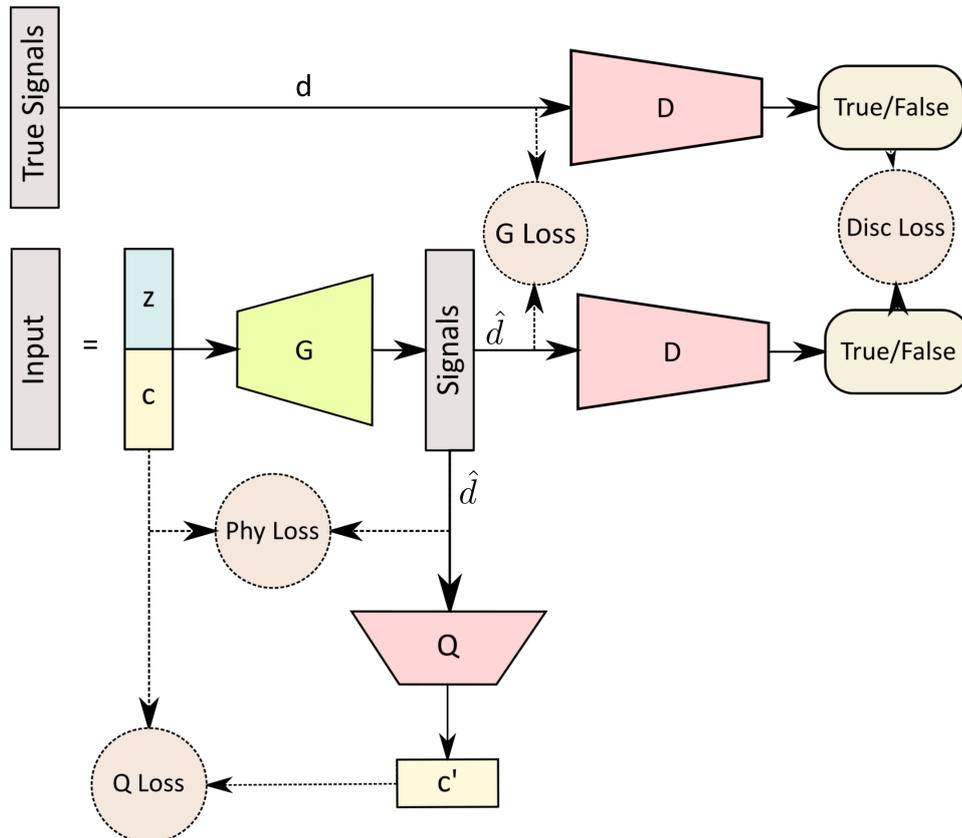


FIGURE 3.3 – Schéma du GAN classique



(a) Schéma du Info-GAN

éléments qui constituent ce vecteur. Dans le but de donner plus de sens à la variable \mathbf{z} , l'InfoGAN a été proposé dans [135]. Le vecteur d'entrée \mathbf{z} se compose désormais de deux parties : une première partie \mathbf{z} est une source de bruit comme dans le GAN classique et la seconde partie \mathbf{c} est un code qui contient des informations interprétables sur les données. Dans notre cas, le code \mathbf{c} correspond aux paramètres du dommage \mathbf{p}_d . Cette approche intègre au GAN des connaissances préalables sur les données à générer. Le terme $I(\mathbf{c}, G(\mathbf{Z}, \mathbf{c}))$ caractérise la quantité d'information apprise par $G(\mathbf{Z}, \mathbf{c})$ à propos de \mathbf{c} et se calcule en utilisant deux termes d'entropie :

$$I(\mathbf{c}', G(\mathbf{z}, \mathbf{c})) = H(\mathbf{c}') - H(\mathbf{c}' | G(\mathbf{z}, \mathbf{c})) \quad (3.13)$$

$$= H(G(\mathbf{z}, \mathbf{c})) - H(G(\mathbf{z}, \mathbf{c}) | \mathbf{c}') \quad (3.14)$$

avec : $H(\mathbf{d})$ l'entropie de la variable aléatoire \mathbf{d} ,

$H(\mathbf{d} | \mathbf{c})$ l'entropie conditionnelle des variables \mathbf{d} et \mathbf{c} .

Si les variables $G(\mathbf{z}, \mathbf{c})$ et \mathbf{c} sont totalement indépendantes alors $I(\mathbf{c}, G(\mathbf{z}, \mathbf{c}))$ est nul. Maximiser $I(\mathbf{c}, G(\mathbf{z}, \mathbf{c}))$ revient à contraindre une relation déterministe entre les deux variables. En pratique, le terme d'information mutuelle est difficile à maximiser car il nécessite d'avoir accès à la distribution postérieure $P(\mathbf{c} | \mathbf{d})$. Il est cependant possible d'obtenir une limite inférieure en définissant une distribution auxiliaire $Q(\mathbf{c} | \mathbf{d})$ pour approximer $P(\mathbf{c} | \mathbf{d})$. Cette technique est connue sous le nom de *Variational Information Maximization* [136]. D'après [135], le terme $I(\mathbf{c}, G(\mathbf{z}, \mathbf{c}))$ est minimisé par :

$$I(\mathbf{c}, G(\mathbf{z}, \mathbf{c})) = H(\mathbf{c}) - H(\mathbf{c} | G(\mathbf{z}, \mathbf{c})) \quad (3.15)$$

$$\geq \mathbb{E}_{\mathbf{d} \sim G(\mathbf{z}, \mathbf{c})} \left[\mathbb{E}_{\mathbf{c} \sim P(\mathbf{c} | \mathbf{d})} [\log Q(\mathbf{c} | \mathbf{d})] \right] + H(\mathbf{c}) = \mathcal{L}_{Info}(G, Q) \quad (3.16)$$

Dans l'équation 3.15 la quantité à maximiser est la log-probablité de la distribution auxiliaire prédite par Q . En pratique, Q est un réseau dont la partie convolutive est identique à celle du discriminateur et dont la partie entièrement connectée est adaptée pour résoudre le problème de régression. La maximisation du terme de l'information peut alors se faire par rétro-propagation du gradient comme lors des étapes d'entraînement du GAN classique. De plus, le partage de la partie convolutive avec le discriminateur limite le nombre de poids supplémentaires rendant la durée d'entraînement d'un InfoGAN compétitive avec celle d'un GAN classique.

Ajout de supervision L'InfoGAN est initialement proposé pour un apprentissage entièrement non-supervisé : les labels des données d'entraînement ne sont pas connus. Un guidage de l'entraînement par de la semi-supervision est proposé dans [137] en intégrant dans la fonction de coût du discriminateur auxiliaire quelques données labellisées. Dans

la mesure où les paramètres \mathbf{p}_d associés aux signaux \mathbf{d} sont connus dans notre cas, nous proposons de modifier les fonctions de coût du générateur et du discriminateur pour contraindre la supervision.

Le générateur doit reconstruire avec précision les signaux \mathbf{d} associés aux paramètres du dommage \mathbf{p}_d , ce qui se traduit par le calcul de la Erreur Quadratique Moyenne (*Mean Squared Error* en anglais, MSE) suivante :

$$\mathcal{L}_s(G) = \mathbb{E}_{(\mathbf{p}_d, \mathbf{d}) \sim \mathcal{S}} MSE(G(\mathbf{p}_d, \mathbf{z}), \mathbf{d}) \quad (3.17)$$

Le réseau auxiliaire Q a la tâche de retrouver les paramètres \mathbf{p}_d associés aux signaux \mathbf{d} , ce qui se traduit par le calcul de la MSE suivante :

$$\mathcal{L}_s(Q) = \mathbb{E}_{(\mathbf{p}_d, \mathbf{d}) \sim \mathcal{S}} MSE(Q(\mathbf{d}), \mathbf{p}_d) \quad (3.18)$$

Ajout de physique Les méthodes d'apprentissage profond sont des boites noires dont les prédictions sont difficiles à interpréter. De plus, dans la mesure où l'apprentissage se fait à partir de données, la physique du problème n'est pas directement intégrée au modèle. Nous proposons alors de pénaliser la fonction de coût du générateur pour ajouter des contraintes physiques lors de l'entraînement : le générateur sera pénalisé si ses prédictions ne respectent pas la physique sous-jacente.

L'interaction des ondes de Lamb avec un dommage, même modélisée simplement, reste un problème complexe. Les modèles analytiques existent mais sont limités à des cas particuliers. Nous pouvons tout de même trouver une loi simple qui estime le temps de vol du premier paquet d'onde ayant interagit avec le dommage et arrivant sur le capteur à partir des vitesses de groupes. Si le temps de vol du signal prédit par le générateur ne correspond pas à celui théorique calculé à partir de la position du dommage, alors le générateur est pénalisé. Ainsi, nous assurons que les prédictions du générateur respecte la physique des temps de vol.

Prenons le cas simple d'un unique chemin entre un PZT actionneur (PZT i) et un PZT capteur (PZT j) (Figure 3.5). Nous notons d_i et d_j la distance respective entre le PZT et le dommage et θ_i , θ_j les angles associés. Le matériau étant légèrement anisotrope, la vitesse de groupe dépend de l'angle de propagation et est notée $V_g(\theta)$. Le calcul du temps de vol t_{ij} du paquet d'ondes passant par le dommage peut alors se calculer simplement :

$$t_{th,ij} = d_i/V_g(\theta_i) + d_j/V_g(\theta_j) \quad (3.19)$$

Ce temps de vol théorique est comparé avec celui des signaux prédits par le générateur $t_{pred,12}$.

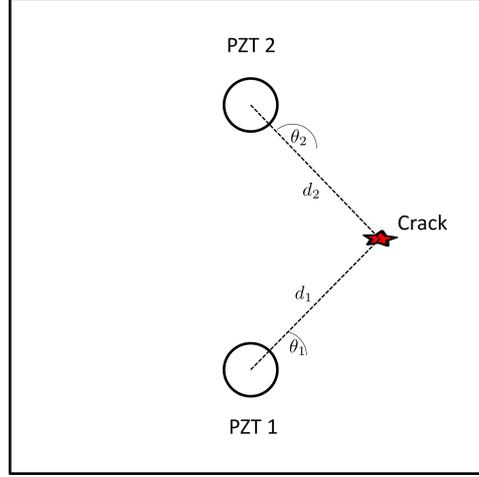


FIGURE 3.5 – Chemin du PZT1 au PZT2 passant par le dommage

Fonction de coût Au final , le problème d'optimisation à résoudre devient alors :

$$\min_{G,Q} \max_D \mathcal{L}_{\text{InfoGAN}}(D, G, Q) = \mathcal{L}_{\text{Adv}}(D, G) - \alpha \mathcal{L}_{\text{Info}}(G, Q) + \beta \mathcal{L}_s(G) + \gamma \mathcal{L}_s(Q) + \delta \mathcal{L}_\phi(G) \quad (3.20)$$

avec :

$$\mathcal{L}_{\text{Adv}}(D, G) = \mathbb{E}_{\mathbf{d} \sim \mathcal{D}}[\log D(\mathbf{d})] + \mathbb{E}_{\mathbf{c} \sim \mathcal{P}, \mathbf{z} \sim \text{noise}}[\log(1 - D(G(\mathbf{c}, \mathbf{z})))]$$

$$\mathcal{L}_{\text{Info}}(Q) = \mathbb{E}_{\mathbf{c} \sim \mathcal{P}, \hat{\mathbf{d}} \sim P_G}[\log Q(\mathbf{c} | \hat{\mathbf{d}})] + H(\mathbf{c}),$$

$$\mathcal{L}_s(Q) = \mathbb{E}_{(\mathbf{p}_d, \mathbf{d}) \sim \mathcal{S}} \text{MSE}(Q(\mathbf{d}), \mathbf{p}_d),$$

$$\mathcal{L}_s(G) = \mathbb{E}_{(\mathbf{p}_d, \mathbf{d}) \sim \mathcal{S}} \text{MSE}(G(\mathbf{p}_d, \mathbf{z}), \mathbf{d}),$$

\mathcal{L}_ϕ la pénalisation physique des prédictions du générateur,
 $\alpha, \beta, \gamma, \delta$ les hyperparamètres pondérant les coûts.

Définition des architectures Les architectures du générateur et du discriminateur sont visibles sur les Figures 3.6 et résumées dans les Tableau 3.4. Elles sont déterminées en s'inspirant de la démarche explicitée dans le Chapitre 4.3.3.

3.4 Processus d'approximation du problème direct

La construction d'un métamodèle suit le processus présenté Figure 3.7, intégré dans une chaîne de calcul sous Matlab et faisant appel à des codes Python. Dans un premier temps, l'échantillonnage définit les données à collecter pour l'apprentissage. Les signaux sont ensuite mis au format désiré et compressés. Un pré-traitement (*preprocessing* en anglais) est appliqué aux données d'entrée et/ou de sortie du métamodèle qui est alors entraîné. Le processus d'utilisation du métamodèle suit une logique similaire : les paramètres d'entrée subissent le pré-traitement configuré lors de l'entraînement, le métamodèle prédit les sorties et la décompression permet d'obtenir les signaux de SHM.

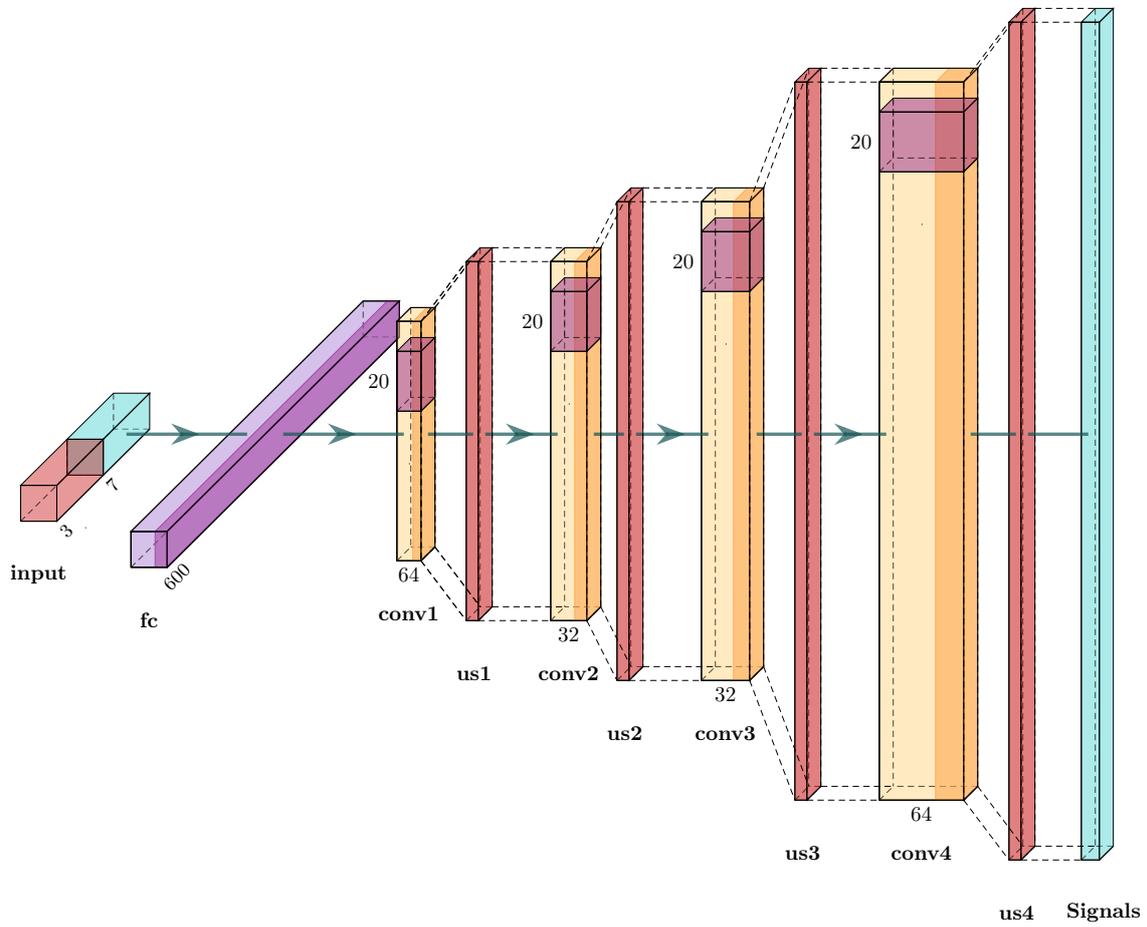
Algorithm 2: Supervised Info-Gan training loop

Input: Discriminator D and generator G with respective weights ω_0 and θ_0 Hyper parameters n_{epoch} , n_{batch} , α, β, γ **Output:** Trained generator G and discriminator D **Data:** Training set $(\mathbf{p}_d^i, \mathbf{d}^i)_{1 < i < n}$

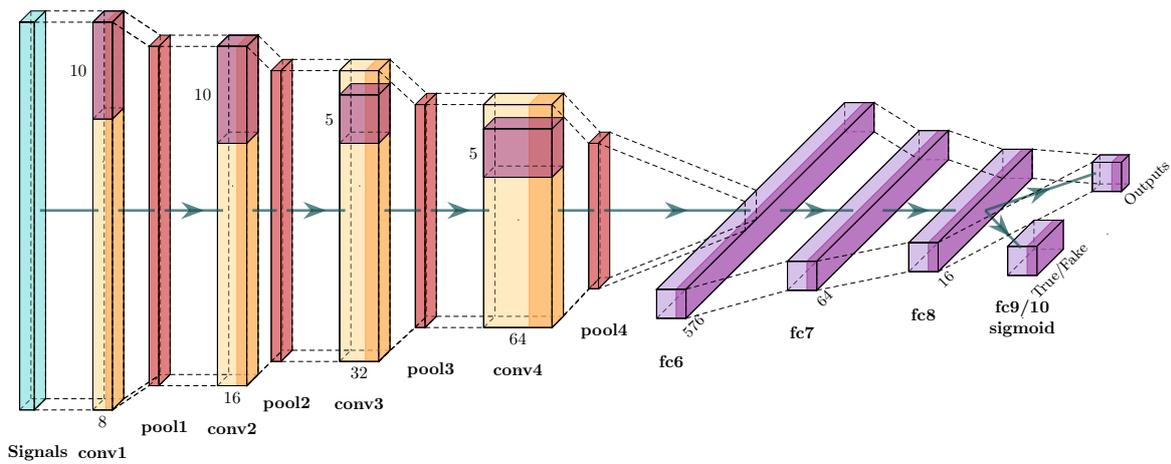
```

1 while  $i_{epoch} \leq n_{epoch}$  do
2   Divide training data set in  $n_{batch}$  batches
3   for  $i_{batch} = [1 : n_{batch}]$  do
4     Predictions :
5      $\mathbf{c} \sim \mathcal{U}_{[0,1]}$ ,  $\mathbf{z} \sim Noise$ 
6     Compute generator outputs for the batch  $\hat{\mathbf{d}} = G_\theta(\mathbf{c}, \mathbf{z})$ 
7     Compute discriminator outputs for the batch :
8      $\hat{y} = D_\omega(\hat{\mathbf{d}})$ ;  $y = D_\omega(\mathbf{d})$ ;
9      $\hat{\mathbf{c}} = Q_\omega(\hat{\mathbf{d}})$ ;  $\mathbf{c} = Q_\omega(\mathbf{d})$ ;
10    Discriminator Training :
11    Compute discriminator loss values for the batch
12     $\mathcal{L}_{D,Q} = -\mathcal{L}_{Adv}(G, D) + \alpha\mathcal{L}_{Info}(Q) + \beta\mathcal{L}_{ss}(Q)$  with Equation 3.20
13    Compute the gradient of the loss  $\nabla_\omega \mathcal{L}_D$ 
14    Compute the new weights  $\omega'$  with the choosen optimizer to minimize  $\mathcal{L}_D$ 
15    Set  $\omega \leftarrow \omega'$ 
16    Generator Training :
17    Compute generator loss values for the batch
18     $\mathcal{L}_G = \mathcal{L}_{Adv}(G, D) + \alpha\mathcal{L}_{Info}(Q) + \gamma\mathcal{L}_{ss}(G)$  with Equation 3.20
19    Compute the gradient of the loss  $\nabla_\theta \mathcal{L}_G$ 
20    Compute the new weights  $\theta'$  with the choosen optimizer to minimize  $\mathcal{L}_G$ 
21    Set  $\theta \leftarrow \theta'$ 

```



(a) Générateur de signaux



(b) Discriminateur de signaux

FIGURE 3.6 – Architecture de l'Info-GAN

TABLE 3.4 – Architecture de l’Info-GAN

(a) Générateur G			(b) Discriminateur D		
Layer	Parameter	Value	Layer	Parameter	Value
Input	size	3 + 7	Input	size	
Dense	Number of neurons	600	Conv.	Filter number \times size	64x20
Act.	Function	ReLU	MaxPooling	Window size	4
BN			Act.	Function	ReLU
Conv.	Filter number \times size	64x20	BN		
UpSampling	r	4	Conv.	Filter number \times size	32x20
Act.	Function	ReLU	MaxPooling	Window size	4
BN			Act.	Function	ReLU
Conv.	Filter number \times size	32x20	BN		
UpSampling	r	2	Conv.	Filter number \times size	16x20
Act.	Function	ReLU	MaxPooling	Window size	4
BN			Act.	Function	ReLU
Conv.	Filter number \times size	16x20	BN		
UpSampling	r	2	Conv.	Filter number \times size	1x20
Act.	Function	ReLU	Act.	Function	ReLU
BN			MaxPooling	Window size	4
Conv.	Filter number \times size	1x20	BN		
Act.	Function	ReLU	Dense	Hidden neurons	64
			Act.	Function	ReLU
			Dense	Hidden neurons	16

3.4.1 Échantillonnage de l’espace paramétrique

Un apprentissage supervisé s’appuie sur des données recueillies au préalable. Le choix des couples entrée-sortie $(\mathbf{p}_i, \mathbf{d}_i)_{1 \leq i \leq N}$, appelé échantillonnage, est important pour la précision et la rapidité de l’apprentissage. Il doit parcourir l’ensemble de l’espace paramétrique \mathcal{P} en évaluant le modèle sur un certain nombre d’observations. Les stratégies d’échantillonnage trouvent leurs origines dans l’étude de phénomènes physiques par des plans d’expériences adaptés aux besoins et aux capacités expérimentales. Pour la construction d’un métamodèle, l’échantillonnage doit être adapté à la méthode utilisée et aux capacités de calculs disponibles. Les métamodèles présentés dans ce chapitre sont construits avec des données exclusivement numériques mais il est possible d’utiliser des données expérimentales ou bien un mix des deux pour les modèles hybrides [138]. Deux stratégies d’échantillonnage ont été retenues dans ces travaux (voir la Figure 3.9) en fonction des méthodes d’apprentissage utilisées :

Grille L’espace paramétrique est découpé suivant une grille régulière afin de le parcourir dans son ensemble. Dans le cas de dimensions nombreuses, le nombre d’observations devient immense et l’échantillonnage très coûteux.

Hypercube Latin (LHS) L’espace paramétrique est divisé en M intervalles réguliers puis un unique échantillon est tiré aléatoirement dans chaque intervalle [139].

La PGD est une méthode contraignante sur l’échantillonnage puisqu’elle impose une

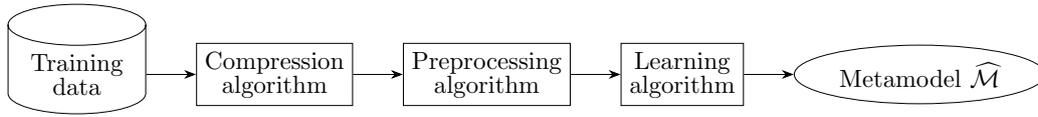


FIGURE 3.7 – Processus d'entraînement d'un métamodèle

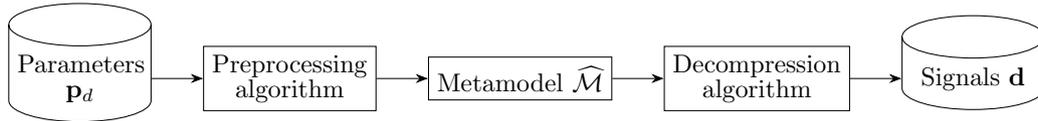
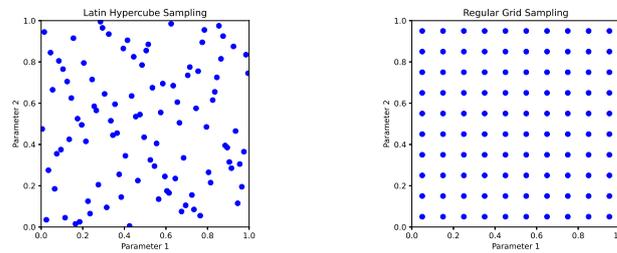


FIGURE 3.8 – Processus de prédiction avec un métamodèle



(a) Hypercube Latin

(b) Grille régulière

FIGURE 3.9 – Stratégies d'échantillonnage courantes : exemple pour un espace paramétrique à deux dimensions

grille (régulière ou non) dont tous les éléments doivent être présents. Lorsque le nombre de paramètres devient élevé, cette méthode est difficile à déployer. Pour ces raisons notamment, elle ne sera déployée que sur le cas de la poutre dans la Section 3.5.2. Les autres méthodes admettent plus de libertés dans le choix de l'échantillonnage, le LHS très répandu dans la littérature sera alors utilisé sur les autres cas d'études.

3.4.2 Compression des signaux

Une première étape préalable à tout apprentissage définit le format des données d'entrée et de sortie des données. En SHM, les mesures prennent la forme de signaux temporels pour chaque chemin d'actionneur-capteur. Plusieurs mises en forme sont possibles : les signaux peuvent être concaténés en un unique vecteur, mis sous la forme d'un tenseur à 3 dimensions (une pour l'actionneur, une pour le capteur et une pour le temps), subir des transformations issues de méthodes de traitements du signal (transformations temps-fréquence, compression) ou subir des transformations typiques du SHM (calcul de DIs, de TOF).

Les méthodes d'interpolation à noyau nécessitent de compresser les signaux afin de réduire la dimension des variables de sorties. Le choix de la représentation des signaux

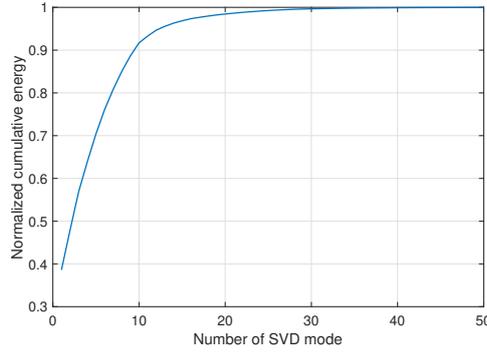


FIGURE 3.10 – Énergie cumulée de la SVD appliquée aux signaux temporels de la poutre

est important pour obtenir un métamodèle précis mais aussi pour faciliter son entraînement. La représentation des données doit à la fois être parcimonieuse [140] et devrait idéalement avoir un sens physique. Il s’agit de déterminer sous quel format exprimer la matrice de sortie D du métamodèle. 4 représentations ont été envisagées : la représentation temporelle classique (TMP), deux compressions via la SVD (domaine fréquentiel et temporel), une compression via un Poursuite de Correspondance (*Matching Pursuit* en anglais, MP).

Temporelle Les modèles numériques décrits précédemment donnent en sortie les signaux temporels de chacun des PZT intégrés de la structure. Cependant, beaucoup de méthodes de métamodélisation prennent en considération les sorties indépendamment les unes des autres et construisent en réalité un métamodèle par sortie. Cela rend l’apprentissage long et redondant. Cette représentation est donc écartée au profit de représentations qui permettent une compression du signal.

Compression à l’aide de la Décomposition en Valeur Singulière L’ensemble des signaux qui composent le jeu de données d’apprentissage (la matrice D) est décomposée par la SVD et les principaux modes sont retenus en appliquant un critère sur l’énergie résiduelle ce qui permet alors de compresser les données [116]. Pour rappel, toute matrice $M \in \mathbb{R}^{n \times m}$ dont les coefficients sont dans \mathbb{R} ou \mathbb{C} peut se décomposer en un produit de trois matrices tel que :

$$M = U\Sigma V^* \in \mathbb{R}^{n \times m} \quad (3.21)$$

avec : U et V des matrices unitaires,

$\Sigma = \text{diag}(\sigma_1, \dots, \sigma_n) \in \mathbb{R}^{n \times m}$ une matrice diagonale positive dont les coefficients sont appelés valeurs singulières,

$U = (u_1, \dots, u_n)$ les vecteurs singuliers de gauche,

$V = (v_1, \dots, v_m)$ les vecteurs singuliers de droite.

Chaque colonne de la matrice V correspond à un vecteur d'une base tronquée suivant un critère sur l'énergie résiduelle [116] :

$$\frac{\sum_{i=1}^r \sigma_i}{\sum_{i=1}^n \sigma_i} \geq 98\% \quad (3.22)$$

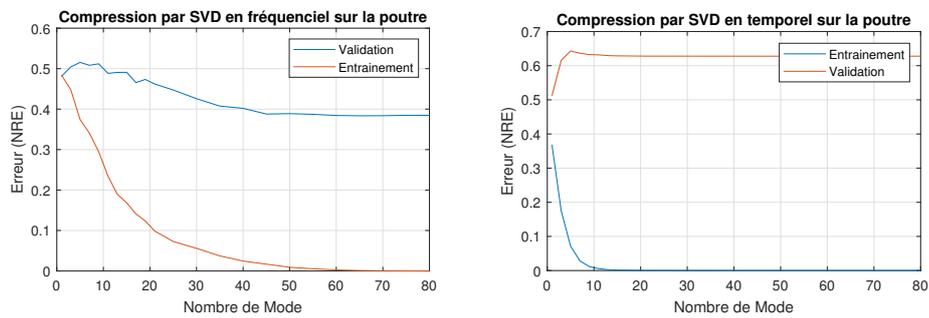
avec : n le nombre d'échantillons,
 r le nombre de modes dans la base réduite,
 $\{\sigma_i\}_1^n$ les valeurs singulières classées par valeurs décroissantes.

Domaine temporel Dans un premier temps, la SVD est appliquée directement sur les signaux temporels. Avec le critère sur l'énergie, la base réduite des signaux de la plaque S2 contient 16 vecteurs (Figure 3.10). Un inconvénient majeur de la SVD est l'absence de lien entre la physique du système et les modes obtenues. De plus, lorsque le temps de vol de l'écho du dommage varie fortement, ce qui correspond mathématiquement à une translation, la SVD ne parvient pas à représenter le signal correctement. Un grand nombre de mode est alors nécessaire et la compression perd en intérêt. La base calculée par la SVD ne permet pas de représenter correctement un signal avec un temps de vol nouveau, qui ne faisait pas parti de la base de compression. Ses performances en généralisation dans ce cadre applicatif sont médiocres. Pour le cas de la poutre, avec des variations importantes sur les temps de vols, cette méthode de compression n'est pas appropriée. Cette méthode de compression est en revanche plus adaptée dans le cas où les signaux se composent de paquets proches les uns des autres comme sur la structure S2.

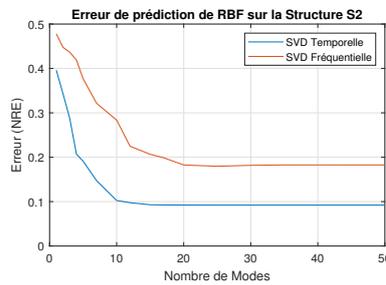
Domaine fréquentiel Le domaine fréquentiel semble plus adapté pour représenter des transformation tel qu'un changement de phase. La transformée de Fourier est alors appliquée aux données temporelles et deux SVD permettent de compresser les données : une pour l'amplitude et une pour la phase. Cependant ce changement de domaine n'induit pas d'amélioration nette des résultats (Figure 3.11) de prédiction du métamodèles.

Dans les deux domaines, l'augmentation du nombre de vecteurs dans les bases permet de réduire à zéro l'erreur sur les données d'entraînement. En revanche, sur les données de validation l'erreur de prédiction atteint une limite ce qui suggère que les coefficients et les bases extraites par la SVD ne permettent pas une parfaite généralisation des métamodèles.

Poursuite de correspondance adaptée



(a) SVD dans le domaine fréquentiel sur la poutre (b) SVD dans le domaine temporel sur la poutre



(c) Évolution de l'erreur de prédictions de la RBF sur les données de validation pour le domaine temporel et fréquentiel sur la structure S2

FIGURE 3.11 – Comparaison des erreurs de prédictions de la RBF avec une compression par SVD sur les signaux dans le domaine fréquentiel et temporel

Poursuite de correspondance Le MP est un algorithme développé par [141] pour décomposer les signaux dans un dictionnaire d'atomes. L'usage du MP intéresse particulièrement la communauté SHM car il permet d'identifier et d'extraire des paquets d'ondes des signaux. Combiné avec des méthodes d'apprentissage machine (SVM et ANN) dans [142], le MP est utile pour détecter automatiquement des dommages sur une plaque métallique. Le MP est utile dans [143] pour extraire des informations sur une fissure dans une tige de métal. Combiné avec la théorie de Love, cette méthode parvient à localiser et quantifier un dommage dans [143]. Une stratégie de détection de dommage sans référence à l'aide du MP est proposée dans [144]. Les propriétés du MP sont utilisées pour décomposer les mesures de propagation d'ondes de Lamb et identifier les différents modes qui se propagent dans ???. Le MP est également utilisé dans [145] pour compresser des signaux de CND par UT. Le MP a d'excellentes propriétés de compression de signaux en attribuant un poids à quelques atomes du dictionnaire. Le dictionnaire regroupe généralement des atomes de différents types (Gabor, ondelette, etc.). Le résultat de la compression est alors un vecteur de poids très parcimonieux : chaque indice correspond au numéro d'un atome du dictionnaire. La décompression se fait par un simple produit matriciel entre le dictionnaire et le vecteur des poids.

Modification En choisissant judicieusement les atomes qui composent le dictionnaire il est possible de distinguer les paquets d'ondes qui arrivent sur le récepteur et de faciliter la généralisation des prédictions. Il est considéré que le signal peut prendre la forme d'une somme d'un unique atome qui se translate. Le signal se décompose alors de la forme suivante :

$$d(\mathbf{p}_d) = \sum_{i=1}^r \alpha_i(\mathbf{p}_d) \Psi(t - \tau_i(\mathbf{p}_d)) \quad (3.23)$$

avec : Ψ l'atome (ici un Burst similaire au signal d'excitation),
 τ_i le déphasage du paquet i ,
 α_i l'amplitude du paquet i ,
 \mathbf{p}_d les paramètres du dommage,
 r le nombre de paquets considérés.

Cette décomposition a un sens physique car il est possible de relier τ_i à la distance parcourue par l'onde et α_i aux caractéristiques du dommage et à la distance parcourue par l'onde. Sur la poutre, cette décomposition se montre particulièrement efficace (Figure 3.12). Dans cet exemple, l'atome Ψ est un Burst de fréquence centrale 100kHz et de 6 cycles. Une partie du signal correspondant aux paquets de faible amplitude est perdue mais les principaux paquets sont préservés. Deux paquets suffisent ici à représenter le signal, ce qui induit 4 variables au total : (α_1, τ_1) pour le premier paquet et (α_2, τ_2) pour

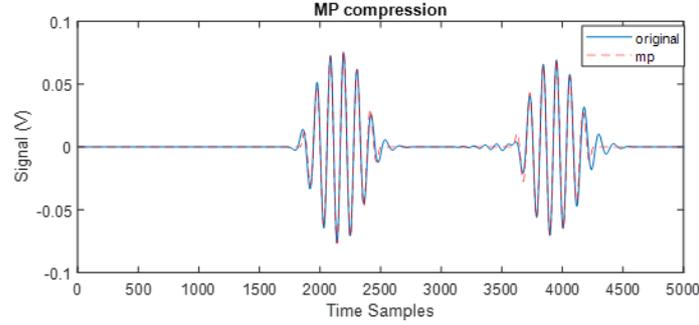


FIGURE 3.12 – Exemple d’une observation de la poutre compressée par MP avec deux paquets.

le second (Figure 3.12). Dans le cas de la poutre, l’amplitude du premier paquet dépend de la position du dommage et de sa sévérité tandis que son temps d’arrivée dépend de la position (Figure 2.11). Les évolutions monotones de ces variables seront faciles à interpoler par un métamodèle à noyau. Cette décomposition ne fonctionne que si les paquets d’ondes se distinguent clairement. Dans le cas contraire, les interférences des paquets entre eux rendent le MP inefficace. L’évolution des amplitudes en fonction de la position du dommage est un phénomène complexe qui est difficile à interpoler. Ainsi dans le cas de la structure S2, le MP donne des résultats décevants. Un autre inconvénient de cet algorithme (Algorithme 3) est sa lenteur, particulièrement lorsque les signaux sont longs et que le nombre d’atomes i dans le dictionnaire est important.

Algorithm 3: Matching Pursuit

Input: y : signal
 \mathcal{D} : Dictionary with normalised columns Φ_i
Output: list of coefficients $(\alpha_i)_{i=1}^r$ and $(\theta_i)_{i=1}^r$

- 1 $R_1 \leftarrow y$
- 2 $n \leftarrow 1$ **while** $R_i < \epsilon$ or $i < r$ **do**
- 3 Find $\phi_{\theta_i} \in \mathcal{D}$ that maximize $|\langle R_i | \phi_{\theta_i} \rangle|$
- 4 $\alpha_i \leftarrow \langle R_i | \phi_{\theta_i} \rangle$
- 5 $R_{i+1} \leftarrow R_i - \alpha_i \phi_{\theta_i}$
- 6 $i \leftarrow i + 1$

3.4.3 Pré-traitement des données

En entrée et/ou en sortie du métamodèle, les données sont transformées en fonction de la méthode d’apprentissage choisie selon deux méthodes paramétrées avec les données d’entraînement :

Minmax Les données sont normalisées et translatées pour avoir une valeur minimale égale à 0 et une valeur maximale égale à 1.

Échellonnement Les données sont centrées et réduites (espérance nulle et variance unitaire).

3.4.4 Entraînement et prédiction du métamodèle

L'entraînement optimise les poids du métamodèle à l'aide du jeu de donnée d'entraînement. La stratégie d'optimisation dépend de la méthode choisie (voir la Section 3.3). Après l'entraînement du métamodèle, il est utilisé pour prédire des nouveaux signaux pour des configurations de dommage inédites (Figure 3.8). La prédiction se déroule en plusieurs phases consécutives : le nouveau vecteur d'entrée \mathbf{p}^* est transformé par le pré-traitement configuré lors de la phase d'entraînement, le métamodèle prédit les nouveaux coefficients de la compression et enfin la décompression est appliquée pour obtenir les signaux.

3.5 Évaluation des méthodes retenues

L'évaluation de la capacité de généralisation d'un modèle se fait sur un ensemble de données qui n'a pas été utilisé durant l'entraînement. Dans l'évaluation simple déployée dans ces travaux, le jeu de données initial est découpé une seule fois aléatoirement en un jeu d'entraînement et un jeu de validation. La distribution des données peut alors avoir une influence sur la qualité de l'entraînement et sur l'évaluation. Il est généralement souhaitable que le jeu d'entraînement et le jeu de validation soient construits suivant la même distribution.

3.5.1 Évaluation de la RBF

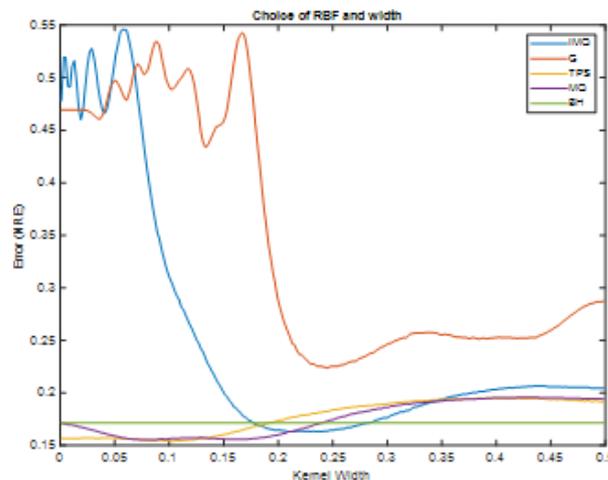


FIGURE 3.13 – Erreur en fonction de la largeur ε pour différentes fonctions RBF pour la poutre avec MP

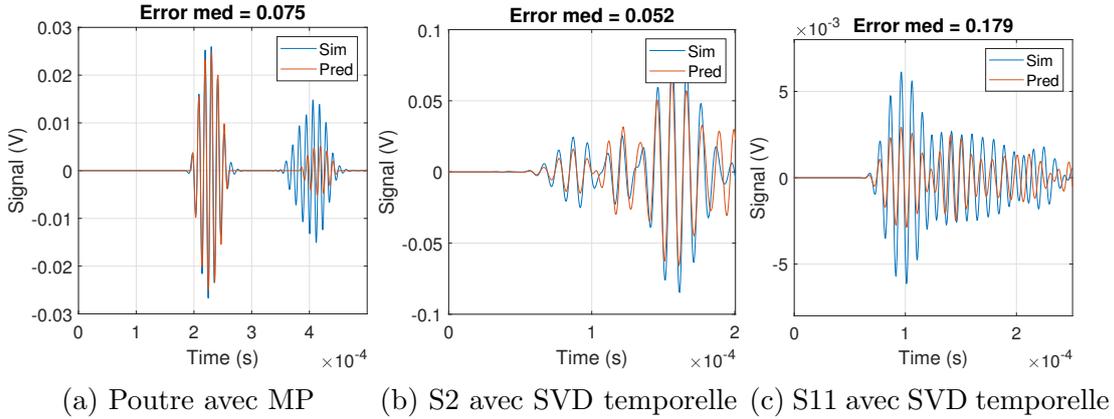


FIGURE 3.14 – Erreur médiane de l'évaluation de la RBF

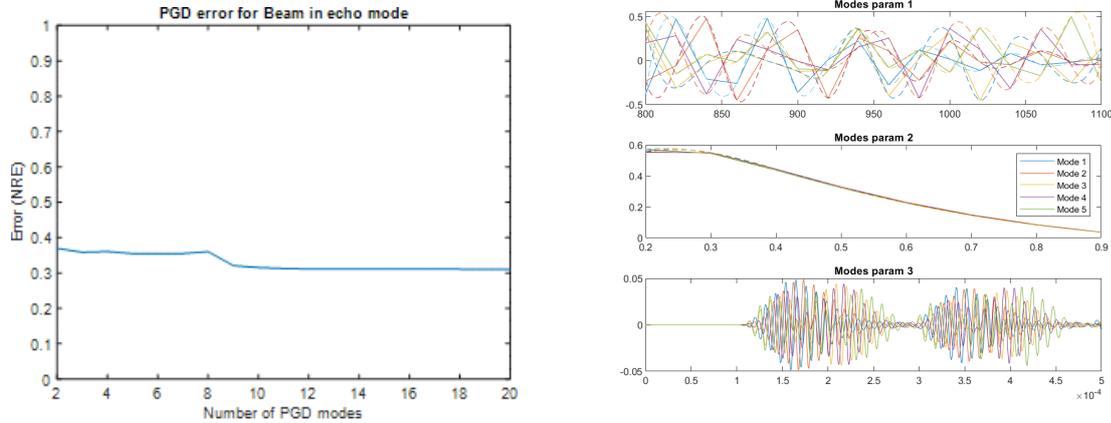
La Figure 3.14a présente le signal prédit avec l'erreur médiane (50% des prédictions sont meilleures et 50% sont pires) pour chacun des cas d'études avec la compression donnant les meilleurs performances. Pour plus de détails sur les résultats, les signaux prédits ayant l'erreur minimale, les signaux prédits ayant l'erreur maximale et la distribution des erreurs sont donnés en Annexe B Figure B.1. L'interpolation par RBF se montre efficace, rapide et précise à condition que la compression des signaux soit adaptée. Dans le cas de la poutre, le MP permet de représenter de manière pertinente les données et seulement 4 variables doivent être interpolées. La RBF prédit alors des signaux avec une erreur faible. Dans le cas de la structure S2, la compression par SVD donne de meilleurs résultats et l'interpolation des 20 coefficients de la base réduite permet à la RBF de prédire avec une relative précision. Dans le cas de la structure S11, aucune stratégie de compression ne permet d'obtenir une représentation facilitant la généralisation du métamodèle et l'erreur de prédiction est importante.

3.5.2 Évaluation de la PGD

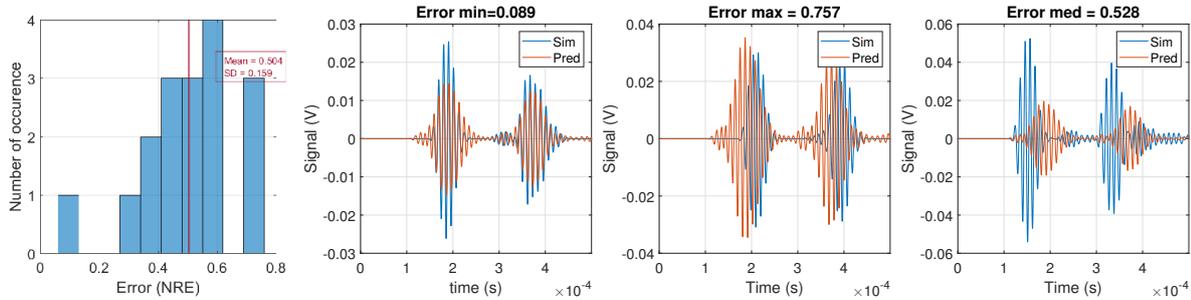
L'échantillonnage par une grille de l'espace paramétrique pour la structure poutre offre la possibilité de mettre les données sous une forme tensorielle avec dans ce cas 3 dimensions : une pour la position du dommage, une autre pour la sévérité et une dernière pour le temps. La PGD propose alors une décomposition de la forme suivante :

$$\widehat{\mathcal{M}}(\mathbf{p}_d) = \widehat{\mathcal{M}}(x, s, t) = \sum_{i=0}^r F_1^i(x) F_2^i(s) F_3^i(t) \quad (3.24)$$

La Figure 3.15a montre que le nombre de mode de la PGD a une influence faible sur l'erreur du métamodèle. L'erreur est importante, la PGD ne parvient pas à bien saisir la physique du système. Les modes obtenus par la PGD sont visibles sur la Figure 3.15b. L'origine mathématique de la PGD étant similaire à celle de la SVD, les inconvénients



(a) Erreur de prédiction en fonction du nombre de modes de la PGD (b) Modes de la PGD pour les 3 paramètres (position, sévérité, temps)



(a) Histogrammes des erreurs de prédictions (b) Erreur de prédiction minimale (c) Erreur de prédiction maximale (d) Erreur de prédiction maximale

FIGURE 3.16 – Évaluation de la PGD sur la structure poutre

listés pour la compression par SVD se retrouvent pour la PGD. La PGD, lorsqu'elle est calculée à partir des signaux temporels bruts, ne représente pas correctement un écho dont le temps de vol varie fortement. Une simple translation d'un paquet d'onde est une opération non-linéaire qui ne peut être représentée correctement par cette méthode. Le jeu de données de validation de la poutre qui se compose de points en dehors de la grille d'entraînement (Tableau 2.4) montre que cette méthode ne prédit pas correctement ces points (Figure 3.16). L'erreur de la prédiction croit fortement avec la distance au point d'apprentissage le plus proche. Une généralisation de la PGD à des points en dehors de la grille d'apprentissage est impossible avec ce type de données.

3.5.3 Évaluation des réseaux génératifs

Pour cette méthode, il n'est pas nécessaire de compresser les signaux, les signaux bruts sont utilisés directement et une représentation pertinente est déterminée lors de l'entraînement. Les bénéfices de l'ajout de la contrainte physique sur la qualité des pré-

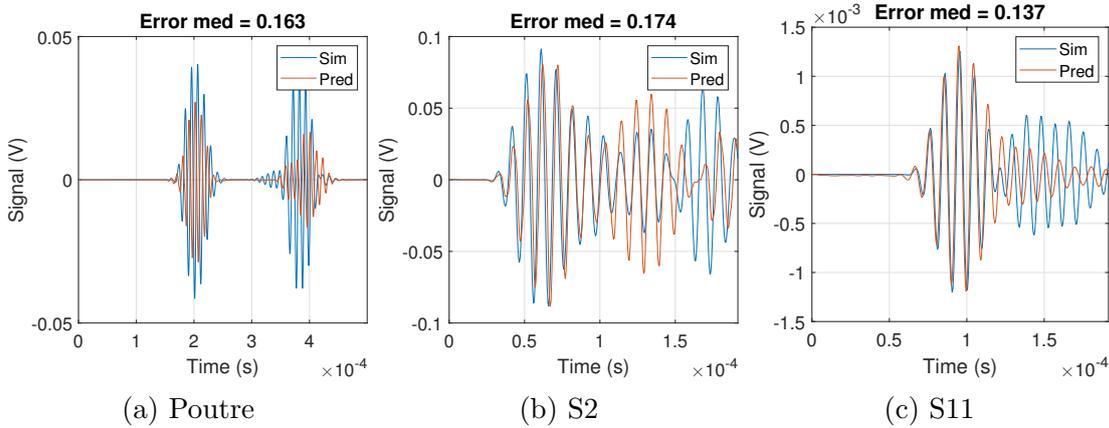


FIGURE 3.17 – Erreur médiane de l'évaluation de l'InfoGAN

dictions du modèle génératif sont difficiles à estimer, le modèle avec et sans physique converge vers la même valeur d'erreur. En revanche, cette physique permet de donner plus de confiance dans ces prédictions, un point important pour le déploiement de l'intelligence artificielle dans les procédures de maintenance. Le guidage par la supervision donne de l'importance aux parties des signaux les plus significatives pour la caractérisation des endommagements. Ainsi les signaux de la figure 3.17 montrent que les premiers paquets d'ondes sont correctement prédits par cette méthode. Des erreurs importantes subsistent cependant pour les paquets d'ondes suivants. Les erreurs sont du même ordre de grandeur pour les deux structures plaques, ce qui indique que l'ajout d'un paramètre supplémentaire a une faible influence sur la qualité des prédictions.

3.6 Bilan des évaluations des métamodèles

Les exemples étudiés montrent que les métamodèles à noyau permettent de prédire avec précision les signaux à condition de trouver une représentation adaptée. Dans le cas où les paquets d'onde se distinguent nettement, ce qui correspond aux structures de grande taille, la variante du MP proposée permet d'isoler les différents paquets et offre une représentation parcimonieuse avec un sens physique fort. Dans le cas contraire (l'exemple de la petite plaque S2), où les paquets d'onde interfèrent entre eux et ne se distinguent pas, la SVD permet alors de compresser rapidement les signaux. Pour le cas intermédiaire, comme la grande plaque s11, ni le MP ni la SVD offre une représentation facile à interpoler par les métamodèles. La recherche d'une représentation adaptée des signaux est donc toujours une question ouverte pour ce type de structure. Quelque soit la représentation choisie, si celle-ci est adaptée aux signaux, l'interpolation par RBF offre un moyen rapide et précis de construire un métamodèle. En revanche, l'approche par décomposition tensorielle via PGD ne permet pas d'obtenir un métamodèle de qualité.

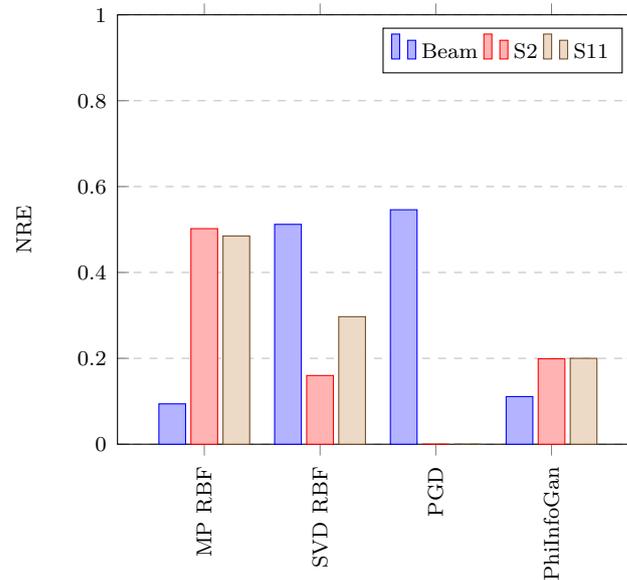


FIGURE 3.18 – Erreur moyenne (NRE) de prédictions des métamodèles sur les trois cas d'étude (Poutre, S2 et S11)

De plus, elle impose un échantillonnage par grille de l'espace paramétrique ce qui est très contraignant et très couteux si le nombre de paramètres étudiés augmente.

Les approches par apprentissage profond sont complexes à mettre en œuvre dans le cas de modèles génératifs. Il existe de nombreux paramètres à déterminer pour définir l'architecture des réseaux. L'approche s'appuyant sur des réseaux adverses guidé par de la supervision et enrichie par de la physique permet d'utiliser les GANs avec des bases de données de dimension réduite par rapport à l'usage usuel de ces méthodes. L'entraînement de ce réseau reste malgré tout long et couteux. Les hyperparamètres optimaux sont difficiles à déterminer en raison de la durée d'entraînement du modèle. Les poids de chacune des contributions de la fonction de coût ont une influence importante sur le résultat final et doivent être déterminés avec finesse. Les résultats du GAN sont cependant compétitifs avec les autres méthodes. Cette méthode offre une certaine souplesse dans son utilisation car les mêmes architectures sont utilisées quelque soit la structure et il n'y a pas de compression ni de formatage particulier à prévoir. De plus, le passage d'une poutre à une plaque ou bien l'ajout de paramètres d'endommagement supplémentaires n'ont pas d'influence significative sur la qualité des prédictions.

3.7 Conclusion

Les métamodèles sont des outils excellents pour prédire de nouveaux signaux de SHM avec une rapidité exceptionnelle. L'usage de métamodèles capables de prédire l'effet d'un dommage sur une structure réduit considérablement le temps de calcul et il devient pos-

sible de tester les procédures SHM sur un grand nombre de configurations de dommage. De plus, ces métamodèles peuvent s'avérer utiles pour retrouver les paramètres d'un dommage dans une stratégie de résolution inverse qui sera déployée au chapitre suivant. Des difficultés liées à la complexité de la physique des ondes de Lamb et de leurs interactions avec les dommages rendent complexe l'usage de méthodes d'apprentissage. Les bases de données doivent être riches avec un échantillonnage de l'espace paramétrique dense pour garantir une bonne généralisation des modèles entraînés.

4

Résolution du problème inverse

Résumé

La résolution du problème inverse vise à identifier les paramètres d'un dommage à partir des signaux mesurés sur une structure équipée d'éléments piézoélectriques. Une première approche exploite les métamodèles construits pour approximer le problème direct en les combinant à un algorithme génétique pour minimiser l'erreur entre les signaux observés et prédits par le métamodèle. Le choix de l'erreur influence fortement le résultat final et ce type de résolution est difficile si le problème est mal posé. Une seconde approche entraîne un CNN pour estimer les paramètres du dommage à partir des signaux. Elle se montre plus fiable les structures étudiées et est robuste à un biais sur la position des PZTs et à un bruit de mesure. Le CNN entraîné est ensuite utilisé avec succès pour prédire la position du dommage sur les plaques endommagées expérimentalement.

Sommaire

4.1	Introduction	92
4.2	Approche déterministe exploitant les métamodèles	93
4.2.1	Généralités sur la résolution inverse déterministe	93
4.2.2	Détermination d'une fonction de coût spécifique au SHM	94
4.2.3	Minimisation de la fonction de coût	94
4.2.4	Évaluation sur les structures numériques	94
4.3	Résolution inverse à l'aide d'un réseau de neurones convolutifs	98
4.3.1	Choix du CNN	98
4.3.2	Du modèle numérique de S11 aux dommages expérimentaux	98
4.3.3	Architectures proposées	100
4.3.4	Évaluation des CNNs	105
4.3.5	Discussions sur les approches directe et inverse	108
4.4	Conclusion	109

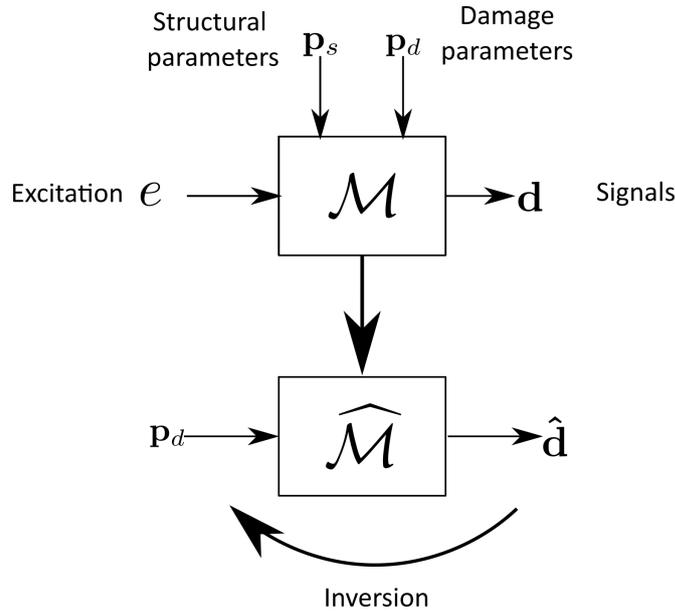


FIGURE 4.1 – La résolution inverse vise à trouver les paramètres du dommages \mathbf{p}_d à l'aide des prédictions rapides $\widehat{\mathbf{d}}$ du métamodèle $\widehat{\mathcal{M}}$

4.1 Introduction

Contexte Les notations des chapitres précédents sur la modélisation d'un système de SHM par onde de Lamb (Section 1.5) sont reprises ici. Les métamodèles prédisent très rapidement les résultats d'une simulation habituellement longue. Ainsi, il peut être envisagé de les utiliser pour la résolution du problème inverse qui consiste à rechercher les valeurs des paramètres du dommage \mathbf{p}_d qui ont permis d'obtenir une observation \mathbf{d}^{obs} (Figure 4.1). L'utilisation de métamodèles pour la résolution d'un problème inverse se retrouve notamment dans [13, 69, 86, 87, 90].

Objectifs Ce chapitre propose et compare deux approches pour la résolution du problème inverse. La première s'appuie sur le métamodèle direct construit au chapitre précédent et compare une valeur observée avec celles prédites à l'aide d'une fonction de coût. Une optimisation permet de minimiser ce coût et de calculer la configuration d'endommagement optimale. Une seconde approche entraîne des CNN pour résoudre le problème inverse

4.2 Approche déterministe exploitant les métamodèles

4.2.1 Généralités sur la résolution inverse déterministe

Dans le cadre déterministe, les problèmes inverses sont formulés sous la forme d'un problème d'optimisation qui cherche à minimiser une fonction de coût \mathcal{L} par la recherche d'un vecteur déterministe de paramètres \mathbf{p}_d^* minimisant \mathcal{L} .

$$\mathbf{p}_d^* = \underset{\mathbf{p}_d \in \mathcal{P}_d}{\operatorname{argmin}} \mathcal{L}(\mathbf{p}_d) \quad (4.1)$$

La principale tâche dans la résolution d'un problème inverse est alors de trouver une fonction de coût \mathcal{L} qui puisse produire de manière robuste une bonne estimation des paramètres. Cette fonction prend généralement la forme d'une erreur entre les sorties du modèle $\widehat{\mathcal{M}}$ pour une valeur de \mathbf{p}_d et les observations \mathbf{d}_{obs} . Après la définition de la fonction de coût, les algorithmes classiques de minimisation sont utilisés pour résoudre le problème inverse. Dans le cadre de la méthode des moindres carrés, l'erreur est calculée par la norme euclidienne et le problème inverse précédent devient alors :

$$\mathcal{L}(\mathbf{p}_d) = \|\widehat{\mathcal{M}}(\mathbf{p}_d) - \mathbf{d}^{obs}\|_2^2 \quad (4.2)$$

avec : $\widehat{\mathcal{M}}$ un métamodèle (ou tout modèle rapide à évaluer),
 \mathbf{p}_d les entrées du modèle,
 \mathbf{d}^{obs} des observations.

Cette méthode est très couramment utilisée, facile à déployer mais elle ne prend pas en compte la physique du problème à résoudre et elle peut avoir une faible performance en fonction de la nature du problème. Par exemple, cette formulation n'est pas robuste lorsque les données sont corrompues par un bruit non uniformément distribué [146]. Afin d'améliorer la robustesse, des termes de régularisation sont ajoutés. Lorsque des connaissances sont disponibles sur le niveau de bruit, une fonction des moindres carrés pondérée par le niveau de bruit de chaque observation peut être introduite.

Un autre problème de la méthode des moindres carrés est que le caractère mal posé du problème inverse peut être préservé. Si le nombre de données expérimentales n'est pas suffisant, la solution fournie peut être sensible aux conditions initiales. La fonction \mathcal{L} peut également avoir plusieurs minima locaux et la solution peut ne pas être unique. Ainsi, la minimisation est parfois très difficile et coûteuse. Une méthode qui peut aider à la minimisation est l'introduction d'un terme de régularisation $\mathcal{R}(\mathbf{p}_d)$ connu sous le nom de régularisation de Tikhonov.

$$\mathcal{L}'(\mathbf{p}_d) = \mathcal{L}(\mathbf{p}_d) + \alpha \mathcal{R}(\mathbf{p}_d) \quad (4.3)$$

avec : α un terme de pondération associé à la régularisation.

Un choix courant pour le terme de régularisation est de prendre $\mathcal{R}(\mathbf{p}_d) = \|\mathbf{p}_d - \mathbf{p}_d^0\|_2^2$ pour pénaliser les solutions trop éloignées d'un point \mathbf{p}_d^0 connu préalablement et supposé proche de la solution réelle. La régularisation peut aussi pénaliser les solutions qui ont une norme trop importante avec la forme simple $\mathcal{R}(\mathbf{p}_d) = \|\mathbf{\Gamma}\mathbf{p}_d\|_2^2$ où $\mathbf{\Gamma}$ est souvent égale à l'identité. Il existe une infinité de régularisations possibles et elles doivent être adaptées au problème posé et aux connaissances préalables sur sa solution.

4.2.2 Détermination d'une fonction de coût spécifique au SHM

Dans notre cas nous cherchons à identifier les paramètres (\mathbf{p}_d) de l'endommagement à partir d'un ensemble de signaux \mathbf{d}^{obs} mesurés sur chaque capteur. La détermination de la fonction de coût adaptée aux signaux du SHM est un point important pour mieux conditionner le problème, éviter les minima locaux, la sensibilité aux conditions initiales et l'instabilité de la résolution inverse.

Dans le cas du SHM, le dommage ne peut sortir des limites physiques de sa structure, les solutions en dehors de la plaque sont alors fortement pénalisées. Il en va de même pour les solutions dont la sévérité n'est pas entre 0 et 1. La fonction de coût est calculée ici à l'aide de deux DIs (NRE et CC dans le Tableau A.1) additionnés pour chacun des chemins actionneur-capteur (4.4). Cette erreur est sensible à l'énergie du signal par la NRE et au temps de vol des paquets d'onde par la CC.

$$\mathcal{L}(\mathbf{p}_d) = \sum_{i=1}^{n_{pzt}} \sum_{i \neq j, j=1}^{n_{pzt}} NRE(\widehat{\mathcal{M}}_{i,j}(\mathbf{p}_d), \mathbf{d}_{i,j}^{obs}) + CC(\widehat{\mathcal{M}}_{i,j}(\mathbf{p}_d), \mathbf{d}_{i,j}^{obs}) + \alpha \mathcal{R}(\mathbf{p}_d) \quad (4.4)$$

avec : $\widehat{\mathcal{M}}_{i,j}(\mathbf{p}_d)$ le signal prédit avec l'actionneur j et le capteur i ,
 $\mathbf{d}_{i,j}^{obs}$ le signal mesuré,
 α un terme de pondération associé à la régularisation,
 \mathcal{R} la régularisation qui pénalise les solutions en dehors de la structure.

4.2.3 Minimisation de la fonction de coût

Un algorithme par essaim particulaire minimise l'erreur caractérisant l'écart entre les signaux prédits par le métamodèle et les signaux mesurés. Cet algorithme permet de calculer efficacement le minimum globale d'une fonction de plusieurs variables.

4.2.4 Évaluation sur les structures numériques

Cette approche est testée sur chacune des structures numériques créées avec le métamodèle qui a obtenu les meilleurs résultats (Figure 3.18). Les Figures 4.3, 4.4 et 4.5

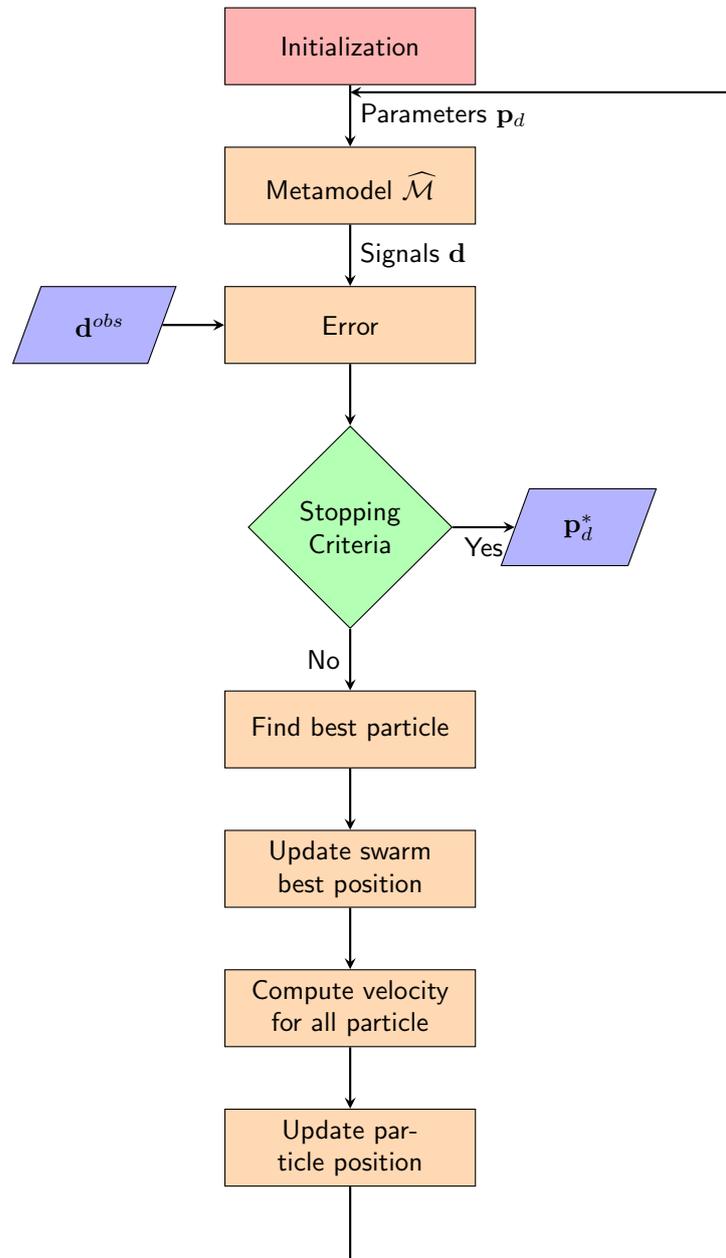


FIGURE 4.2 – Diagramme de l'algorithme de résolution inverse

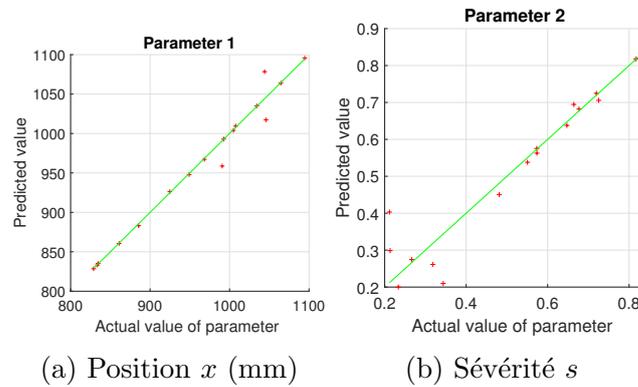


FIGURE 4.3 – Évaluation de la résolution inverse sur la Poutre avec RBF + MP

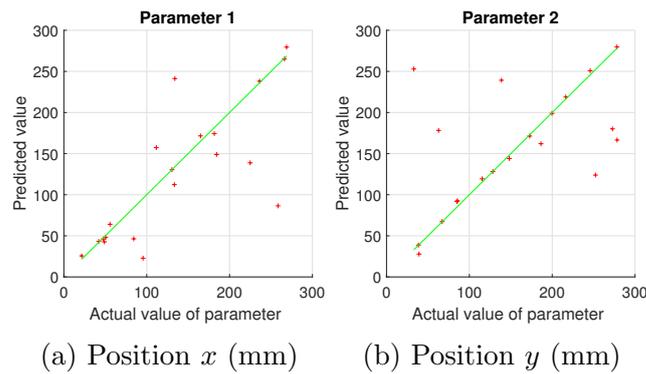


FIGURE 4.4 – Évaluation de la résolution inverse sur S2 avec RBF et SVD

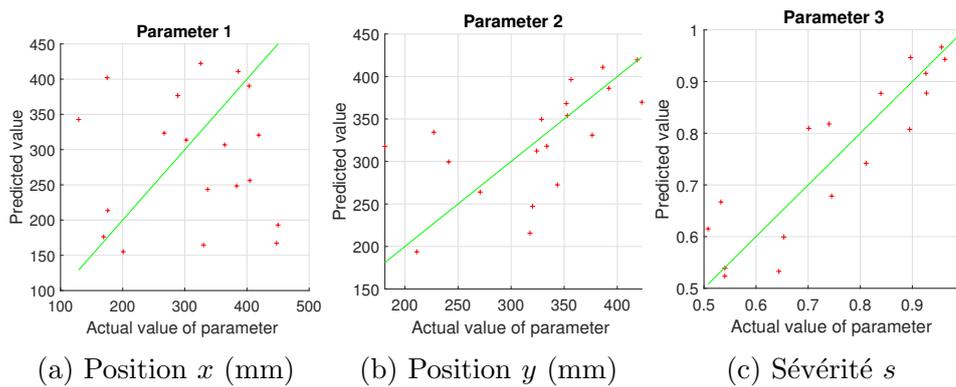


FIGURE 4.5 – Évaluation de la résolution inverse sur S11 avec la RBF et SVD

TABLE 4.1 – Durée de la résolution inverse pour une observation

-	Poutre	S2	S11
Temps (s)	30	180	600

permettent de visualiser les résultats des résolutions inverses. Chaque colonne correspond à un paramètre et compare la valeur prédite par le CNN à la valeur réelle. Plus les points sont proches de la ligne $x = y$ visible en vert, plus les prédictions sont justes.

Poutre Pour la poutre, la résolution inverse exploite le métamodèle construit par la RBF avec des données compressées par le MP (Figure 4.3). La résolution se montre très précise avec une erreur moyenne de 6.4mm pour la localisation et de 3.9% pour la sévérité (Figure C.1) ce qui confirme la pertinence de la représentation choisie pour cette structure et les qualités de l’interpolation par RBF.

S2 Dans le cas de la plaque S2, la résolution inverse exploitant le métamodèle construit par la RBF avec des données compressées par la SVD (Figure 4.4) donne des résultats corrects. Certains dommages sont bien localisés mais quelques uns pénalisent fortement l’évaluation et l’erreur euclidienne moyenne de localisation atteint alors 55mm.

S11 Dans le cas de la plaque S11, quelque soit la représentation ou le métamodèle utilisé, l’erreur est importante lors de la résolution inverse (4.5). Le métamodèle direct ne parvient pas à interpoler correctement le comportement de la plaque car les deux représentations (SVD ou MP) ne sont pas adaptées à cette structure. La sévérité du dommage est cependant mieux estimée par cette méthode que la localisation.

La stratégie de résolution inverse s’appuyant sur des métamodèles directs montre ses limites sur les structures plaques. Les faibles capacités de généralisation des compressions utilisées empêchent le métamodèle d’approximer correctement le comportement de la plaque. Ces écarts se répercutent alors sur les résultats de la résolution inverse. Par ailleurs, le coût de calcul de la minimisation n’est pas négligeable, il augmente avec le nombre de paramètres du métamodèle de capteurs 4.1. Si les modèles d’endommagement deviennent plus complexes et les réseaux qui équipées les structures plus grands, ce coût pourrait être limitant.

Une autre approche est possible : elle consiste à entraîner un métamodèle $\widehat{\mathcal{M}}^{-1}$ ayant pour entrée les signaux mesurés \mathbf{d} et en sortie les paramètres du dommage \mathbf{p}_d . Ce métamodèle sera donc dédié à la résolution du problème inverse. Nous avons vu que la question de la représentation des signaux est encore une question ouverte et qu’il n’est pas facile de trouver quelle méthode permet d’extraire les informations les plus pertinentes des signaux. Les réseaux de neurones convolutifs peuvent apporter une réponse à

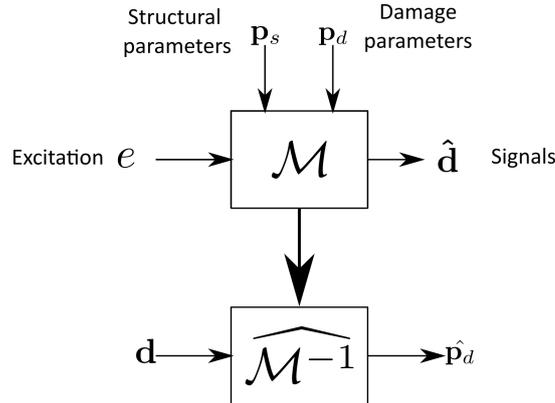


FIGURE 4.6 – Résolution inverse par un métamodèle dédié

ce problème en proposant une méthode permettant de trouver une représentation adaptée automatiquement.

4.3 Résolution inverse à l'aide d'un réseau de neurones convolutifs

4.3.1 Choix du CNN

Il s'agit désormais de construire un métamodèle inverse $\widehat{\mathcal{M}}^{-1}$ prenant en entrée les signaux mesurés et en sortie les paramètres d'un dommage. La différence importante de dimension entre les données d'entrée et de sortie impose des méthodes différentes de la construction du modèle direct. Les CNNs ont montré leurs performances pour extraire automatiquement des caractéristiques des données et résoudre les problèmes de régression ou classification (Paragraphe 3.2.3.3) et sont par conséquent retenus comme métamodèle inverse.

4.3.2 Du modèle numérique de S11 aux dommages expérimentaux

Afin d'évaluer correctement les CNNs proposés dans ce chapitre, quatre cas d'études supplémentaires - du plus simple au plus complexe - sont considérés. Ces cas s'appuient sur le modèle par éléments finis de la plaque S11 du Chapitre 2.3. Ils visent à se rapprocher progressivement des conditions expérimentales en ajoutant des biais et des incertitudes sur le modèle.

Cas 1 Le premier cas reprend le modèle de la plaque S11 avec la base de données contenant 368 configurations de dommage dont la position et la sévérité varient. 90% des données sont utilisées lors l'entraînement et les 10% restantes pour la validation.

Cas 2 Lors du collage des PZTs sur une structure, des incertitudes apparaissent

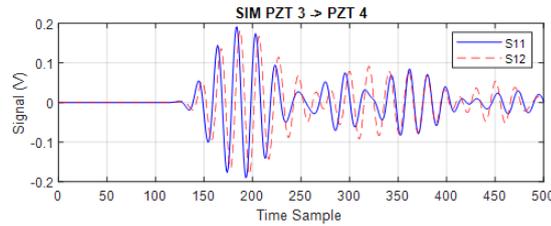


FIGURE 4.7 – Comparaison des signaux à l'état sain de la structure S11 et S12

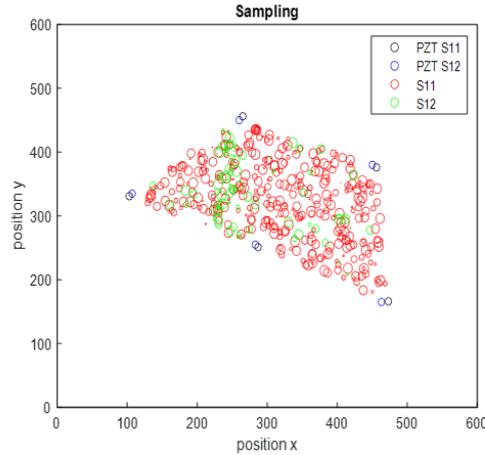


FIGURE 4.8 – Échantillonnage et placement des capteurs pour les structures S11 et S12

sur la position des PZTs : il n'est pas évident de parvenir à reproduire à plusieurs reprises le même placement et le PZT peut glisser sur la structure lors du collage. Ces incertitudes sur la position peuvent atteindre quelques mm . Il est donc nécessaire de connaître la sensibilité des architectures proposées à ce type d'incertitude. Ainsi, une plaque numérique nommée S12 avec des variations sur la position des PZTs est modélisée. Ces variations de l'ordre du mm sont visibles sur la Figure 4.8. Les vitesses de groupe des ondes de Lamb sont élevées dans ce matériau, de l'ordre de $5000 m/s$. Des faibles variations de positions entraînent alors de fortes variations sur les signaux mesurés (Figure 4.7). Ainsi, pour cette structure légèrement modifiée, 80 configurations de dommages sont simulées en faisant varier la sévérité et la position de ceux-ci. Le CNN est alors entraîné avec 100% des simulations de S11 et ses prédictions sont testées avec les mesures de S12.

Cas 3 Le cas précédent est repris en ajoutant du bruit aux données. Les données de S11 servent à l'entraînement et celles de S12 à l'évaluation du CNN. Le bruit de mesure étant inévitable expérimentalement, il faut vérifier qu'il ne dégrade pas les performances du CNN. Sur le matériel d'acquisition du laboratoire, le bruit de mesure a un Rapport Signal sur Bruit (*Signal to Noise Ratio* en anglais, SNR) de 70 dB. Les signaux de chaque configuration de dommage sont dupliqués 5 fois pour simuler des mesures multiples puis un bruit gaussien est ajouté aux données.

Cas 4 Le cas le plus complexe consiste à entraîner le CNN avec les données issues des simulations de la plaque S11 pour localiser et quantifier un dommage sur les deux plaques réellement endommagées dans la Section 2.2.3.

4.3.3 Architectures proposées

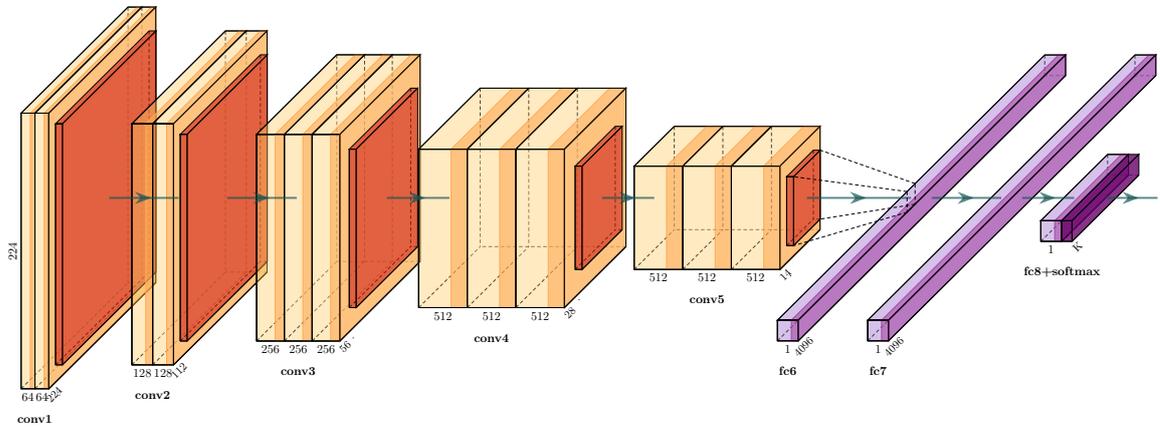
Le CNN est chargé de détecter, localiser et quantifier un dommage sur une structure en identifiant 3 paramètres (position x , position y et sévérité s) à partir des signaux mesurés. Pour traiter ce problème de régression, les architectures des réseaux proposés s'inspirent du réseau VGG16 initialement conçu pour la classification d'images [122].

Deux formats sont considérées pour les données d'entrée : sous la forme d'un vecteur de signaux temporels concaténant tous les chemins d'actionneur/capteur, et sous la forme d'un vecteur concaténant les TVDIIs proposés par [98] pour tous les chemins. Deux architectures, une pour chaque entrée, sont alors proposées. Dans un premier temps, les choix menés pour définir l'architecture du CNN traitant les signaux temporels sont explicités. Des choix légèrement différents ont été réalisés pour le réseau prenant pour entrée les TVDI.

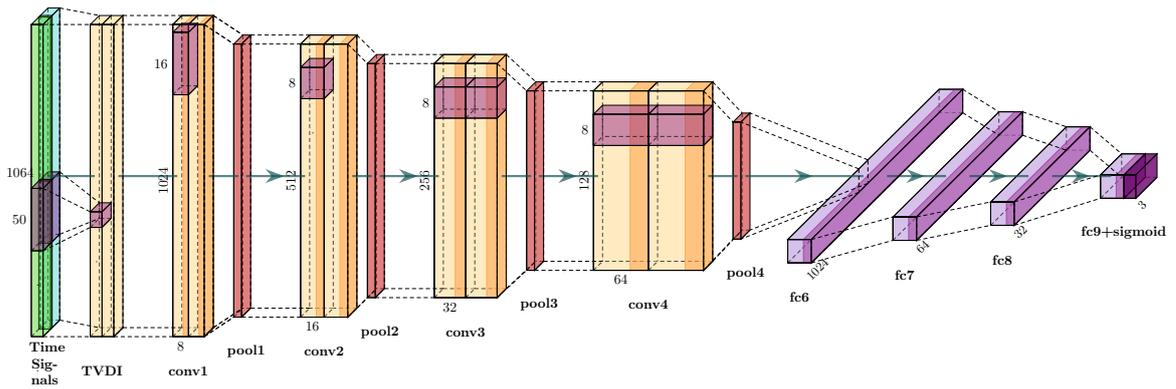
Le réseau se compose d'une succession de blocs de convolution : chaque bloc applique aux données d'entrées deux couches de convolution avec une rectification de type *Relu* et une mise en commun de type *MaxPooling*. Le nombre total de blocs caractérise la profondeur du réseau : plus il y a de blocs, plus le réseau est profond. La Figure 4.12d présente l'évolution de la fonction de coût lors de l'entraînement en fonction de la profondeur du réseau. Elle montre qu'il n'est pas nécessaire que le réseau soit très profond pour ce problème, 4 blocs suffisent à extraire les informations utiles pour prédire avec précision.

Lors de chaque couche de convolution, des filtres sont appliqués aux données d'entrée. Le nombre de filtres est croissant avec la profondeur de la couche. Plus il y a de filtres, plus le nombre de caractéristiques extraites des données sera important. Il est préférable de ne pas avoir un nombre trop élevé de filtres afin de faciliter l'apprentissage sur des bases de données de taille limitée. La Figure 4.12b permet de voir que 8 filtres pour la première couche puis 16 pour la deuxième, 32 pour la troisième et 64 pour la dernière obtiennent de bons résultats.

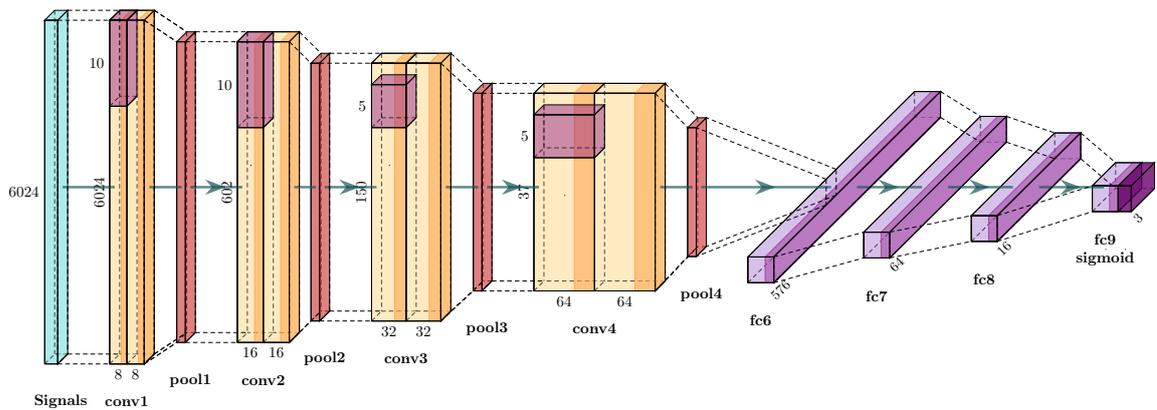
La taille des filtres utilisés lors des différentes convolutions est également un paramètre important de l'architecture du réseau. Le réseau VGG16 obtient de beaux résultats avec des filtres de petite taille (3x3). Pour les deux premiers blocs, une taille de filtre plus importante de taille 10 suivi d'une mise en commun *MaxPooling* de même taille sont utilisées pour extraire des informations pertinentes et réduire leurs dimensions. Pour la suite du réseau, nous utilisons des filtres et un *Pooling* de taille 5.



(a) VGG16



(b) CNN avec TVDI



(c) CNN avec signaux temporels

FIGURE 4.9 – Architectures des CNNs

Pour le CNN exploitant les TVDI, il est considéré que leur calcul a un rôle semblable à celui de la première couche de convolution du CNN temporel. Ce nouveau CNN ne comporte alors que trois blocs de convolution similaires aux 3 derniers blocs du CNN temporel. Ce CNN est entraîné avec chacun des DI implémentés dans SHM@PIMM (Figures 4.10a et Figures 4.11). Il en ressort que la déviation standard (voir STDABS dans le Tableau A.1) permet au CNN d'avoir les meilleures performances. Il est donc sélectionné pour la suite.

En sortie des blocs de convolution, une couche de 128 neurones entièrement connectés, puis une couche de 16 neurones entièrement connectés et enfin une couche de q neurones permettent de résoudre le problème de régression. Le nombre de neurones de la couche intermédiaire est déterminé à l'aide de la Figure 4.12a. Ce nombre est important pour la précision du réseau, mais aussi pour son entraînement : le nombre de paramètres à entraîner est principalement dû à ces couches. Le choix des fonctions d'activation influence la qualité des prédictions du réseau. La fonction d'activation est de type *ReLU* pour la partie convolutive et de type *Softmax* pour la dernière couche. Un décrochage de 5% est appliqué en sortie des couches de neurones entièrement connectés. La Figure 4.12 permet de voir l'influence de la proportion de décrochage sur la qualité de l'apprentissage.

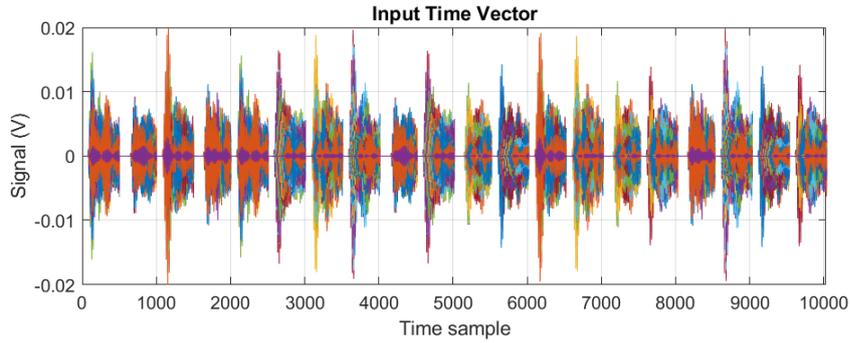
4.3.4 Évaluation des CNNs

Poutre Le même jeu de données utilisés pour l'entraînement des métamodèles directs est utilisé pour entraîner le CNN à caractériser les dommages la poutre. Les résultats des prédictions sur le jeu de validation montre la grande capacité de généralisation du CNN pour traiter les signaux de SHM.

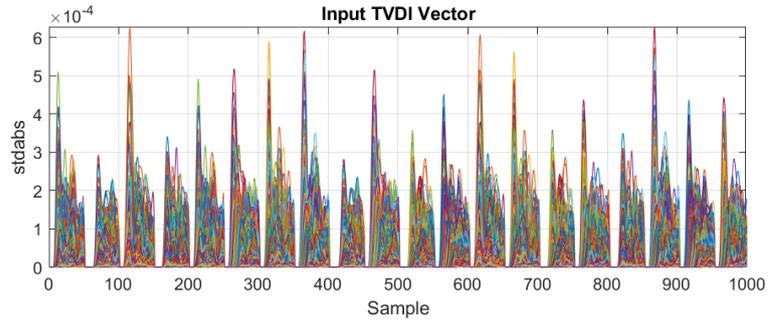
Structure S2 Le CNN montre également une grande capacité de généralisation sur cette structure. Alors que la stratégie précédente basé sur l'entraînement d'un métamodèle direct et une résolution inverse ne parvient pas à localiser avec une grande précision le dommage, cette tâche ne pose pas de problème particulier pour le CNN.

Structures S11

Cas 1 Dans ce cas – le plus simple – 90% des données issues de simulations numériques sont utilisées pour l'entraînement du CNN et 10% sont gardées pour l'évaluation ultérieure des prédictions. Les résultats de l'évaluation sont visibles sur la Figure 4.15 pour le CNN avec TVDI et Figure 4.16 pour le CNN avec les signaux temporels. Les prédictions du CNN coïncident très bien avec les valeurs réelles. L'erreur de localisation est faible, de l'ordre de 8.9mm et l'erreur sur la sévérité n'est que de 1.6%.

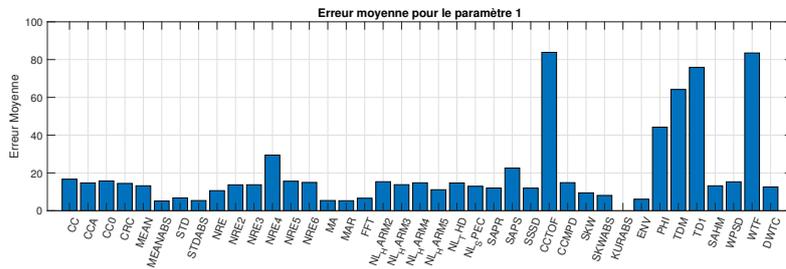


(a) Vecteurs temporels

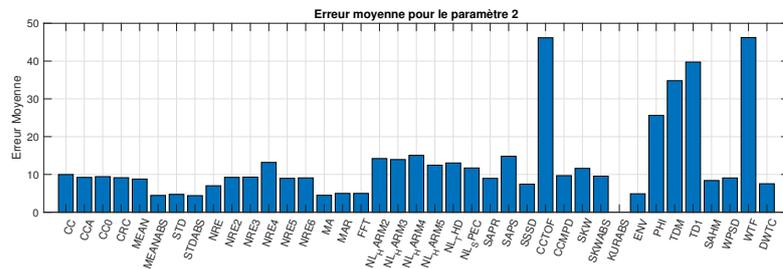


(b) Vecteurs de TVDI

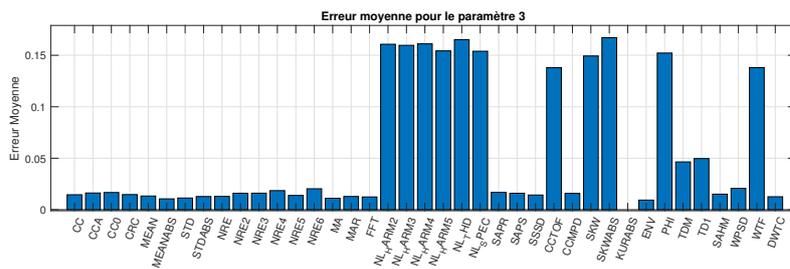
FIGURE 4.10 – Vecteurs d’entrée des CNNs



(a) Erreur de position x



(b) Erreur de position y



(c) Erreur de sévérité s

FIGURE 4.11 – Erreur moyenne des prédictions en fonction du TVDI sur le cas 1

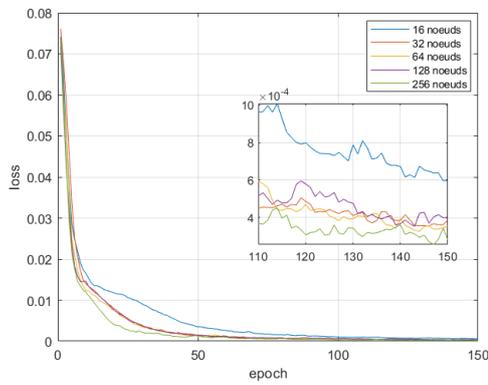
TABLE 4.2 – Architectures des CNNs

(a) CNN temporel

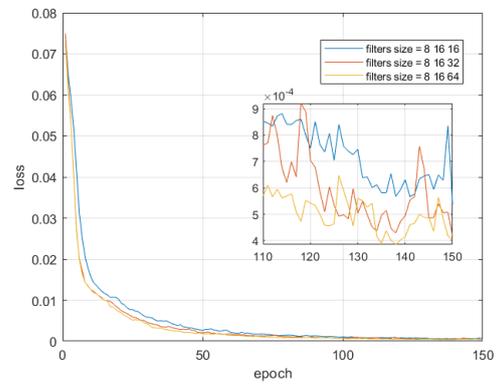
Layer	Parameter	Value
Input	size	10040
Conv1D	Filter number \times size	8×10
Conv1D	Filter number \times size	8×10
Act.	Function	ReLu
MaxPool	Window size	10
Dropout	τ	0.05
Conv1D	Filter number \times size	16×10
Conv1D	Filter number \times size	16×10
MaxPool	Window size	1°
Act.	Function	ReLu
Dropout	τ	0.05
Conv1D	Filter number \times size	32×5
Conv1D	Filter number \times size	32×5
MaxPool	Window size	5
Act.	Function	ReLu
Dropout	τ	0.05
Conv1D	Filter number \times size	64×5
Conv1D	Filter number \times size	64×5
MaxPool	Window size	5
Act.	Function	ReLu
Dropout	τ	0.05
Dense	Number of neurons	64
Act.	Function	ReLu
Dense	Number of neurons	16
Act.	Function	ReLu
Dense	Number of neurons	3
Act.	Function	SoftMax

(b) CNN avec TVDI

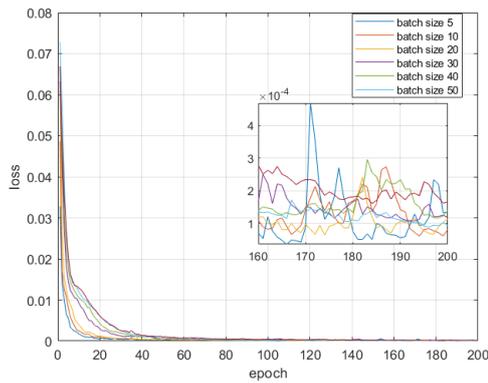
Layer	Parameter	Value
Input	size	1000
Conv1D	Filter number \times size	16×10
Conv1D	Filter number \times size	16×10
MaxPool	Window size	10
Act.	Function	ReLu
Dropout	τ	0.05
Conv1D	Filter number \times size	32×5
Conv1D	Filter number \times size	32×5
Act.	Function	ReLu
MaxPool	Window size	5
Conv1D	Filter number \times size	64×5
Conv1D	Filter number \times size	64×5
MaxPool	Window size	5
Act.	Function	ReLu
Dropout	τ	0.05
Dense	Number of neurons	64
Act.	Function	ReLu
Dense	Number of neurons	16
Act.	Function	ReLu
Dense	Number of neurons	3
Act.	Function	SoftMax



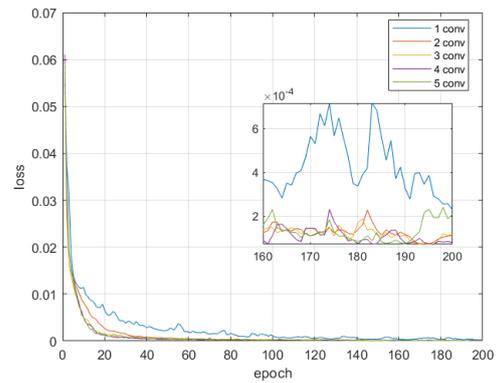
(a) En fonction du nombre de nœuds



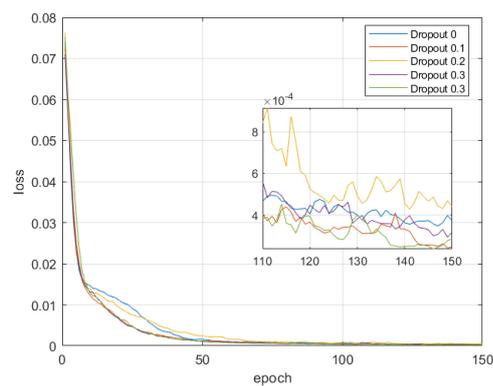
(b) En fonction de la taille du dernier filtre



(c) En fonction de la taille des lots



(d) En fonction de la profondeur du réseau



(e) En fonction du taux de décrochage

FIGURE 4.12 – Évolutions de la fonction coût lors de l'entraînement pour différentes valeurs des hyperparamètres du CNN

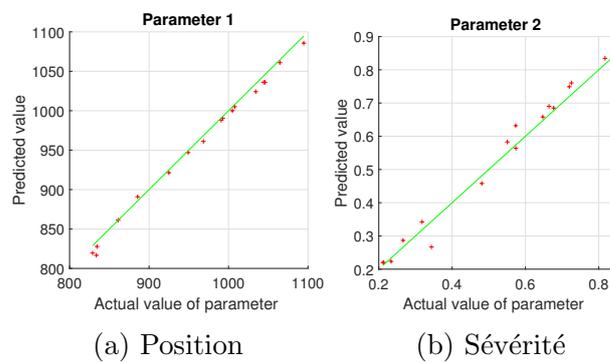


FIGURE 4.13 – Évaluation de la résolution inverse sur la poutre avec CNN temporel

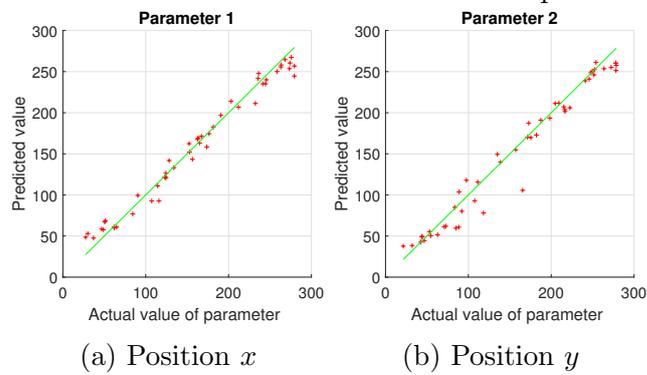


FIGURE 4.14 – Évaluation de la résolution inverse sur S2 avec CNN temporel. Des figures équivalentes sont obtenues avec le CNN avec TVDI.

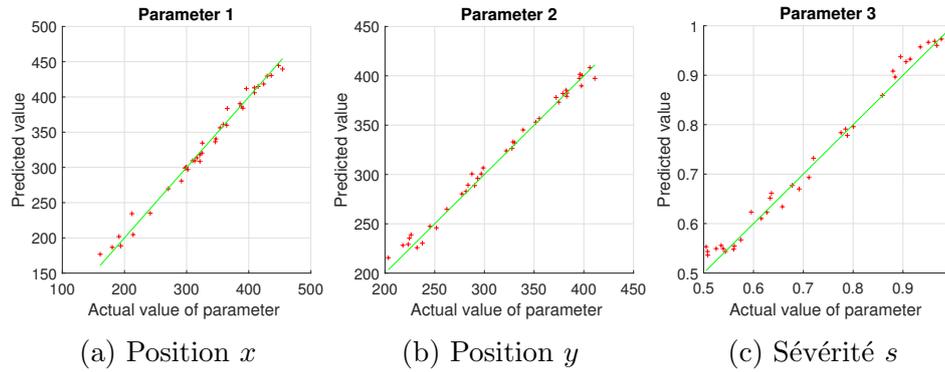


FIGURE 4.15 – Évaluation du CNN temporel sur le cas 1

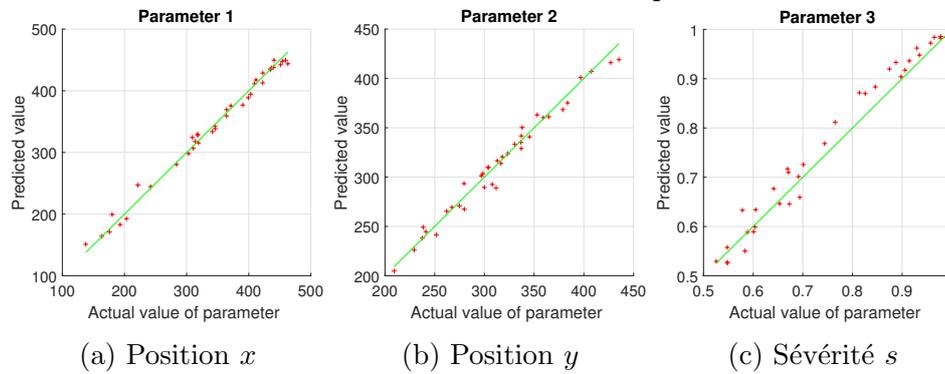


FIGURE 4.16 – Évaluation du CNN TVDI sur le cas 1

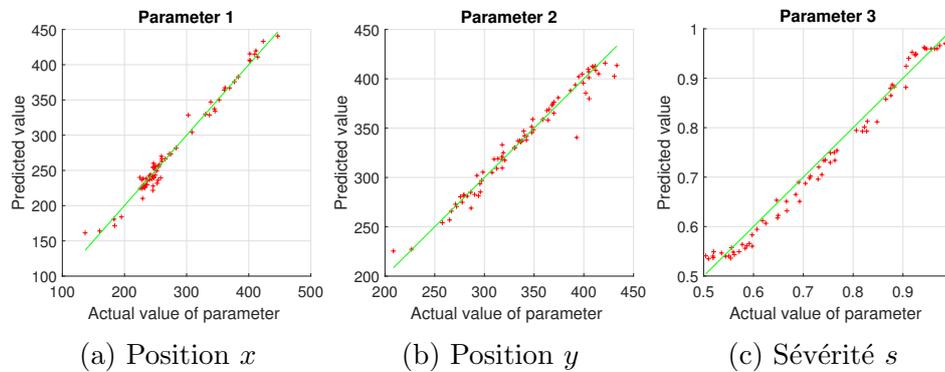


FIGURE 4.17 – Évaluation du CNN temporel sur le cas 2

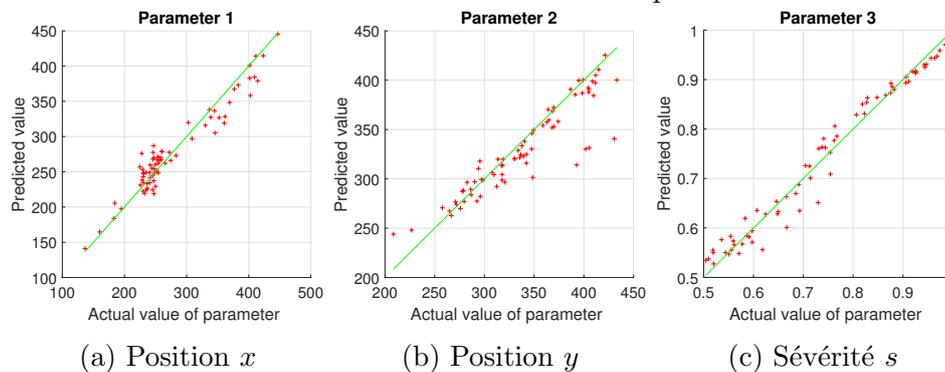


FIGURE 4.18 – Évaluation du CNN avec TVDI sur le cas 2

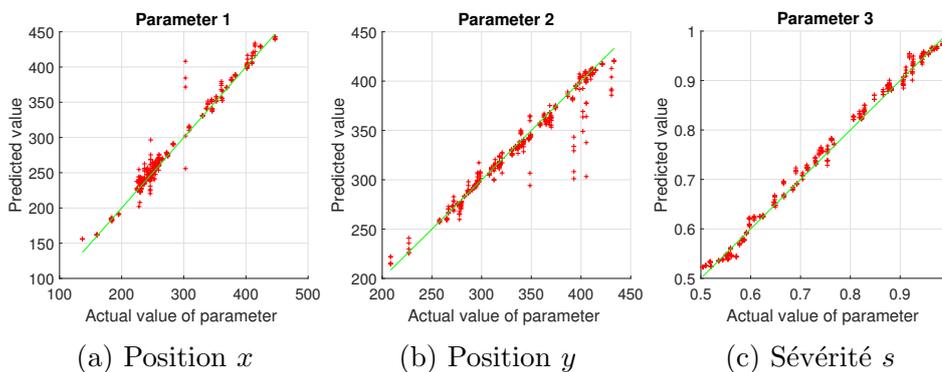


FIGURE 4.19 – Évaluation du CNN temporel sur le cas 3

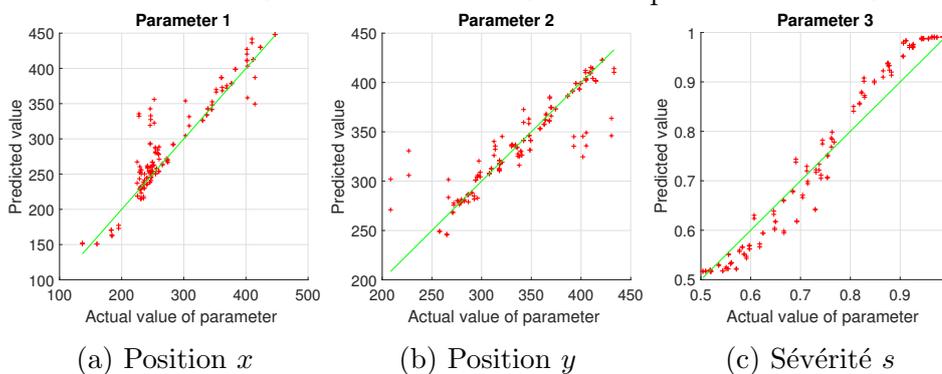


FIGURE 4.20 – Évaluation du CNN TVDI sur le cas 3

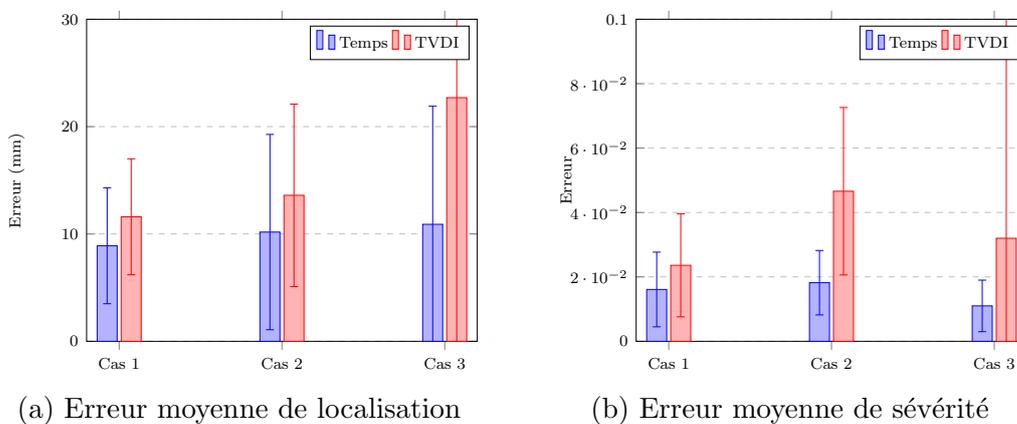


FIGURE 4.21 – Comparaison prédictions du CNN sur les différents cas de S11

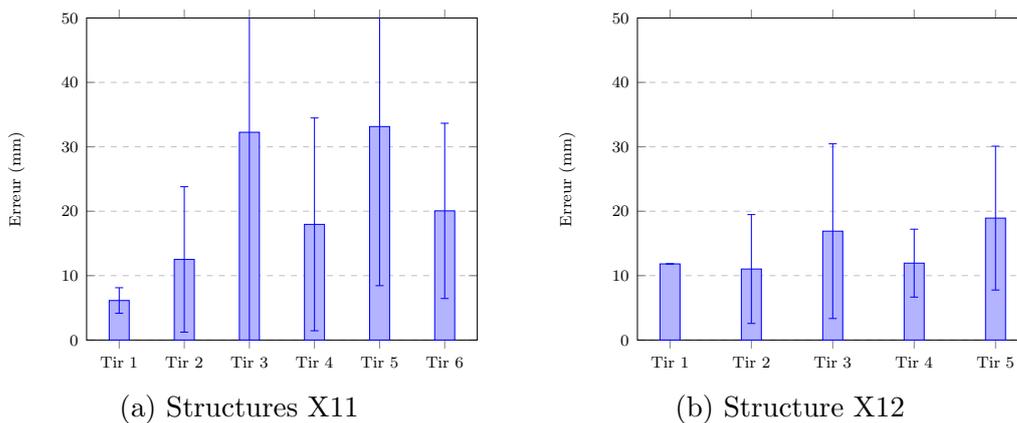


FIGURE 4.22 – Erreur de localisation sur les structures expérimentales du CNN temporel

Cas 2 Malgré des variations importantes sur les signaux mesurés 4.7, l'erreur sur la position des PZTs ne détériore pas les prédictions du CNN. Les prédictions de deux architectures sont visibles Figures 4.18 et Figures 4.17. Les erreurs sont similaires à celles du cas précédent.

Cas 3 La duplication des données pour simuler différentes mesures augmente la quantité de données d'entraînement ce qui augmente de manière importante la durée d'apprentissage. Celle-ci reste suffisamment faible pour que l'apprentissage se fasse sur un ordinateur de bureau en quelques dizaines de minutes. Le CNN temporel se montre robuste au bruit ajouté qui ne perturbe que quelques prédictions. La Figure 4.19 montre un étalement important des valeurs prédites pour quelques points. Il s'agit d'échantillons qui ont une sévérité très faible, le signal de différence est alors noyé dans le bruit ce qui perturbe la prédiction. La sévérité étant très faible, ces échantillons peuvent alors être supposés comme sains et la caractérisation du dommage n'est alors pas utile. Pour le CNN avec TVDI (Figure 4.20), des performances inférieures sont obtenues mais restent proches du CNN temporel.

Cas 4 Les signaux mesurés sur des plaques X11 et X12 endommagées par des chocs Laser sont traités par les CNNs entraînés sur la plaque numérique S11. Lors de l'acquisition, chaque mesure a été répétée à 10 reprises ce qui permet d'estimer la position moyenne ainsi que la variance des prédictions. La position du premier tir sur chacune des deux structures est prédite avec précision : l'erreur moyenne de localisation n'est que de 6mm pour le premier tir de X11 et de 11mm pour le premier tir de X12 et l'écart type des prédictions entre chaque mesure est très faible (inférieur à 2mm pour les deux structures). Sur les tirs suivants, l'erreur moyenne des prédictions augmentent et atteint au maximum 30mm sur les tirs 3 et 5 de la structure X11 avec un écart type important de 34mm et 24mm. Cette augmentation peut s'expliquer par l'étendue du dommage qui augmente avec le nombre de tir et le caractère discontinu du dommage généré (Figure 2.7). Les deux architectures proposées obtiennent des résultats similaires 4.21 et compétitifs avec les méthodes classiques de SHM.

4.3.5 Discussions sur les approches directe et inverse

Les Figures 4.23a et 4.23b comparent les erreurs de prédictions des différentes méthodes de résolution inverse pour la poutre, la plaque S2 et la plaque S11. Pour la résolution inverse s'appuyant sur un métamodèle direct, la Figure 4.23a ne présente que le meilleur résultat de chaque cas d'étude.

Sur les structures de type plaque, les CNNs surpassent nettement la résolution inverse exploitant les métamodèles directs pour la localisation. L'écart est moins important pour

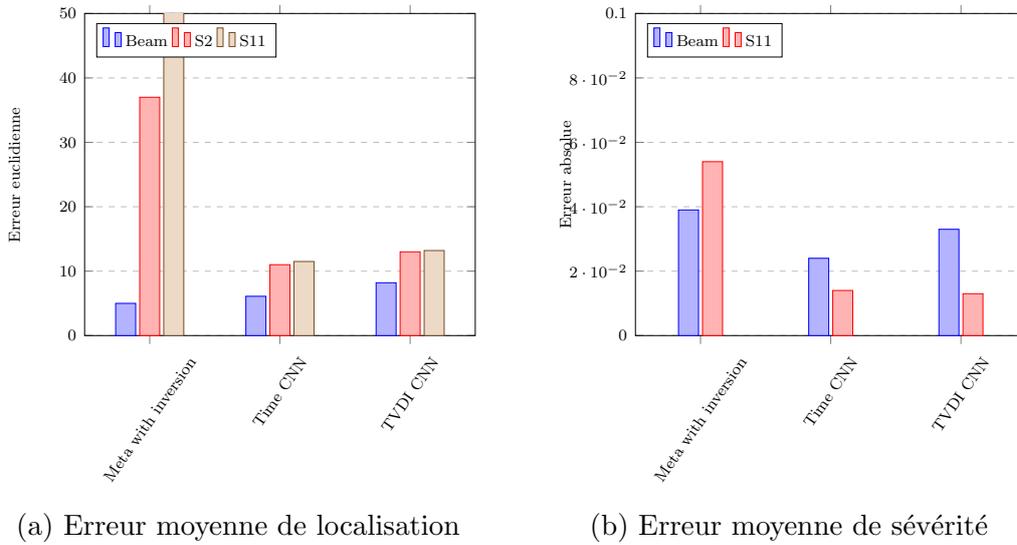


FIGURE 4.23 – Comparaison des méthodes de résolution inverse

la quantification mais les CNNs restent supérieurs. Sur la structure très spécifique de la poutre, la résolution inverse à l'aide de métamodèle direct est légèrement meilleure que les CNNs pour la localisation ce qui confirme la pertinence de la représentation des signaux pour ce cas. Que le réseau soit entraîné avec des signaux temporels ou avec des TVDI a peu d'influence sur la qualité des prédictions. Il est important de noter que l'architecture des réseaux est la même quelque soit la structure sur laquelle il est appliqué, ainsi le travail fastidieux de détermination de l'architecture idéale n'a pas à être reproduit pour une nouvelle structure.

4.4 Conclusion

Les métamodèles construits au chapitre précédent permettent le déploiement de méthodes de résolution inverse en SHM en prédisant rapidement les résultats d'une simulation longue et coûteuse. Ici, la minimisation d'une erreur composée de DI's par un algorithme d'optimisation à essaim particulière donne de bons résultats lorsque le métamodèle est suffisamment précis. Cependant, les difficultés rencontrées dans la construction des métamodèles se propagent et s'amplifient lors de la résolution inverse. Les erreurs de prédictions mises en lumière dans le Chapitre 3 rendent ces métamodèles difficilement exploitables pour une résolution inverse sur les structures de grandes tailles. Les résultats sont cependant encourageants sur la structure poutre et la plaque S2. En améliorant les prédictions des métamodèles, il sera envisageable d'améliorer considérablement la résolution inverse.

Les CNNs se montrent très puissants pour répondre aux besoins de régression sur des

signaux temporels à très grande dimension. Ils parviennent à prédire avec une grande précision la position et la sévérité des endommagements sur les différents cas d'études proposés. Ils se montrent robustes au bruit de mesure et aux erreurs de positions de capteurs, une source importante de biais entre les modèles numériques et les structures réelles. Quelque soit le cas d'étude, les architectures exploitant les signaux temporels ou les TVDI obtiennent des résultats similaires. Leur exploitation sur les plaques expérimentales permet d'obtenir une position plus précise que les méthodes classiques de SHM présentées dans le Chapitre 2. L'exploitation de modèles d'apprentissage entraîné avec des données numériques pour caractériser des dommages expérimentaux est valide malgré un recalage imparfait des modèles par éléments finis. Dans le cadre de développement de stratégies d'apprentissages pour le SHM par onde de Lamb, les outils d'apprentissage profond doivent être privilégiés au vu des résultats obtenus. Ils sont cependant limités par leur dépendance au problème, un biais ou une incertitude trop importante risque de détériorer leurs prédictions. Notamment, un changement dans les conditions environnementales ou opératoires peut avoir une influence néfaste sur les diagnostics des CNNs.

5

Apprentissage par transfert fondé sur la théorie du transport optimal

Résumé

Une approche originale d'apprentissage profond par transfert intégrant la théorie du transport optimal à l'entraînement d'un CNN permet de transférer l'apprentissage entre deux structures relativement proches. Un Input Convex Neural Network (ICNN) est utilisé pour représenter les potentiels de Kantorovich et transporter les caractéristiques extraites des signaux à une couche intermédiaire du CNN. Afin d'évaluer la proximité entre deux structures, un indicateur appelé Indice Structurel (*Structural Index* en anglais, SI) et inspiré des DIs est proposé. L'approche est validée sur des structures numériques qui sont soumises à des biais (changements de position d'un des transducteurs et des propriétés du matériau) et des incertitudes ouvrant la voie à des apprentissages profonds hybrides mélangeant des données numériques nombreuses avec des données expérimentales.

Sommaire

5.1	Introduction	112
5.1.1	Nécessité du transfert pour le SHM	113
5.2	État de l'art de l'apprentissage profond par transfert	115
5.3	Transfert d'apprentissage profond par transport optimal	120
5.3.1	Originalité de l'approche proposée	120
5.3.2	Introduction au transport optimal	122
5.3.3	Algorithme d'apprentissage par transfert profond à l'aide de potentiels de Kantorovich neuronaux	128
5.4	Application au SHM	129
5.4.1	Architecture détaillée du réseau	129
5.4.2	Évaluation des transferts	131
5.4.3	Discussions des évaluations	131
5.5	Conclusion	135

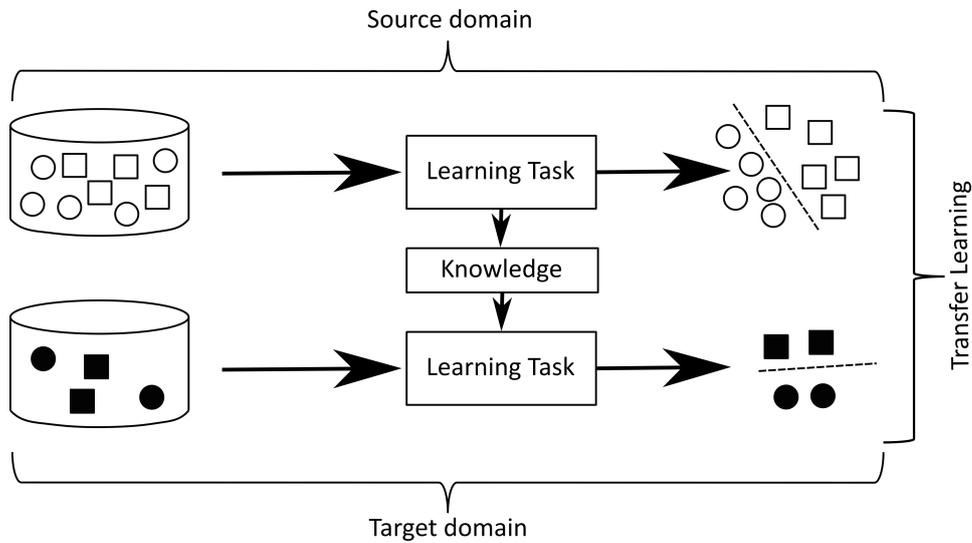


FIGURE 5.1 – Exemple simple d’apprentissage par transfert : ici la tâche source consiste à distinguer des carrés creux des cercles creux. L’apprentissage peut être transféré pour distinguer les cercles pleins des carrés pleins.

5.1 Introduction

Contexte Les méthodes d’apprentissage profond et plus particulièrement les CNNs ont connu de nombreux succès pour des tâches extrêmement variées. Dans le cadre du SHM par des ondes de Lamb, elles parviennent à détecter, localiser et quantifier un dommage (voir le Chapitre 4). Ces méthodes pilotées par les données s’appuient sur des bases de données obtenues au préalable. L’apprentissage dépend alors inéluctablement des données d’entraînement et donc de la structure qui a permis d’obtenir les données : toute variation structurelle, géométrique ou environnementale modifie la propagation des ondes et risque de dégrader les prédictions. Or ces données sont difficiles à collecter : en SHM, les données expérimentales sont rarement en quantité suffisante pour pouvoir faire de l’apprentissage profond. Entraîner les modèles à l’aide de bases de données obtenues numériquement est nécessaire mais il subsiste toujours un écart entre les données numériques et les données réelles qui dégrade les performances et empêche le déploiement industriel de telles méthodes. Ce problème a déjà été identifié en apprentissage automatique et est résolu par les méthodes d’apprentissage par transfert [147, 148, 149] qui visent à transférer les connaissances acquises sur une base de données vers une autre relativement proche. En SHM, la caractérisation des dommages sur deux structures similaires, ou sur une structure réelle et sa version numérique, peuvent être considérées comme des problèmes relativement proches.

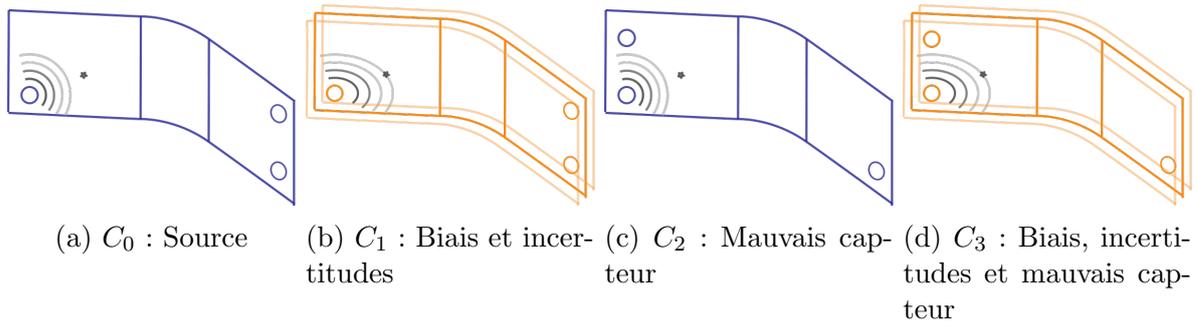


FIGURE 5.2 – Structures étudiées

Objectifs Ce chapitre démontre les limites de l'apprentissage profond en SHM liées à la dépendance des modèles aux données et propose une méthode d'apprentissage par transfert originale s'appuyant sur la théorie du transport optimal présentée dans la Section 5.3.3. Pour des considérations pédagogiques et de complétude du chapitre, cette théorie est sciemment reprise et expliquée dans la Section 5.3.2. Le lecteur pourra se référer à [150] et [151] pour des développements théoriques plus avancés.

5.1.1 Nécessité du transfert pour le SHM

5.1.1.1 Définition des structures numériques voisines

Pour illustrer les limites au déploiement de l'apprentissage profond à cause la dépendance aux données des modèles, nous reprenons l'architecture du CNN proposée dans la Section 4.3 afin d'estimer la sévérité et la position d'un dommage (tâche (i), (ii) et (iv) du SHM) sur une structure composite courbe. Considérons quatre structures intelligentes représentées par leurs modèles numériques (Figure 5.2) :

C_0 La première nommée C_0 est une structure composite courbe avec 3 PZTs et un empilement équilibré $[0_2/90_2/+45_2/-45_2]_s$ dont le modèle par éléments finis est décrit dans la Section 2.4.4. 100 configurations d'endommagement avec 3 paramètres (deux pour la position et un pour la sévérité) sont simulées selon un échantillonnage par LHS. Comme pour les autres modèles, l'endommagement est modélisé par une réduction de rigidité sur un diamètre de 10mm.

C_1 Un biais et des incertitudes sont introduits dans le modèle de la deuxième structure (Tableau 5.3). L'empilement déséquilibré $[0_2/90_2/+45_2/-45_2/0_2]_s$ induit un comportement global anisotrope et des incertitudes sont ajoutées sur les propriétés mécaniques, la position des PZT et la géométrie afin de simuler un lot de coupons dans des conditions expérimentales réelles. La base de données contient alors 80 configurations d'endommagement dont la position et la sévérité varient.

C_2 Imposer un positionnement strictes des transducteurs lors de la fabrication de la

TABLE 5.1 – DIs utilisés pour le calcul des SI avec respectivement $d_{ij}^s(t)$ et $d_{ij}^t(t)$ les signaux sources et les signaux cibles pour le chemin de l'actionneur i au capteur j

DI	Définition
CC	$1 - \max \left(\frac{IFFT[FFT[d_s^{ij}(t)]FFT[d_t^{ij}(t)]^*]}{\sqrt{(E_{d_s^{ij}} E_{d_t^{ij}})}} \right)$
NRE	$\frac{\int_T^0 (d_s^{ij}(t) - d_t^{ij}(t))^2 dt}{2 \times \int_T^0 d_s^{ij}(t)^2 dt + \int_T^0 d_t^{ij}(t)^2 dt}$

TABLE 5.2 – Indices Structurels (SIs) entre la structure source et les structures cibles

	$C_0 \rightarrow C_0$	$C_0 \rightarrow C_1$	$C_0 \rightarrow C_2$	$C_0 \rightarrow C_3$
SI	0.0	0.12978	0.5977	0.7466

structure n'est pas toujours facile et des écarts importants peuvent apparaître entre le placement prévu et réel. De plus, au cours de sa durée de vie, certains des éléments du réseau de transducteurs peuvent être endommagés, perdus ou remplacés. Dans le but de reproduire ce type d'événement, un fort biais est ajouté sur le troisième modèle : le troisième transducteur est placé différemment ce qui induit des fortes variations sur les signaux mesurés. Les autres aspects de ce modèle sont similaires à la première structure. La base de données se compose de 100 configurations d'endommagement.

C₃ Le quatrième modèle est similaire au deuxième mais le troisième transducteur est également déplacé. La base de données contient alors 80 configurations d'endommagement.

Pour chacune des bases de données, une partie des échantillons est utilisée pour l'apprentissage et une autre partie est conservée pour tester les modèles. Toutes ces propriétés sont présentées dans le Tableau 5.3. Dans chacun des cas, 80 échantillons sont utilisés provenant de la structure source C_0 et 20 provenant des structures cibles $C_{1 \leq i \leq 3}$.

5.1.1.2 Estimation de la proximité entre des structures

Les DIs, très répandus pour la détection des dommages en SHM, sont repris pour estimer la différence entre les structures car la propagation des ondes de Lamb dépend fortement des propriétés et de la géométrie de la structure. Tout changement structurel et toute modification des conditions environnementales ou opératoires modifie les signaux à l'état sain et peut se quantifier avec un DI. Nous choisissons pour le SI la moyenne de 2 DIs : l'erreur résiduelle normalisée et la corrélation croisée (Tableau 5.1). Pour les structures avec incertitudes (C_1 et C_3), le SI est la moyenne des SIs calculées avec les mesures saines chacun des coupons (Tableau 5.2).

La courbe bleue de la Figure 5.15 montre que l'erreur de prédiction du CNN en-

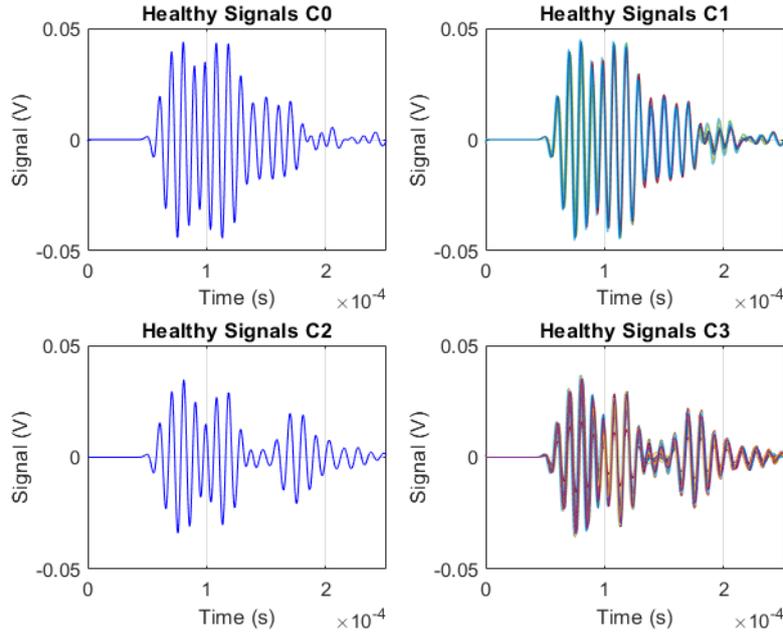


FIGURE 5.3 – Signaux sains utilisés pour le calcul des SIs (uniquement le signal du chemin PZT1 vers PZT3 est affiché). Pour les structures C_1 et C_3 , il y a plusieurs signaux sains, un pour chaque coupon.

traîné avec les données C_0 augmente avec la valeur du SI. Avec de petites variations sur la structure ($C_0 \rightarrow C_1$), l'erreur quadratique moyenne des prédictions reste faible mais avec un changement de transducteur dans le modèle ($C_0 \rightarrow C_2$ et $C_0 \rightarrow C_3$) l'erreur augmente fortement, une nouvelle approche est nécessaire. Le CNN est incapable de caractériser correctement un dommage lorsqu'il existe un biais important entre la structure utilisée pour l'entraînement et la structure en exploitation. Pourtant les deux structures possèdent des similarités importantes qui doivent être exploitées pour faciliter l'apprentissage.

5.2 État de l'art de l'apprentissage profond par transfert

L'apprentissage par transfert cherche à capitaliser les connaissances acquises lors de la résolution d'un problème pour les appliquer à un autre problème relativement proche. Une schématisation simple de l'apprentissage par transfert pour un problème de classification est présentée sur la Figure 5.1. L'apprentissage par transfert s'appuie sur les notions de **domaine** et de **tâche** [147, 148]. Un **domaine** \mathcal{D} se compose d'un espace de caractéristiques \mathcal{X} associé à la loi de probabilité marginale $\mu(X)$ avec un jeu de données $X = x_1, \dots, x_n \in \mathcal{X}$ et aux labels $\mathbf{y} \in \mathcal{Y}$. La loi de probabilité marginale $\mu(X)$ est rarement explicitée, elle est le plus souvent inaccessible. Une **tâche** \mathcal{T} se compose d'un espace de

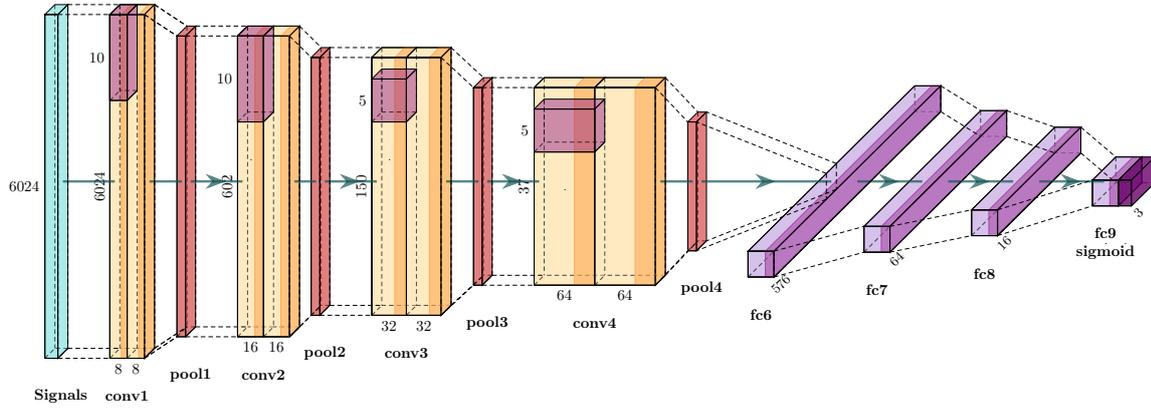


FIGURE 5.4 – Architecture du CNN initial

TABLE 5.3 – Propriété mécanique et géométrique des structures étudiées

Param.	C_0	C_1	C_2	C_3	Unité
L	500	$500 + \mathcal{N}_{0,2}$	500	$500 + \mathcal{N}_{0,2}$	mm
H	200	$200 + \mathcal{N}_{0,1}$	200	$200 + \mathcal{N}_{0,1}$	mm
PZT 1	[100, 160]	$[100, 160] + \mathcal{N}_{0_2, I_2}$	[100, 160]	$[100, 160] + \mathcal{N}_{0_2, I_2}$	mm
PZT 2	[100, 40]	$[100, 40] + \mathcal{N}_{0_2, I_2}$	[100, 40]	$[100, 40] + \mathcal{N}_{0_2, I_2}$	mm
PZT 3	[400, 160]	$[400, 160] + \mathcal{N}_{0_2, I_2}$	[400, 40]	$[400, 40] + \mathcal{N}_{0_2, I_2}$	mm
E_1	150	$150 + \mathcal{N}_{0,0.5}$	150	$150 + \mathcal{N}_{0,0.5}$	GPa
E_2	9	$9 + \mathcal{N}_{0,0.5}$	9	$9 + \mathcal{N}_{0,0.5}$	GPa
G_{12}	4.7	4.7	4.7	4.7	GPa
ν_{12}	0.33	0.33	0.33	0.33	-
ν_{23}	0.48	0.48	0.48	0.48	-
ρ	1594	1594	1594	1594	kg/m^3
SNR	0	30	0	30	dB
Empilement	ISO	ANISO	ISO	ANISO	-
N_{tr}	80	20	20	20	-
N_{test}	20	60	80	60	-

label \mathcal{Y} et d'une fonction de décision $f : \mathcal{X} \rightarrow \mathcal{Y}$ tel que $\mathcal{T} = \{\mathcal{Y}, f(\cdot)\}$. Elle cherche à associer à une nouvelle donnée $x \in \mathcal{X}$ un label $y \in \mathcal{Y}$ à l'aide de la fonction f . Pour les tâches de classification, la fonction $x \rightarrow f(x)$ renvoie une probabilité conditionnelle $\mu(y | x)$. Pour rappel, dans l'apprentissage supervisé, cette tâche est apprise à partir d'un ensemble de paires de données et de labels $(x_i, y_i) \in (\mathcal{X} \times \mathcal{Y})$.

Le **domaine source** est noté $\mathcal{D}_s = \{\mathcal{X}_s, \mu_s(X)\}$ avec les labels \mathcal{Y}_s et la tâche source $\mathcal{T}_s = \{\mathcal{Y}, f_s\}$. Sur ce domaine où la quantité de données est importante, l'apprentissage de la tâche \mathcal{T}_s se fait facilement. Le **domaine cible** est défini de manière analogue $\mathcal{D}_t = \{\mathcal{X}_t, \mu_t(X)\}$ avec les labels \mathcal{Y}_t et la tâche $\mathcal{T}_t = \{\mathcal{Y}_t, f_t\}$. Sur ce domaine \mathcal{D}_t , les données labellisées sont généralement manquantes pour permettre d'entraîner correctement la tâche \mathcal{T}_t . Dans la littérature, l'hypothèse que les domaines source et cible sont obtenus suivant des variables indépendantes et identiquement distribuées est souvent faite.

L'**apprentissage par transfert** se définit alors de la manière suivante [152] :

Definition 5.2.1 *Pour une tâche \mathcal{T}_t s'appuyant sur le domaine \mathcal{D}_t et avec l'aide du domaine \mathcal{D}_s associé à la tâche \mathcal{T}_s , l'apprentissage par transfert vise à améliorer les performances de la fonction $f_t(\cdot)$ pour apprendre la tâche \mathcal{T}_t en découvrant et transférant les connaissances sous-jacentes de \mathcal{D}_s vers \mathcal{D}_t , où $\mathcal{D}_s \neq \mathcal{D}_t$ et/ou $\mathcal{T}_s \neq \mathcal{T}_t$. De plus, dans la plupart des cas la taille de \mathcal{D}_s est bien plus grande que celle de \mathcal{D}_t , ie $n_s \gg n_t$.*

Dans le cas du SHM, le domaine source provient d'une structure initiale dans des conditions opératoires connues et le domaine cible provient d'une structure voisine de la structure initiale mais certaines propriétés sont différentes (géométrie, positions des capteurs, conditions opératoires, propriétés mécaniques, etc). Les techniques de transfert doivent alors compenser les variabilités structurelles et environnementales qui réduisent la qualité des diagnostics des modèles construits par apprentissage. Elles offrent la possibilité d'utiliser les connaissances acquises sur une base de données riche pour les transférer vers une base plus pauvre en données labellisées. Au final, l'apprentissage par transfert permettrait d'entraîner un modèle sur une base de données numériques et d'utiliser quelques données expérimentales pour corriger les prédictions sur les structures réelles.

La définition du transfert suggère que de nombreuses configurations de transfert sont possibles : entre des domaines différents, pour des tâches différentes, avec un nombre de données labellisées qui varie fortement, etc. Il existe ainsi un nombre important de méthodes et d'approches selon les configurations. Les connaissances sous-jacentes entre le domaine source et le domaine cible prennent la forme de caractéristiques extraites des données. Elles peuvent être déterminées par l'utilisateur comme lors du calcul de DI mais dans le cas de l'apprentissage profond celles-ci sont calculées automatiquement par les différentes couches des CNNs. La majorité des approches combinant des stratégies d'apprentissage profond avec du transfert cherchent des caractéristiques communes au

deux domaines, c'est-à-dire des caractéristiques dont les distributions entre le domaine source et le domaine cible sont alignées. Quatre catégories d'apprentissage par transfert sont distinguées [152] :

Approche fondée sur les échantillons Les approches s'appuyant sur les échantillons sélectionnent certains échantillons du domaine source comme compléments au jeu d'entraînement du domaine cible. Une distance détermine l'écart entre les échantillons des deux domaines (la norme euclidienne dans [153] ou la distance de Mahalanobis dans [154]). Seuls les échantillons proches sont préservés via une stratégie de pondération pour imposer des distributions similaires entre les deux domaines. En revanche, un certain nombre d'échantillons sont de ce fait exclus de l'apprentissage avec le risque de perdre de l'information. Cette approche ne peut se faire que lorsque le nombre d'échantillons est important dans le domaine source et dans le domaine cible.

Approche fondée sur une projection Les données issues du domaine source et du domaine cible sont projetées dans un nouvel espace de représentations commun aux deux domaines. Dans cette approche qui peut également se retrouver sous le nom d'**adaptation de domaine**, l'entraînement se fait simultanément avec les données cibles et sources. Le plus souvent une erreur probabiliste aligner les distributions des caractéristiques sources et cibles. Ainsi, la Maximum Mean Discrepancy (MMD) pénalise l'écart entre les distributions sources et cibles des prédictions d'un CNN permettant alors le transfert entre deux systèmes d'engrenages surveillés par des accéléromètres dans [155]. Cette approche appelée Joint Distribution Adpatation (JDA) a été proposée par [156] pour la classification d'images et cherche à aligner simultanément les distributions marginales et conditionnelles du domaine source et du domaine cible. Elle se retrouve dans [12, 111] où le transfert est utilisé pour compenser les effets des réparations d'une aile d'avion en composite sur les distributions des caractéristiques des données. Dans [110], un LSTM est entraîné à quantifier un dommage avec des données de structures différentes à l'aide de la JDA. Dans une approche innovante reprenant les travaux de [157], les méthodes d'apprentissage profond sont combinées avec les avancées récentes en transport optimal en intégrant à la fonction de coût d'un CNN le coût de transport optimal des caractéristiques cibles vers les caractéristiques sources dans [158]. Le problème de transport optimal exploité dans notre méthode sera détaillé dans la Section 5.3.2. L'apprentissage se fait alors en deux étapes à chaque itération : dans un premier temps le coût de transport est déterminé puis dans un second temps le modèle est entraîné. Dans ce cas, le modèle est entraîné en utilisant simultanément les données sources et les données cibles. Ce nouveau type de pénalisation lors de l'entraînement contraint l'extraction de caractéristiques communes entre les deux domaines.

Les méthodes d'adaptation de domaine sont plus couramment utilisées en dehors de cadre de l'apprentissage profond, en complément des méthodes classiques d'apprentissage machine tel que le KRG ou le GP. Le Transfer Component Analysis (TCA) introduit dans [159] est une des approches les plus courantes que l'on retrouve notamment dans [160] où l'apprentissage par transfert permet de calibrer un jumeau numérique d'un procédé de perçage sans label préalable sur le domaine cible. La TCA est également utilisée dans [106] pour compenser l'écart entre un modèle numérique et une structure réelle. Des études numériques et expérimentales valident l'efficacité d'une méthode de mise à jour dynamique de modèle pour identifier la position et l'étendue des dommages.

Approche fondée sur le réseau Un modèle entraîné dans un premier temps sur le domaine source est partiellement ré-entraîné sur le domaine cible. Lors du ré-apprentissage (ou *fine tuning* en anglais), seule une partie des poids est modifiée (souvent les poids des couches les plus profondes) et le taux d'apprentissage est volontairement maintenu faible afin que le modèle soit légèrement modifié et qu'il n'oublie pas la première phase de l'apprentissage. Cette approche est par exemple utilisée avec le réseaux VGG6 [161] entraîné pour reconnaître des motifs dans des images et partiellement ré-entraîné pour détecter des tumeurs cancéreuses dans des radiographies pulmonaires. Bien que la base d'entraînement source ne contienne aucune image de tumeur, le pré-entraînement du réseau augmente tout de même de considérablement la qualité de ses prédictions [162]. Dans une démarche similaire mais pour une application de SHM, un CNN entraîné pour la classification d'image est réentraîné pour détecter des dommages à l'aide d'une caméra filmant un pont dans [109]. Dans une application de surveillance d'un barrage par un CNN, un transfert par ré-apprentissage compense des variations de positions des capteurs dans [20]. Dans [22], un CNN est ré-entraîné partiellement en minimisant la MMD entre les caractéristiques extraites par les convolutions pour la surveillance de rails par des mesures d'émissions acoustiques.

Approche fondée sur un apprentissage adverse Sur le modèle du GAN présenté dans le chapitre 3, deux modèles adverses sont entraînés simultanément pour trouver des représentations communes entre le domaine source et le domaine cible [163, 164]. Un premier modèle est chargé de résoudre les deux tâches en donnant des labels aux données. Un second modèle s'appuie sur les caractéristiques extraites sur une couche intermédiaire pour déterminer s'il s'agit de données provenant du domaine source ou du domaine cible. En pénalisant le premier modèle par les performances du second, il devient possible de le contraindre à calculer des représentations communes aux deux modèles.

5.3 Transfert d'apprentissage profond par transport optimal

5.3.1 Originalité de l'approche proposée

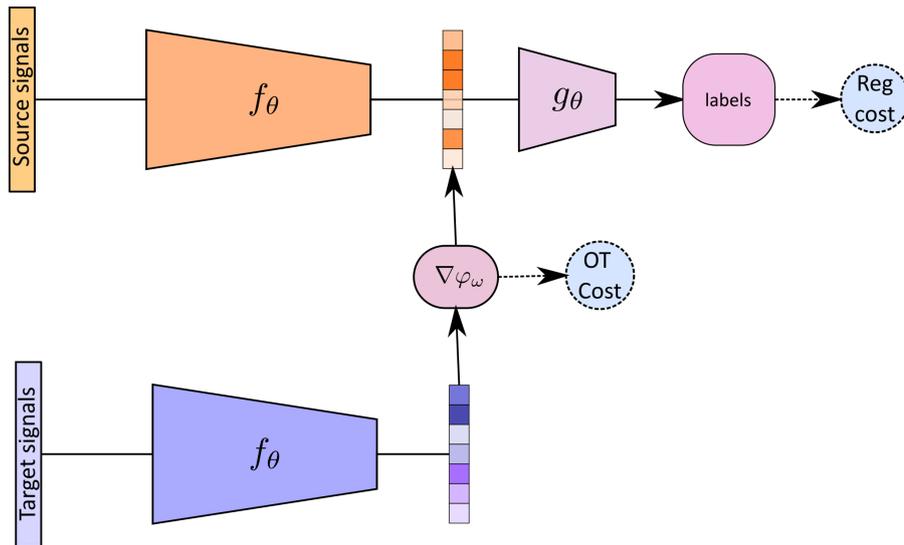


FIGURE 5.5 – Apprentissage de transfert profond basé sur le transport de caractéristiques avec la dualité de Monge-Kantorovich

Positionnement de la méthode La revue bibliographique précédente montre que les CNNs sont des outils performants en SHM pour caractériser les dommages avec des signaux de propagation d'ondes. L'approche d'apprentissage par transfert proposée doit être compatible avec l'implémentation de tels modèles. Les approches de transfert fondées sur des projections ont également montré des résultats prometteurs, en particulier pour suivre une population de coupons similaires [12, 24, 165]. Cependant, la plupart des méthodes de Adaptation de Domaine (*Domain Adaptation* en anglais, DA) s'intègrent difficilement dans une implémentation d'apprentissage profond et l'approche fondée sur une projection prend alors généralement la forme d'une simple régularisation pour forcer l'extraction de caractéristiques communes. Le coût des données en SHM impose de minimiser leur nombre dans le domaine cible, ce qui conduit à maximiser la capacité de généralisation des modèles proposés avec seulement quelques données cibles. Des progrès récents appliquant la théorie du transport optimal [151] avec des réseaux neuronaux calculent des transformations entre deux distributions avec un faible nombre d'échantillons et une grande capacité de généralisation [166, 167]. Son utilisation dans une approche d'apprentissage profond par transfert peut répondre aux exigences précédentes.

Ce travail présente une preuve de concept pour l'utilisation du transport optimal

dans une stratégie d'apprentissage profond par transfert en SHM. Notre approche vise à transporter les caractéristiques extraites des signaux par la partie convolutive d'un CNN, du domaine cible vers le domaine source, en appliquant la théorie du transport optimal. Cette approche appartient à deux catégories mentionnées précédemment : elle est à la fois *fondée sur une projection* et *fondée un apprentissage adverse*. Tout comme la méthode Joint Distribution Optimal Transport (JDOT) [158], le coût de transport optimal quantifie l'écart entre les distributions des caractéristiques du domaine source du domaine cible. Ce coût de transport contraint le CNN à apprendre des caractéristiques communes en pénalisant la fonction de coût. De plus, dans notre approche, le coût de transport est calculé à l'aide d'un réseau neuronal entraîné en parallèle, ce qui en fait une approche fondée sur un apprentissage adverse. Un des avantages de notre approche est que le transport n'est pas uniquement utilisé pour pénaliser l'écart entre les caractéristiques des deux domaines mais il est également appliqué pour corriger cet écart par l'intégration des potentiels de Kantorovich dans le CNN. L'approche présentée ici est entièrement supervisée : nous utilisons des labels dans le domaine cible. La méthode peut simplement être adaptée dans le cas d'un transfert non-supervisé ou semi-supervisé avec quelques hypothèses sur les distributions des labels des deux domaines.

Architecture globale Le CNN initial avec l'architecture Figure 5.4 est conçu pour estimer la position et la sévérité d'un dommage sur le jeu de données source. Il est dupliqué en deux CNNs (voir Figure 5.5) : le premier appelé *modèle source* \mathcal{M}_θ^s est une simple composition de la partie convolutive f_θ et de la partie entièrement connectée g_θ . Le modèle *cible* $\mathcal{M}_{\theta,\omega}^t$ partage les mêmes parties convolutives et entièrement connectées avec le modèle source, mais à la L -ième couche, un autre modèle φ_ω est inséré afin de résoudre le problème de transport optimal. Plus de détails sur le modèle de transport optimal φ_ω sont donnés dans la suite du chapitre. Ainsi, nous avons par une composition les relations suivantes :

$$\begin{aligned}\mathcal{M}_\theta^s &= g_\theta \circ f_\theta \\ \mathcal{M}_{\theta,\omega}^t &= g_\theta \circ \nabla\varphi_\omega \circ f_\theta\end{aligned}\tag{5.1}$$

avec : \mathcal{M}_θ^s le modèle source,

$\mathcal{M}_{\theta,\omega}^t$ le modèle cible,

f_θ la partie convolutive du réseau qui extrait les caractéristiques des données avec une profondeur L ,

g_θ la partie discriminante qui résout la tâche de régression ou de classification avec une profondeur $N - L$,

$\nabla\varphi_\omega$ le gradient modèle qui résout le problème de transport.

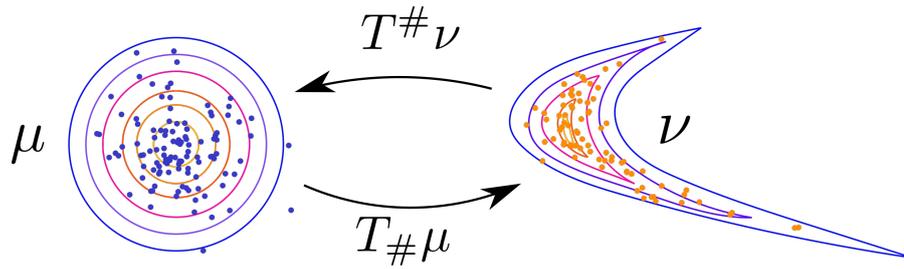


FIGURE 5.6 – Transport entre deux distributions (μ, ν) par les transformations $T_{\#}$ et $T^{\#}$.

5.3.2 Introduction au transport optimal

5.3.2.1 Le problème de Monge

Le problème du transport optimal a été décrit dès le XVIII^e siècle par Monge : il s'agit de trouver la solution la plus économique pour déplacer des objets d'un ensemble de points de départ vers un ensemble de points d'arrivée. Les solutions à ce problème ont des applications multiples en logistique et en économie. Plus récemment, le transport optimal a connu une renaissance avec des applications en mécanique des fluides qui ont encouragé son déploiement dans des domaines variés allant de la physique à la science des données.

Pour décrire ce problème, nous considérons deux mesures de probabilité sur des espaces \mathcal{X} et \mathcal{Y} tel que la mesure cible $\mu \in \mathcal{X}$ et la mesure source $\nu \in \mathcal{Y}$. Nous considérons de plus une application T . On dit que T transporte la mesure μ sur la mesure ν si pour toute application mesurable positive f on a :

$$\int f(T(x))d\mu(x) = \int f(y)d\nu(y) \quad (5.2)$$

Le transport se note alors : $T_{\#}\mu = \nu$. Le transport dans le sens inverse, de la mesure source vers la cible, se note : $T^{\#}\nu = \mu$. Le nombre de solutions à ce problème est infini : il peut y avoir une infinité de transformation T entre deux mesures de probabilité mais il est également possible qu'il n'y ait pas de solution et qu'aucun transport n'existe. Si une transformation de transport existe, un coût $c : \mathcal{X} \times \mathcal{Y} \rightarrow \mathbb{R}^+$ représentant l'énergie nécessaire pour déplacer une unité de masse de μ vers ν peut être calculé. En utilisant cette fonction, le coût total pour envoyer μ vers ν par l'application T est alors la somme :

$$C(T) = \int_{\mathcal{X}} c(x, T(x))d\mu(x) \quad (5.3)$$

La minimisation de ce coût $C(T)$ parmi l'ensemble des transformations T possibles sous la contrainte $\mu = T_{\#}\nu$ revient à résoudre le **problème de Monge** et l'application T^* qui en résulte est une **transformation de transport optimale** (*Optimal Transport Map*, en anglais). Une infinité de fonction de coût existent et son choix influence évidemment le

résultat du calcul de la transformation optimale [150]. L'existence du transport, son unicité et sa monotonie lorsque la fonction de coût $c(\mu, \nu)$ est quadratique sont démontrées dans [168].

Le **transport de Knothe**, proposé indépendamment par [169] et [170] recherche des solutions au problème de Monge parmi des transformations numériquement avantageuses : les réarrangements de Knothe-Rosenblatt. Cette approche implémentée dans [91] en minimisant la divergence de Kullback-Leibler est particulièrement adaptée pour le transport de densités lorsqu'elles sont connues et accessibles. Elle peut être également utilisée pour inférer une densité à partir d'un échantillonnage. Ces réarrangements sont notamment utilisés pour réduire le temps de calcul des méthodes de type MCMC [90, 91]. Leurs utilisations restent limitées car le coût de calcul devient vite prohibitif avec l'augmentation du nombre de dimensions des distributions à transporter.

5.3.2.2 Le problème primal de Monge-Kantorovich

Le problème de Monge (Équation 5.3) peut être relaxé en un problème plus simple en introduisant une distribution conjointe Π dont les distributions μ et ν sont respectivement la première et la seconde marginale [171]. Il ne s'agit plus de résoudre le problème avec une fonction mais avec une mesure appelée plan de transport. Le problème primal de Monge-Kantorovich revient alors à calculer l'optimisation suivante :

$$C(\mu, \nu) = \inf_{\pi \in \Pi(\mu, \nu)} \int_{\mathcal{X} \times \mathcal{Y}} c(x, y) d\pi(x, y) \quad (5.4)$$

parmi toutes les mesures Π sur $\mathcal{X} \times \mathcal{Y}$ admettant μ et ν pour première et seconde marginales. Cette formulation primale est mathématiquement avantageuse par rapport à celle précédente [150], notamment l'existence d'un minimum est garantie avec des hypothèses peu contraignantes sur la fonction de coût.

Lorsque le problème primal est décrit sous une forme discrète, il devient un problème classique d'optimisation linéaire et peut se résoudre très rapidement [172]. Une implémentation est proposée dans [173] et est exploitée dans la JDOT [157, 158]. Cette implémentation calcule la distance entre deux histogrammes multi-dimensionnels mais elle ne permet pas de transporter des nouvelles données. Afin de pouvoir transporter de nouveaux échantillons d'une distribution vers une autre - ce qui est nécessaire dans notre approche de transfert - le transport doit être une transformation continue. Le calcul du plan de transport dans sa forme discrète n'est donc pas adapté à notre problème.

5.3.2.3 Distance de Wasserstein

Il existe une infinité de possibilités pour le choix de la fonction de coût, la distance Wasserstein- p est le coût de transport optimal calculé avec $c(x, y) = \frac{1}{p} \|x - y\|_2^p$ où $\|\cdot\|_2$

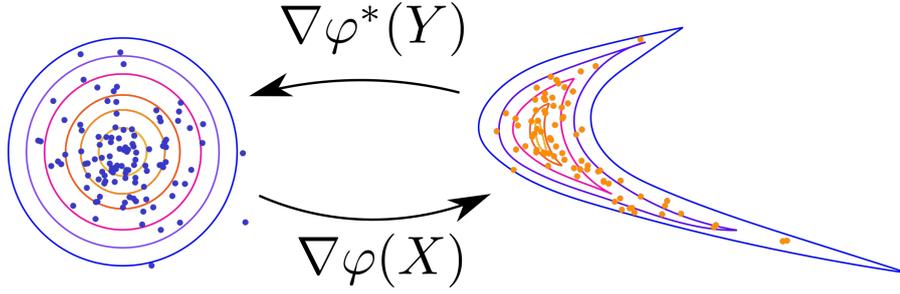


FIGURE 5.7 – Transport entre deux distributions (μ, ν) par les potentiels de Kantorovich φ et $\bar{\varphi}$

désigne la norme euclidienne. La distance de Wasserstein-2 est largement utilisée :

$$W_2^2(\mu, \nu) = \inf_{\pi \in \Pi(\mu, \nu)} \left(\int \int \frac{1}{2} \|x - y\|_2^2 d\pi(x, y) \right) \quad (5.5)$$

5.3.2.4 Le problème dual de Monge-Kantorovich

Lorsqu'un problème primal est difficile à résoudre, il peut être relaxé sous une forme duale [174]. La dualité de Monge-Kantorovich, une dualité spécifique à la théorie du transport a été proposée par Kantorovich [171] :

$$W_2^2(\mu, \nu) = \sup_{\psi(y) - \varphi(x) \leq c(x, y)} \left(\int_{\mathcal{Y}} \psi(y) d\nu(y) - \int_{\mathcal{X}} \varphi(x) d\mu(x) \right) \quad (5.6)$$

Lors du calcul de la distance W_2^2 , le maximum est choisi parmi tous les couples de fonctions potentielles $(\varphi, \psi) \in (L^1(\mathcal{Z}_s, \mu) \times L^1(\mathcal{Z}_t, \nu))$ respectant l'inégalité $\psi(y) - \varphi(x) \leq \frac{1}{2} \|x - y\|_2^2$. Le couple de fonctions (φ, ψ) respecte cette inégalité si φ est convexe (Il s'agit plus généralement de la c -convexité, une convexité par rapport à la distance c qui correspond à la convexité usuelle dans le cas de la distance de W_2^2 où $c(x, y) = \frac{1}{2} \|x - y\|_2^2$) et ψ est le conjugué de φ noté $\psi = \bar{\varphi}$ [151]. La résolution du problème est obtenue en trouvant une seule fonction convexe :

$$W_2^2(\mu, \nu) = \sup_{\varphi \in L^1(\nu)} \int \varphi d\mu + \int \bar{\varphi} d\nu \quad (5.7)$$

avec : $\bar{\varphi}(y) = \sup_x \left(\frac{1}{2} \|x - y\|_2^2 - \varphi(x) \right)$

Revenons à la contrainte sur les fonctions potentielles : en développant le carré de la norme par le théorème de Pythagore, l'inégalité est équivalente à une autre :

$$\varphi(x) + \bar{\varphi}(y) \leq \frac{1}{2} \|x - y\|_2^2 \iff \left[\frac{1}{2} \|x\|_2^2 - \varphi(x) \right] + \left[\frac{1}{2} \|y\|_2^2 - \bar{\varphi}(y) \right] \geq \langle x, y \rangle \quad (5.8)$$

Et en effectuant le double changement de variable suivant :

$$\begin{cases} \frac{1}{2} \|\cdot\|_2^2 - \bar{\varphi}(\cdot) \leftarrow \bar{\varphi}(\cdot) \\ \frac{1}{2} \|\cdot\|_2^2 - \varphi(\cdot) \leftarrow \varphi(\cdot) \end{cases} \quad (5.9)$$

la distance de Wasserstein-2 est alors reformulée par :

$$W_2^2(\mu, \nu) = C_{\mu, \nu} - \inf_{\varphi \in CVX(\nu)} \int \varphi d\mu + \int \bar{\varphi} d\nu \quad (5.10)$$

avec : $C_{\mu, \nu} = \frac{1}{2} \int \|x\|_2^2 d\mu(x) + \frac{1}{2} \int \|y\|_2^2 d\nu(y)$ une constante indépendante de $(\varphi, \bar{\varphi})$
 $\bar{\varphi}(y) = \sup_x \langle x, y \rangle - \varphi(x)$ le conjugué de φ (ou transformée de Legendre-Fenchel).

5.3.2.5 Théorème de Brenier

Considérons que le coût de transport optimal est atteint avec une mesure optimale π^* dans l'équation 5.6 et par une fonction convexe optimale φ^* dans l'équation 5.7. Le théorème de Brenier (ou théorème de factorisation polaire [175]) fait remarquablement le lien entre la mesure optimale et la fonction convexe optimale :

Theorem 5.3.1 *Théorème de factorisation polaire Soient $d\mu(x) = \varphi(x)dx$ et $d\nu(y) = \psi(y)dy$ deux mesures de probabilité sur \mathbb{R} absolument continues par rapport à la mesure de Lebesgue¹. Alors il existe un unique gradient de fonction convexe $\nabla\varphi$, tel que :*

$$\nabla\varphi = \nu \quad (5.11)$$

De plus, si les seconds moments $\int |x|^2 d\mu(x)$ et $\int |y|^2 d\nu(y)$ sont finis, alors φ est l'unique minimiseur de la fonction de coût quadratique $\int |x - T(x)|^2 d\mu(x)$ parmi toutes les applications T qui transportent μ sur ν

5.3.2.6 Formulation Minimax du problème dual

Le plus souvent les densités ne sont pas accessibles et les distributions sont échantillonnées, le problème de l'équation 5.10 prend alors la forme d'une optimisation stochastique sur les poids d'un modèle φ en approximant les espérances sur des échantillons aléatoires de μ et ν .

$$W_2^2(\mu, \nu) = C_{\mu, \nu} - \inf_{\varphi \in CVX(\mu)} \mathbb{E}_{x \sim \mu} [\varphi(x)] + \mathbb{E}_{y \sim \nu} [\bar{\varphi}(y)] \quad (5.12)$$

En pratique, la contrainte sur le conjugué $\bar{\varphi}(y) = \sup_x \langle x, y \rangle - \varphi(x)$ de l'équation 5.12 n'est pas facile à appliquer. À l'aide du Théorème 5.3.1, nous pouvons introduire une autre fonction convexe ψ telle que : $\bar{\varphi}(y) = \sup_{\psi} \langle y, \nabla\psi(y) \rangle - \varphi(\nabla\psi(y))$. Le problème est alors reformulé comme une optimisation Maximin (Théorème 3.3 de [167]) :

1. En théorie de la mesure, la mesure de Lebesgue généralise le concept de volume aux sous-espaces d'un espace euclidien à n dimensions.

$$W_2^2(\mu, \nu) = \sup_{\varphi \in \text{CVX}(\mu)} \inf_{\psi \in \text{CVX}(\nu)} \mathcal{V}_{\mu, \nu}(\varphi, \psi) + C_{\mu, \nu} \quad (5.13)$$

avec : $\mathcal{V}_{\mu, \nu}(\varphi, \psi)$ une valeur qui dépend de φ et ψ tel que :

$$\mathcal{V}_{\mu, \nu}(\varphi, \psi) = -\mathbb{E}_{x \sim \mu}[\varphi(x)] - \mathbb{E}_{y \sim \nu}[\langle y, \nabla \psi(y) \rangle - \varphi(\nabla \psi(y))]$$

Il existe alors une paire optimale de fonctions (φ^*, ψ^*) assurant respectivement l'infimum et le suprémum où $\nabla \varphi^*$ est le transport optimal de ν à μ .

5.3.2.7 Potentiels de Kantorovich neuronaux

Les récentes avancées dans l'étude des ANNs et les progrès importants réalisés pour leur entraînement invitent à les exploiter pour le calcul du problème de transport. Cela permet de donner une justification mathématique forte aux architectures des ANNs. Les ANNs étant notamment capables de traiter efficacement des données à très grandes dimensions, il devient alors envisageable de transporter toutes sortes de données. Nous détaillerons ici les approches où les potentiels sont recherchés sous la forme de ANNs pour intégrer la théorie du transport optimal à des méthodes d'apprentissage profond.

La transformation du problème dual en un problème d'optimisation de type minimax a été proposée à plusieurs reprises avec succès. Un type particulier de réseau, l'ICNN (détaillé dans la Section 5.3.2.8) a des propriétés de convexité très intéressantes pour être utilisé comme potentiel de Kantorovich.

Dans [176], un unique modèle d'ICNN est entraîné, le conjugué étant calculé avec la formule l'équation 5.10. Cette dernière approche était complexe à entraîner, l'algorithme a alors été amélioré et relaxé par [167] en substituant le conjugué par un autre ICNN. C'est cette approche que nous adoptons ici. Cette formulation minimax est difficile à résoudre et les difficultés rencontrées lors de l'entraînement des GANs (Section 3.3.3.4) se retrouvent alors (instabilité, non-convergence, effondrement des modes, etc.). Il faut parvenir à trouver le bon jeu d'hyperparamètres qui permettra de réaliser correctement le transport. Dans [177], le problème minimax de l'équation 5.13 est résolu avec un ICNN comme potentiel combiné à un générateur inspiré des GANs afin de calculer le transport entre des distributions avec des dimensions différentes. La résolution du problème de transport avec des distributions de dimensions différentes est également proposée par [178] qui compare les solutions pour différentes fonctions de coût.

La formulation minimax de l'équation 5.13 est utilisée à plusieurs reprises pour une forme particulière de GAN, le Wasserstein-GAN [179]. Les performances des GANs pour différentes variantes de la distance de Wasserstein sont comparées dans [180]. La distance de Wasserstein W_2^2 est calculée en résolvant la formulation duale du problème avec des potentiels de Kantorovich sous la forme d'ANNs dans [181, 182, 183].

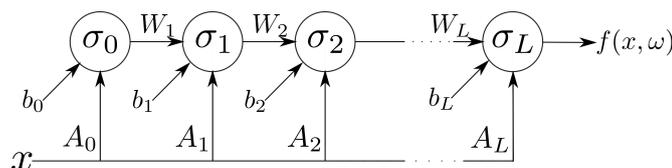


FIGURE 5.8 – Schéma d'un ICNN

Afin de s'abstenir de résoudre un problème minimax souvent difficile à optimiser, une méthode de régularisation a été proposée par [184] qui combine la régularisation L_2 et une régularisation reposant sur l'entropie exploitant les valeurs des potentiels. Cette approche est probablement la première à proposer de modéliser les potentiels de Kantorovich par des ANNs. Dans [185], la distance de Wasserstein–2 est minimisée à l'aide d'un unique ICNN combiné à une nouvelle régularisation : la *cycle-consistency* [186] utilisant les valeurs des gradients des potentiels. Cette même proposition est exploitée pour le calcul des barycentres de Wasserstein [166]. Ce type de barycentres est également calculé avec des ICNNs dans [178].

5.3.2.8 Les Réseaux de neurones convexes par rapport aux entrées

L'ensemble des fonctions convexes permettant de calculer le transport est approximé par des modèles paramétriques reposant sur un type particulier de réseaux de neurones : les réseaux de neurones convexes par rapport aux entrées (ICNN). Ils ont été proposés récemment dans [187] et connaissent un intérêt croissant grâce à leurs propriétés particulières. Ils ont montré de bons résultats pour les problèmes de classification [188], ils ont trouvé des applications dans le cadre de nouvelles stratégies de contrôle [189] mais c'est l'application pour la résolution du problème de transport optimal qui nous intéresse ici [176]. Les ICNNs forment une catégorie de réseaux de neurones à valeurs scalaires tels que la fonction $x \rightarrow f(x, \omega) \in \mathbb{R}$ est convexe. Leurs architectures prennent la forme suivante :

Pour une entrée donnée $x \in \mathbb{R}^d$, la fonction $x \rightarrow f(x, \omega)$ est définie par un réseau de neurones de L couches avec l'expression suivante pour $i \in [0, 1, \dots, L]$:

$$\mathbf{z}_{i+1} = \sigma_i(W_i \mathbf{z}_i + A_i x + b_i), \quad f(x; \omega) = \mathbf{z}_k \quad (5.14)$$

avec σ_i une fonction d'activation. L'ensemble des paramètres de ce type d'architecture est noté ω tel que $\omega = \{A_{0:L}, W_{1:L}, b_{0:L}\}$ et se compose de matrices $A_{0:L-1} \in \mathbb{R}^d \times \mathbb{R}^n$, de vecteurs $W_{1:L-1} \in \mathbb{R}^n$ et de biais $b_{0:L-1} \in \mathbb{R}^n$. La dernière couche se compose d'une matrice $A_L \in \mathbb{R}^d$, d'un vecteur $W_L \in \mathbb{R}$ d'un biais $b_L \in \mathbb{R}$. La convexité de $x \rightarrow f(x, \omega)$ est assurée sous les conditions suivantes [187] :

- tous les poids W_i sont positifs,

- la fonction d'activation σ_0 est convexe,
- σ_i est convexe et non-décroissante $\forall i \in [1, \dots, L - 1]$.

En effet, une somme de fonctions convexes est convexe et la composition $f \circ g$ préserve la convexité si g est convexe et si f est convexe et non-décroissante [174]. De plus, cette classe de fonction est suffisamment riche pour représenter l'ensemble des fonctions convexes [189]. Le choix des ICNNs pour approximer les fonctions convexes et ainsi résoudre le problème de transport est bien valide. Afin de relaxer le problème d'optimisation, et ainsi faciliter l'apprentissage, la contrainte sur les poids $W_i > 0$ peut prendre la forme d'une régularisation pour le modèle lors de l'entraînement [167]. Nous choisissons d'imposer une contrainte stricte sans régularisation supplémentaire.

5.3.3 Algorithme d'apprentissage par transfert profond à l'aide de potentiels de Kantorovich neuronaux

5.3.3.1 Extraction des caractéristiques

Bien que les ICNNs soient théoriquement capables de transporter des données à très grandes dimensions, la résolution du problème de transport est plus facile et numériquement moins coûteuse avec un nombre réduit de dimensions. La partie convolutive f du CNN schématisé Figure 5.4 extrait des informations pertinentes et parcimonieuses des signaux. La taille initiale des données d'entrée est de 6024, réduite à 576 après les convolutions. Après quelques couches entièrement connectées, seules 16 caractéristiques décrivent les données (voir le Tableau 5.5). Le transport est appliqué à cette couche intermédiaire à la profondeur $N - 2$ en insérant le gradient du potentiel de Kantorovich. Dans la formulation de l'équation 5.10, les distributions sont échantillonnées à chaque itération. En pratique, les densités ne sont pas accessibles et le nombre d'échantillons est limité par le jeu de données. Pour surmonter ce problème, l'utilisation de couches de décrochage dans le CNN ajoute de la variabilité à chaque prédiction pendant l'entraînement.

L'MSE entre les paramètres prédits $\widehat{\mathbf{p}}_d$ et les labels réels \mathbf{p}_d est minimisée pour entraîner f_θ et g_θ . En plus de cette erreur, la fonction de coût est pénalisée par le coût de transport avec la distance Wasserstein-2 W_2^2 pour contraindre f_θ à extraire des caractéristiques communes aux domaines cible et source, sur le modèle de la méthode JDOT. Des coefficients sont introduits pour pondérer chacune de ces erreurs : β_s et β_t pondèrent respectivement la MSE sur les données sources et sur les données cibles et α_{ot} pondère l'influence du coût de transport.

$$\mathcal{L}_\theta = \frac{\beta_s}{n_s} \sum_{i=1}^{n_s} \text{MSE}(\mathcal{M}_\theta^s(\mathbf{d}_s^i), \mathbf{p}_{d,s}^i) + \frac{\beta_t}{n_t} \sum_{j=1}^{n_t} \text{MSE}(\mathcal{M}_\theta^t(\mathbf{d}_t^j), \mathbf{p}_{d,t}^j) + \alpha_{ot} W_2^2(\nabla \varphi_\omega(f_\theta(\mathbf{d}_t), f_\theta(\mathbf{d}_s))) \quad (5.15)$$

5.3.3.2 Résolution du problème dual de Monge-Kantorovich

La résolution du problème Maximin de l'équation 5.13 se fait en deux étapes principales répétées à chaque itération. L'utilisation d'un algorithme en deux étapes pour la résolution d'un problème Maximin est habituelle pour le problème de transport [167, 177, 184] mais aussi pour l'entraînement de GAN [124]. Ici, la première étape entraîne le modèle ψ avec des poids γ pour s'assurer que ce modèle est le conjugué de φ et la deuxième étape entraîne φ avec des poids ω pour calculer le transport entre les deux domaines.

$$\max_{\omega: W_l \geq 0, \forall l \in [L-1]} \min_{\gamma: W_l \geq 0, \forall l \in [L-1]} \mathcal{J}_{\omega, \gamma} \quad (5.16)$$

avec :

$$\mathcal{J}_{\omega, \gamma} = \frac{1}{n_t} \sum_{j=1}^{n_t} \varphi_{\gamma}(\nabla \psi_{\omega}(\mathbf{z}_t^j)) - \langle \mathbf{z}_t^j, \nabla \psi_{\omega}(\mathbf{z}_t^j) \rangle - \frac{1}{n_s} \sum_{i=1}^{n_s} \varphi(\mathbf{z}_s^i) \quad (5.17)$$

5.3.3.3 Entraînement global

L'apprentissage global est une optimisation miniMaximin effectuée en 3 étapes : d'abord le modèle d'extraction de caractéristiques et le modèle discriminatif (f et g) sont entraînés pour minimiser le coût \mathcal{L} de l'équation 5.15 et ensuite le problème de transport optimal est résolu en entraînant φ et ψ pour minimiser \mathcal{J} dans l'équation 5.17. L'apprentissage de φ et ψ suit la boucle d'optimisation proposée par l'Algorithme 4. Plusieurs hyperparamètres doivent être optimisés :

α pondère l'influence du coût de transport W_2 ,

β_s, β_t pondèrent l'influence de l'erreur quadratique du modèle source et du modèle cible,

lr le taux d'apprentissage du CNN,

lr_{φ}, lr_{ψ} les taux d'apprentissage des potentiels φ et ψ ,

t_{iter} nombre global d'itérations,

n_{iter} nombre d'itérations du calcul du transport,

k_{iter}, j_{iter} nombre d'itérations de l'entraînement des potentiels φ et ψ ,

n_s, n_t taille du lot source et cible.

5.4 Application au SHM

5.4.1 Architecture détaillée du réseau

L'architecture du CNN initial reprend celle du Chapitre 4. Le transport optimal est calculé par un ICNN de 4 couches de 64 neurones. Le choix de cette architecture a une

Algorithm 4: Dual Monge-Kantorovich problem optimization loop

Input: (μ, ν) source and target distributions; M batch size; T total iterations; φ_ω and ψ_γ : ICNNs with their respective weights ω and γ ;

- 1 **for** $n = 1, \dots, n_{iter}$ **do**
- 2 **for** $k = 1, \dots, k_{iter}$ **do**
- 3 Sample a batch $\{\mathbf{z}_t^j\}_{j=1}^{n_t}$ from ν ;
- 4 Update γ to minimize $\frac{1}{n_t} \sum_{j=1}^{n_t} \varphi_\gamma(\nabla\psi_\omega(\mathbf{z}_t^j)) - \langle \mathbf{z}_t^j, \nabla\psi_\omega(\mathbf{z}_t^j) \rangle$;
- 5 **for** $l = 1, \dots, l_{iter}$ **do**
- 6 Sample a batch $\{\mathbf{z}_s^i\}_{i=1}^{n_s}$ from μ ;
- 7 Update ω to minimize $\frac{1}{n_s} \sum_{i=1}^{n_s} \varphi_\gamma(\mathbf{z}_s^i) - \frac{1}{n_s} \sum_{j=1}^{n_t} \varphi_\gamma(\nabla\psi_\omega(\mathbf{z}_t^j))$;

Algorithm 5: Deep Transfer Learning with Kantorovich Potentials

Input: $\mathcal{M}_\theta = g_\theta \circ f_\theta$: initial model with f_θ feature model extraction model at layer l and discriminative model g_θ ;

$(\varphi_\omega, \psi_\gamma)$: ICNNs with their respective weights ω and γ ;

Data: Set of source data X_s and target data X_t

Output: $\mathcal{M}_\theta^s = g_\theta \circ f_\theta$ and $\mathcal{M}_{\theta, \omega}^t = g_\theta \circ \nabla\varphi_\omega \circ f_\theta$

- 1 $\mathcal{M}_{\theta_0}^s \leftarrow g_{\theta_0} \circ f_{\theta_0}$ Initialize source model ;
- 2 $\mathcal{M}_{\theta_0, \omega_0}^t \leftarrow g_{\theta_0} \circ \nabla\varphi_{\omega_0} \circ f_{\theta_0}$ Initialize target model ;
- 3 **for** $t = 1, \dots, t_{iter}$ **do**
- 4 Sample a batch $(\mathbf{d}_s^i, \mathbf{p}_{d,s}^i)_{i=1}^{n_s}$ and $(\mathbf{d}_t^j, \mathbf{p}_{d,t}^j)_{j=1}^{n_t}$ respectively from X_s and X_t ;
- 5 Update θ to minimize $\mathcal{L}_\theta(X_s^{batch}, X_t^{batch})$ from Equation 5.15;
- 6 $Z_s^{batch} = \{\mathbf{z}_s^i = f_\theta(\mathbf{d}_s^i)\}_{i=1}^{n_s}$;
- 7 $Z_t^{batch} = \{\mathbf{z}_t^j = f_\theta(\mathbf{d}_t^j)\}_{j=1}^{n_t}$;
- 8 Update ω and γ to minimize $\mathcal{J}_{\omega, \gamma}(Z_s^{batch}, Z_t^{batch})$ from Equation 5.17 with Algorithm 4

TABLE 5.4 – Valeurs des hyperparamètres

Hyperparameter	α	β_s	β_t	t_{iter}	n_{iter}	k_{iter}	j_{iter}	n_s	n_t	lr	lr_φ	lr_ψ
Value	$1E-3$	1	1	1000	1	1	4	80	20	$1E-4$	$0.25E-4$	$0.25E-4$

grande influence sur la qualité du transport. Le Tableau 5.5 décrit l’architecture utilisée.

Dans l’équation 5.10, les distributions sont échantillonnées à chaque itération. En pratique, les densités ne sont pas accessibles et le nombre d’échantillons est limité. Pour palier à cela, l’utilisation de couches de décrochage dans l’architecture du CNN (Tableau 5.5) permet d’ajouter de la variabilité à chaque nouvelle prédiction de caractéristique. Les valeurs des différentes hyperparamètres sont visibles dans le Tableau ??.

5.4.2 Évaluation des transferts

$C_0 \rightarrow C_1$ Dans ce cas, le biais du modèle et les incertitudes ont une influence légère sur les performances du CNN et la qualité des prédictions n’est pas fortement détériorée. La stratégie d’apprentissage par transfert proposée n’apporte alors pas de bénéfice clair par rapport à un simple apprentissage sur les données sources (Figure 5.10 et 5.9).

$C_0 \rightarrow C_2$ Dans ce cas, la Figure 5.12a montre bien l’incapacité du modèle à prédire sur une structure dont un capteur est mal positionné. La Figure 5.12b montre que le nombre de données dans le domaine cible est insuffisant pour prédire correctement. Une approche simple qui consisterait à simplement mélanger les deux domaines ne donne pas de résultats satisfaisants. L’approche d’apprentissage par transfert proposée ici permet d’obtenir une nette amélioration des prédictions avec une amélioration de plus de 50% de l’erreur de prédiction sur les données cibles.

$C_0 \rightarrow C_3$ Les résultats de ce dernier cas sont très similaires à ceux du cas précédent, la Figure 5.14a montre les difficultés du modèle à prédire sur une structure dont un capteur est mal positionné et la Figure 5.13 montre que l’approche d’apprentissage par transfert proposée ici permet de diminuer de plus de 50% l’erreur de prédiction sur les données cibles.

5.4.3 Discussions des évaluations

Le Tableau 5.6b et le Tableau 5.6a comparent les différentes approches évaluées respectivement sur les données de validation du domaine source et du domaine cible. La Figure 5.15 compare les évolutions des erreurs pour les différentes méthodes en fonction du SI. Pour des structures trop proches, le transfert n’apporte pas de bénéfices et n’est donc pas nécessaire, le CNN parvient à caractériser avec précision l’endommagement. Lorsque

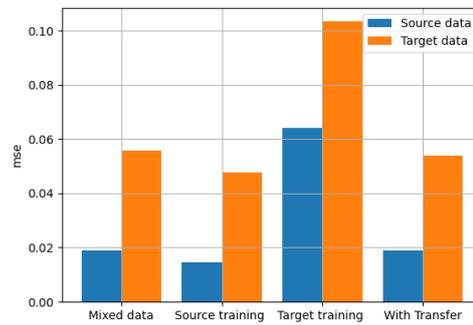
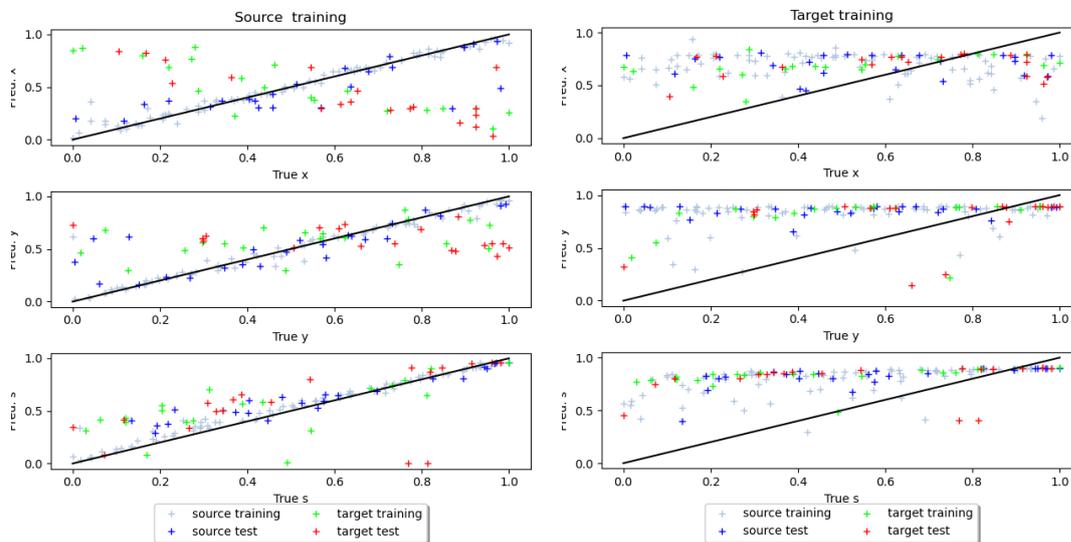
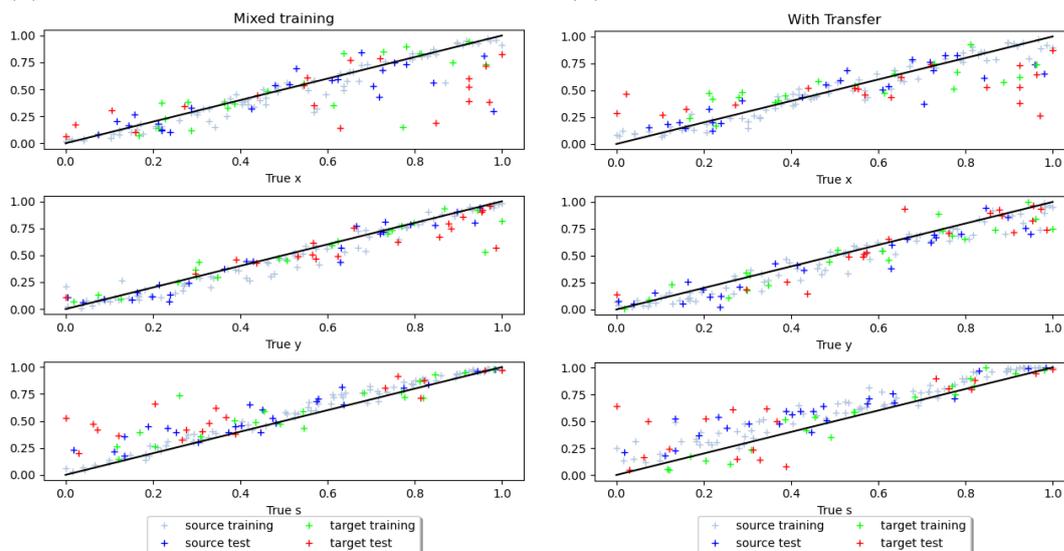


FIGURE 5.9 – Erreur quadratique moyenne du transfert $C_0 \rightarrow C_1$



(a) Entraînement avec les données sources

(b) Entraînement avec les données cibles



(c) Entraînement sans transfert sur les données cibles et sources

(d) Entraînement avec transfert sur les données cibles et sources

FIGURE 5.10 – Évaluation du transfert $C_0 \rightarrow C_1$

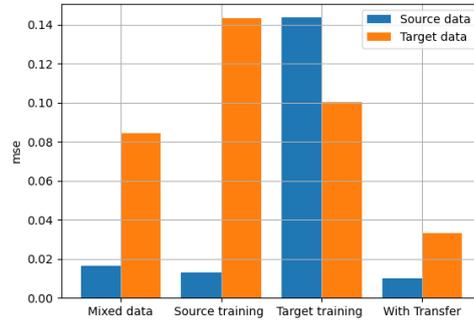
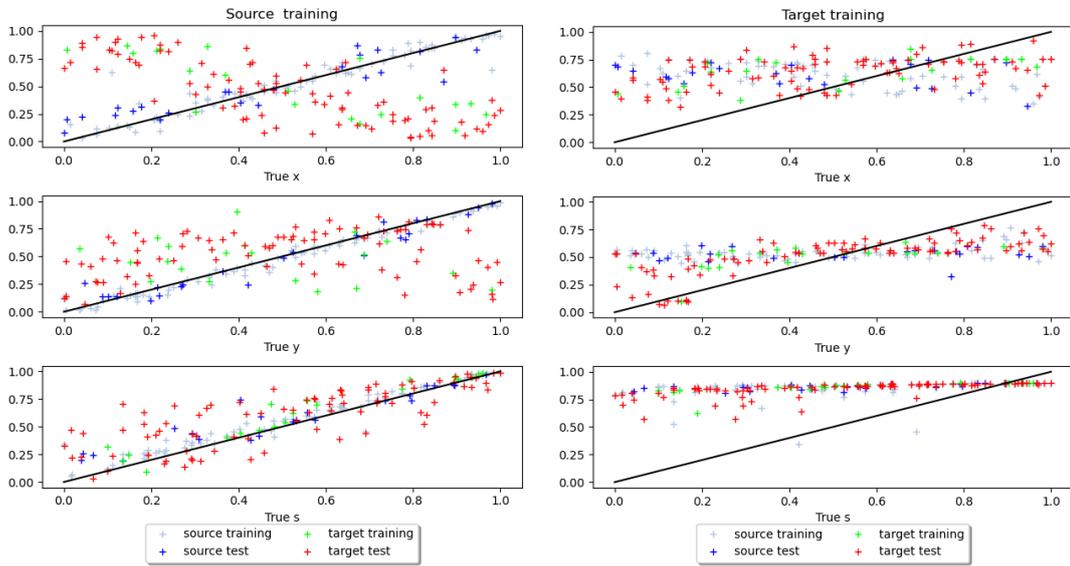
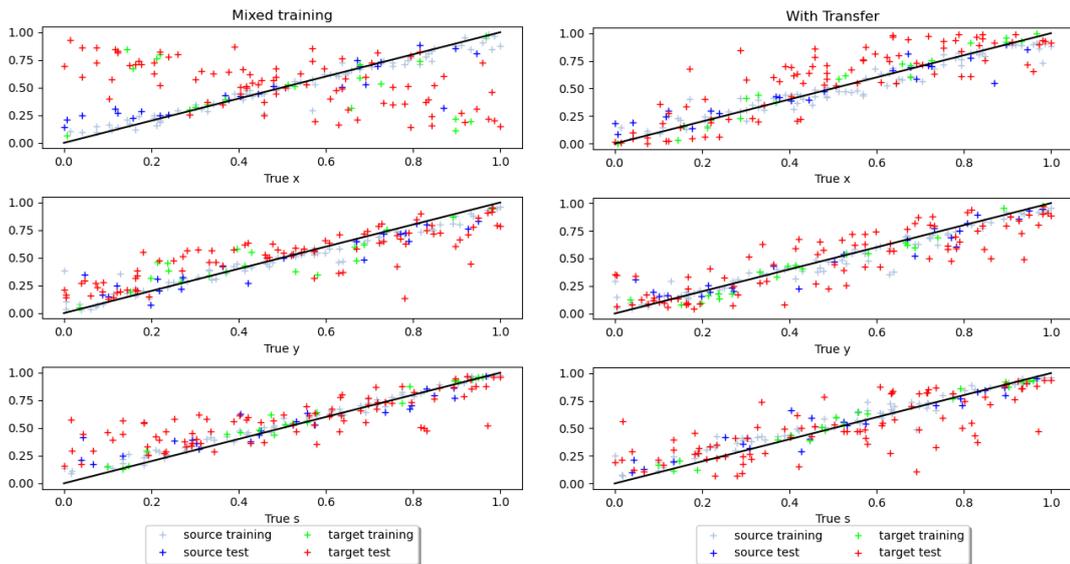


FIGURE 5.11 – Erreur quadratique moyenne du transfert $C_0 \rightarrow C_2$



(a) Entraînement avec les données sources

(b) Entraînement avec les données cibles



(c) Entraînement sans transfert sur les données cibles et sources

(d) Entraînement avec transfert sur les données cibles et sources

FIGURE 5.12 – Évaluation du transfert $C_0 \rightarrow C_2$

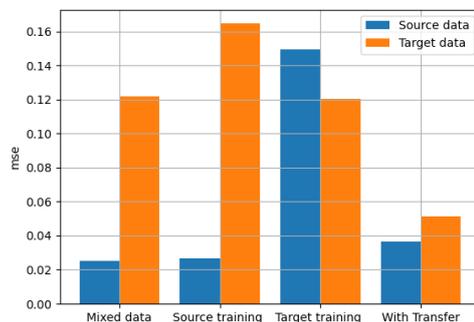
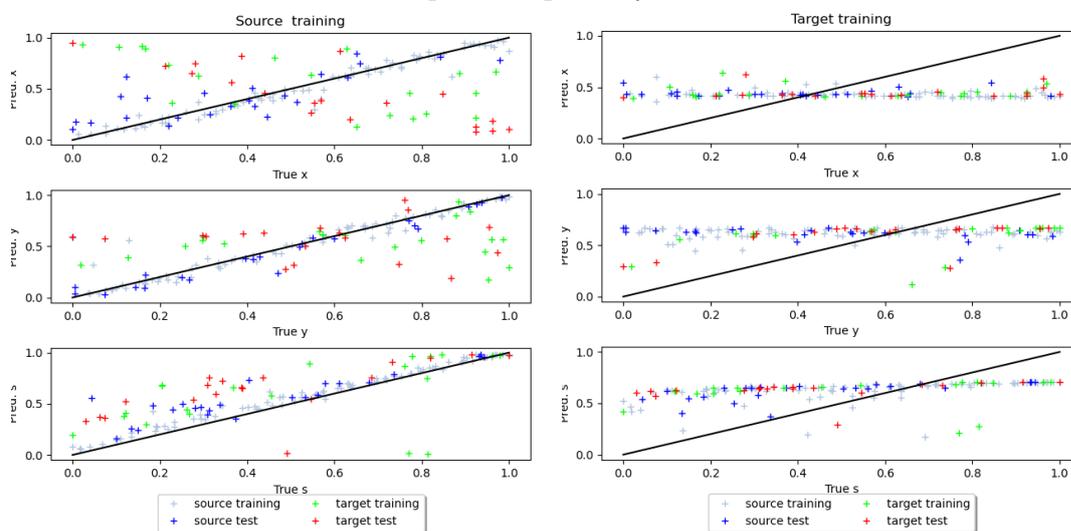
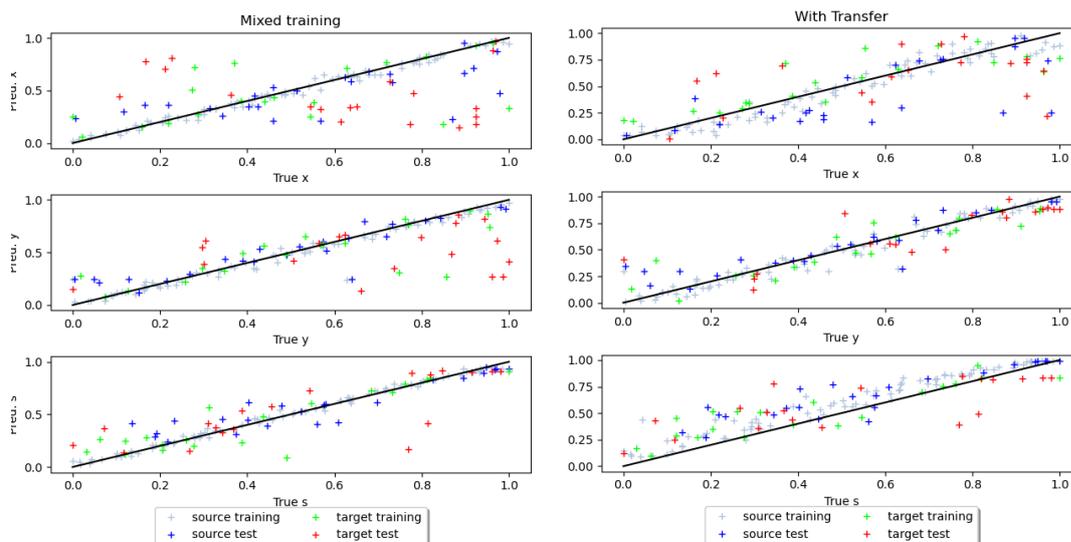


FIGURE 5.13 – Erreur quadratique moyenne du transfert $C_0 \rightarrow C_3$



(a) Entraînement avec les données sources

(b) Entraînement avec les données cibles



(c) Entraînement sans transfert sur les données cibles et sources

(d) Entraînement avec transfert sur les données cibles et sources

FIGURE 5.14 – Évaluation du transfert $C_0 \rightarrow C_3$

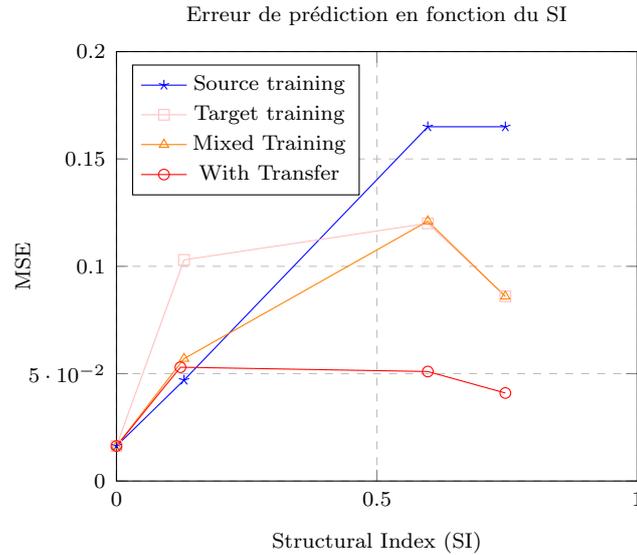


FIGURE 5.15 – Évolution de l’erreur de prédiction en fonction du SI

le SI devient plus important (ici supérieur à 0.5), l’écart entre les données sources et les données cibles détériore considérablement les prédictions du CNN. Le transfert est alors nécessaire et l’approche proposée réduit l’erreur de près de 50%. L’algorithme global n’est cependant pas toujours facile à entraîner en raison de sa formulation MiniMaximin. Les différentes erreurs et la formulation Maximin du problème de transport le rendent parfois instable ou ne lui permettent pas de converger vers une solution acceptable.

5.5 Conclusion

En transférant les connaissances acquises sur une base de données riches vers une base plus pauvre en données, le CNN intégrant les potentiels de Monge-Kantorovich parvient à considérablement améliorer les prédictions et à compenser les biais des modèles et incertitudes expérimentales. Il devient alors possible de n’utiliser qu’un nombre réduit de simulations pour entraîner un nouveau réseau sur une structure nouvelle mais relativement similaire. Un indicateur synthétique, le SI est proposé pour quantifier l’écart entre deux structures adapté aux SHM à base d’ondes de Lamb.

L’apprentissage par transfert réduit considérablement le temps de calcul nécessaire pour la génération de base de données en SHM. De plus, cette approche pourra être déployée sur des bases de données expérimentales où un ensemble de coupons similaires ont été endommagés et caractérisés. Il sera alors possible de suivre des nouveaux coupons en s’appuyant sur les données acquises sur un nombre réduit de coupons. Cette approche ouvre la voie vers des modèles d’apprentissage profond hybrides mélangeant des données numériques nombreuses avec des données expérimentales parcimonieuses.

TABLE 5.5 – Architectures du modèle en charge d’extraire les caractéristiques f_θ , du potentiel de Kantorovich φ_ω et du discriminateur g_θ

Model	Layer	Parameter	Value
f_θ	Input	size	10040
	Conv1D	Filter number \times size	8x10
	Activation	Function	ReLU
	Conv1D	Filter number \times size	8x10
	Activation	Function	ReLU
	MaxPool	Window size	10
	Dropout	τ	0.05
	Conv1D	Filter number \times size	16x10
	Activation	Function	ReLU
	Conv1D	Filter number \times size	16x10
	MaxPool	Window size	4
	Activation	Function	ReLU
	Dropout	τ	0.05
	Conv1D	Filter number \times size	32x5
	Activation	Function	ReLU
	Conv1D	Filter number \times size	32x5
	Activation	Function	ReLU
	MaxPool	Window size	4
	Conv1D	Filter number \times size	64x5
	Conv1D	Filter number \times size	64x5
	MaxPool	Window size	4
	Activation	Function	ReLU
	Dropout	τ	0.05
	Dense	Number of neurons	64
	Activation	Function	ReLU
	Dense	Number of neurons	16
	Activation	Function	ReLU
φ_ω	Input Convex Layer	Number of neurons	256
	Input Convex Layer	Number of neurons	64
	Input Convex Layer	Number of neurons	64
	Input Convex Layer	Number of neurons	64
	Input Convex Layer	Number of neurons	1
∇ Gradient Layer			
g_θ	Activation	Number of neurons	ReLU
	Dense	Number of neurons	3
	Activation	Function	SoftMax

TABLE 5.6 – Évaluation du transfert

(a) Erreur (MSE) sur les données de validation du domaine cible

	$C_0 \rightarrow C_0$	$C_0 \rightarrow C_1$	$C_0 \rightarrow C_2$	$C_0 \rightarrow C_3$
Source only	0.047	0.047	0.161	0.165
Target only	-	0.103	0.101	0.120
Mixed data	-	0.057	0.083	0.121
OT Transfer	-	0.053	0.033	0.051

(b) Erreur (MSE) sur les données de validation du domaine source

	$C_0 \rightarrow C_0$	$C_0 \rightarrow C_1$	$C_0 \rightarrow C_2$	$C_0 \rightarrow C_3$
Source only	0.0163	0.0163	0.033	0.026
Target only	-	0.063	0.150	0.151
Mixed data	-	0.0195	0.0173	0.025
OT Transfer	-	0.0194	0.0133	0.036

Conclusion générale et perspectives

Conclusion générale

Le développement de structures intelligentes équipées d'un système de SHM à base d'ondes de Lamb est un choix à privilégier pour le déploiement de la maintenance prédictive dans le secteur aéronautique. Cette technologie active et locale est sensible aux endommagements de petites tailles et permet d'inspecter des larges portions d'une structure avec un nombre réduit de PZTs. La collecte en temps réel d'une grande quantité de données à traiter rend l'usage des stratégies d'apprentissage particulièrement attractif et ces travaux ont cherché à repérer, développer et déployer les méthodes les plus appropriées aux spécificités du SHM.

Le procédé de délaminages induits par des chocs laser répond pleinement aux besoins d'endommagements maîtrisés et réalistes du SHM des structures composites. Les délaminages des deux plaques endommagées sont très nettement visibles par les CNDs par UT. Ils sont également détectés par le dispositif de SHM à base d'onde de Lamb proposé dans ces travaux. Les meilleurs DI pour la détection et les meilleurs algorithmes pour la localisation sont identifiés. De plus, les données collectées permettent de recalibrer un modèle par éléments finis de la structure intelligente équipée de ses PZTs mais des écarts persistent avec la structure expérimentale équivalente en raison des incertitudes sur les propriétés matériaux et le positionnement réel des capteurs. En s'appuyant sur ce modèle, 4 structures (une poutre, une petite plaque, une grande plaque et une structure courbe) sont conçues pour générer des bases de données utiles au développement et à l'évaluation des méthodes d'apprentissage et de transfert.

La modélisation d'un dispositif de SHM à base d'ondes de Lamb en un système entrée/sortie est nécessaire en raison des méconnaissances sur la physique sous-jacente, des biais et des incertitudes sur les paramètres structurels, opératoires et les modélisations imparfaites des endommagements. Ce système permet alors de distinguer clairement le problème direct et le problème inverse. Il apporte ainsi une structuration utile au déploiement des stratégies d'apprentissage et de transfert.

La résolution du problème directe est coûteuse en raison de la complexité des modèles par éléments finis mais elle est nécessaire pour déployer des stratégies de résolutions inverse et aussi valider les procédures de SHM sur des nombreuses configurations d'endommagement. Ainsi l'approximation du problème direct par des métamodèles s'appuyant sur des données de simulations numérique a été proposée. La complexité de la propagation des ondes de Lamb dans les matériaux composites et de leurs interactions avec les endom-

magement impose cependant des bases de données de tailles importantes. Un panorama des méthodes les plus prometteuses pour la résolution de ce problème permet d'identifier la plus adaptée. Les méthodes à noyau se montrent rapides et précises mais il est nécessaire de définir au préalable des représentations des signaux adaptées. Les méthodes à bases réduites se généralisent mal sur ce type de signaux en raison des non-linéarités de la physique des ondes de Lamb. Les méthodes d'apprentissage profond sont difficiles à entraîner et à paramétrer mais elles se montrent plus précises. L'enrichissement par des connaissances physiques lors de l'apprentissage doit garantir une meilleure généralisation de cette méthode et une plus grande confiance dans ses prédictions.

La résolution inverse exploitant les métamodèles dépend de la précision du métamodèle direct utilisé. Une fonction de coût exploitant les indicateurs d'endommagement permet dans le cas d'une structure poutre de retrouver avec précision les paramètres d'endommagement. Pour les autres structures, les CNNs se montrent bien plus précis et rapides pour la résolution du problème inverse. Ils sont robustes aux bruits et à des erreurs sur le positionnement des capteurs. De plus, le CNN entraîné sur les données de simulation d'une plaque parvient à localiser des délaminages sur les structures expérimentales équivalentes endommagées par des chocs laser. Ils doivent donc être privilégiés pour les stratégies de SHM pilotées par les données.

L'apprentissage est associé à une structure dans des conditions environnementales et opératoires fixes. Tout changement écarte la structure (appelée *structure cible*) de la structure initiale (appelée *structure source*). Le transfert d'un apprentissage d'une structure vers un autre est nécessaire en SHM afin de compenser les biais des modèles, les incertitudes expérimentales et les changements de la structure au cours de sa vie. Les écarts entre deux structures sont quantifiés par des SIs, une grandeur synthétique proposée dans ces travaux qui compare les signaux à l'état sain de deux structures relativement similaires. Lorsque le SI devient trop élevé (comme lors d'un changement de position d'un capteur) l'apprentissage réalisé sur la structure source ne permet pas de caractériser correctement un endommagement sur la structure cible, il est alors nécessaire de faire appel à des méthodes de transfert d'apprentissage. Le transfert d'apprentissage s'appuyant sur la théorie du transport optimale intégrant les potentiels de Monge-Kantorovich à un CNN est une méthode originale et prometteuse pour compenser les effets de ces changements et suivre une population de coupons dans les conditions des avions en exploitation. L'utilisation de la théorie transport optimal donne une justification mathématique forte pour l'utilisation des ICNNs dans ce contexte. L'algorithme proposé dans ses travaux offre une flexibilité d'utilisation importante et il pourra être facilement adapté pour des architectures différentes et pour d'autres bases de données. Le transfert répond alors à un verrou important au déploiement du SHM piloté par les données.

Perspectives

Choc laser et SHM

Intégration Afin d'améliorer l'intégration des deux briques technologiques que forment une plateforme de choc Laser et un système de SHM par ondes de Lamb, il serait intéressant de synchroniser le contrôle avec la génération du choc. Ainsi, il sera possible de suivre le processus d'endommagement en temps réel et automatiquement. Cela pourra être utile lors de la recherche des seuils d'endommagement, pour suivre la création de cale étalon ou bien pour contrôler le désassemblage d'une structure intelligente déjà équipée de capteurs.

Endommagement L'allure en grappe des délaminages induits par choc laser est éloignée des délaminages réels qui prennent la forme d'une surface continue. À l'avenir, des études expérimentales complémentaires doivent être menées pour réduire la distance entre les centres des deux tirs et valider la possibilité d'avoir un délaminage continu par ce procédé.

Stratégies d'apprentissage pour le SHM

Amélioration des bases de données Toute stratégie d'apprentissage dépend évidemment d'une base de données utilisées lors de l'entraînement. Le modèle d'endommagement utilisé dans les simulations de ces travaux est très simplificateur et représente partiellement l'effet d'un vrai dommage. D'autres modèles plus fins introduisant des non-linéarités pourrait être ajoutés à nos modèles et compléter les bases de données existantes. De même, les bases de données utilisées ici ne contiennent que les données d'un unique signal d'excitation, les performances ne pourront que s'améliorer en intégrant des mesures réalisées à d'autres fréquences. En augmentant le nombre de paramètre d'endommagement et le nombre de signaux d'excitation, les bases de données seraient considérablement enrichies mais le coût de calcul de tels plans d'expérience est très élevé et demande des moyens importants.

Amélioration de la représentation des signaux La décomposition en dictionnaire des signaux comme la SVD ou le MP sous sa forme classique représente les signaux sous la forme d'une combinaison linéaire. Cependant une simple translation de paquet d'ondes est une opération très non-linéaire, ces représentations ne sont donc pas adaptées pour les signaux temporels mesurés sur des grandes structures. La recherche d'une autre représentation plus adaptée reste ouverte, la théorie du transport optimal présentée dans le Chapitre 5 pourrait apporter une solution avec les barycentres de Wasserstein.

Réseaux génératifs La recherche d'une représentation idéale des signaux est évitée en laissant l'optimisation du GAN la déterminer automatiquement. Les résultats des l'Info-GAN sont très prometteurs en dépassant les autres méthodes évaluées. Ces réseaux restent difficiles à entraîner et auraient besoin de plus de base de données et de puissance de calcul pour être pleinement valorisés.

Amélioration de la physique L'intégration de modèles physiques analytiques dans les GANs offre la possibilité de faciliter la convergence de l'apprentissage et d'améliorer sa stabilité. La physique des temps de vol ajoutée dans le GAN actuel est très sommaire et n'influence que faiblement la qualité d'apprentissage. En y intégrant des modèles plus complets comme celui des travaux de [59], il devrait être possible de réduire le nombre de données nécessaires à l'apprentissage. Une autre stratégie pour intégrer des connaissances physiques aux GANs peut exister en modifiant les fonctions élémentaires qui le compose : l'ajout de physique ne prend plus uniquement la forme d'une pénalisation lors de l'optimisation, elle est directement intégrée à l'architecture du réseau.

Dépendance aux données d'entrée En utilisant uniquement des données simulées sur une structure, pour un type de dommage et une fréquence d'excitation, les méthodes proposées dans ce chapitre restent dépendantes des données d'entrée. Tout changement structurel ou d'excitation rend leurs prédictions caduques. Il faudrait augmenter considérablement la taille des bases de données et des plans d'expérience afin d'y intégrer plus de paramètres avec un coût de calcul qui deviendrait vite prohibitif. Le Chapitre 5 contourne ce problème en proposant de déployer une méthode de transfert d'apprentissage pour la résolution du problème inverse. Celle-ci n'a pas été déployée dans le cadre de la résolution du problème direct mais la méthode pourrait facilement s'y intégrer en transportant des caractéristiques extraites à des couches intermédiaires du générateur.

Transfert d'apprentissage

Indice Structurel Le SI est un indice pertinent pour déterminer la proximité structurelle entre deux structures. Notre choix du SI est basé sur des connaissances empiriques acquises avec les DIs utilisés dans la détection des dommages. Les travaux futurs se concentreront sur le calcul d'autres SIs pour trouver la meilleure formule et l'appliqueront à d'autres cas pour déterminer un seuil. Un SI idéal devrait être unique pour tout type de structure afin de déterminer à l'avance si une stratégie de transfert est nécessaire ou non avec un nouveau jeu de données.

Correction d'un mauvais modèle d'endommagement Les travaux présentés se concentrent sur la compensation de l'effet des changements structurels ou environnementaux. Cependant, le modèle de dommage utilisé est très simple et reproduit mal l'effet d'un dommage réel. L'approche proposée ici pourrait également être utilisée pour corriger les effets d'une mauvaise modélisation des dommages.

Transfert métamodèle direct Le transfert proposé dans ces travaux n'a été appliqué que sur un CNN chargé de la résolution du problème direct. L'approche proposée peut s'intégrer facilement à d'autres architectures d'apprentissage profond, notamment au GAN exploités pour la résolution du problème direct. Le déploiement du transfert avec le générateur permettrait de construire des métamodèles directs sur des nouvelles structures avec un nombre réduit de données.

Apprentissage hybride L'approche de transfert doit désormais être testée sur la pour capitaliser les connaissances acquises entre un riche jeu de données numériques et un petit jeu de données expérimentales. Le transfert pourrait alors compenser l'effet d'une modélisation approximative de la structure ou de l'endommagement à l'aide de seulement quelques données expérimentales étiquetées. Cette approche ouvre la voie à des modèles d'apprentissage profonds hybrides combinant astucieusement des données numériques avec des données expérimentales.

A

Annexe A : liste des indicateurs d'endommagement

DI name	Comments	Definitions
CC	FFT based implementation of the maximum of the correlation	$1 - \max \left(\frac{IFFT[FFT[x_{ij}(t)]FFT[y_{ij}(t)]^*]}{\sqrt{(E_{x_{ij}} E_{y_{ij}})}} \right)$
CCA	MATLAB based implementation of the maximum of the correlation	$1 - \max(xcorr[x_{ij}(t), y_{ij}(t)])$
CC0	MATLAB based implementation of the zero-lag correlation	$1 - xcorr[x_{ij}(t), y_{ij}(t)](0)$
CRC	MATLAB based implementation of the correlation coefficient	$1 - corrcoeff[x_{ij}(t), y_{ij}(t)]$
NRE	Normalized residual energy	$\frac{\int_T^0 (x_{ij}(t) - y_{ij}(t))^2 dt}{2 \times \int_T^0 x_{ij}(t)^2 dt + \int_T^0 y_{ij}(t)^2 dt}$
NRE2	Normalized residual energy 2	$\frac{\int_T^0 x_{ij}(t)^2 dt - \int_T^0 y_{ij}(t)^2 dt}{\max(\int_T^0 x_{ij}(t)^2 dt, \int_T^0 y_{ij}(t)^2 dt)}$
NRE3	Normalized residual energy 3	$1 - \frac{\min(\int_T^0 x_{ij}(t)^2 dt, \int_T^0 y_{ij}(t)^2 dt)}{\max(\int_T^0 x_{ij}(t)^2 dt, \int_T^0 y_{ij}(t)^2 dt)}$
NRE4	Normalized residual energy 4	$\sqrt{\frac{(\int_T^0 x_{ij}(t)^2 dt \times \int_T^0 y_{ij}(t)^2 dt)}{\max(\int_T^0 x_{ij}(t)^2 dt, \int_T^0 y_{ij}(t)^2 dt)}}$
NRE5	Normalized residual energy 5	$\frac{\int_T^0 (x_{ij}(t)/\max(x_{ij} - y_{ij}(t)/\max(y_{ij}))^2 dt)^2 dt}{2 \times (\int_T^0 [x_{ij}(t)/\max(x_{ij})]^2 \int_T^0 [y_{ij}(t)/\max(y_{ij})]^2 dt)^2 dt}$
NRE6	Normalized residual energy 6	$(1 - NRE4) \frac{\min(\int_T^0 x_{ij}(t)^2, \int_T^0 y_{ij}(t)^2)}{\max(\int_T^0 x_{ij}(t)^2, \int_T^0 y_{ij}(t)^2)}$

TABLE A.1 – Indices d'endommagement implémentés dans SHM@PIMM (1/2)

DI name	Comments	Definitions
MA	Maximum Amplitude of difference	$\max[x_{ij}(t) - y_{ij}(t)]$
MAR	Maximum Amplitude Relative	$\max[x_{ij}(t) - y_{ij}(t)] / \max(x_{ij}(t))$
FFT	FFT ratio of the difference signal over the sum off signals at f_0	$\frac{FFT[x_{ij}(t) - y_{ij}(t)]_{f=f_0}}{FFT[x_{ij}(t) - y_{ij}(t)]_{f=f_0}}$
STFT	Short Time Fourier Transform	$\frac{FFT[x_{ij}(t)W(t)]_{f=f_0}}{FFT[x_{ij}(t)W(t)]_{f=f_0}}$
Env	Energy of the envelope of the difference	$\sqrt{\frac{\sum_{t=T_1}^{T_2} env[y_{ij}(t) - x_{ij}]^2}{\sum_{t=T_1}^{T_2} env[x_{ij}]^2}}$
PHI	Energy of the phase of the difference	$\sqrt{\frac{\sum_{t=T_1}^{T_2} \Phi[y_{ij}(t) - x_{ij}]^2}{\sum_{t=T_1}^{T_2} \Phi[x_{ij}]^2}}$
TDM	Time Delay of Max	$\frac{argmax(\mathcal{H}(y_{ij}) - argmax(\mathcal{H}(x_{ij})))}{argmax(\mathcal{H}(x_{ij}(t)))}$
TD1	Time Delay of the first wave packet	$TD1 = \frac{t_2 - t_1}{t_1}$
SPAR	Signal Amplitude Peak Ratio	$ 1 - \frac{\max(y_{ij}(t))}{\max(x_{ij}(t))} $
SAPS	Signal Amplitude Peak squared percentage differences	$[\frac{\max(y_{ij}(t)) - \max(x_{ij}(t))}{\max(x_{ij}(t))}]^2$
SAHM	Signal Amplitude Hilbert transform Maximum percentage differences	$[\frac{\max((H)(y_{ij}(t))) - \max((H)(x_{ij}(t)))}{\max((H)(y_{ij}(t)))}]^2$
SSSD	Signal Sum of Squared Differences	$\frac{\int 0T(x_{ij}(t) - y_{ij})^2 dt}{\int 0Tx_{ij}(t)^2 dt}$
CCTOF	Cross-correlation- based TOF percentage difference	$ \frac{argmax(xcorr[x_{ij}(t), x_{ij}(t)]) - argmax(xcorr[x_{ij}(t), y_{ij}(t)])}{argmax(xcorr[x_{ij}(t), x_{ij}(t)])} $
WPSD	Welch-based Power Spectral Density	-
WTF	Welch- based transfer function	-
CCMPD	Cross-correlation maximum percentage difference	-
DWTC	Discrete Wavelet Transform approximation coefficient	-

TABLE A.2 – Indices d'endommagement implémentés dans SHM@PIMM (2/2)

B Annexe B : évaluations des prédictions des métamodèles directs

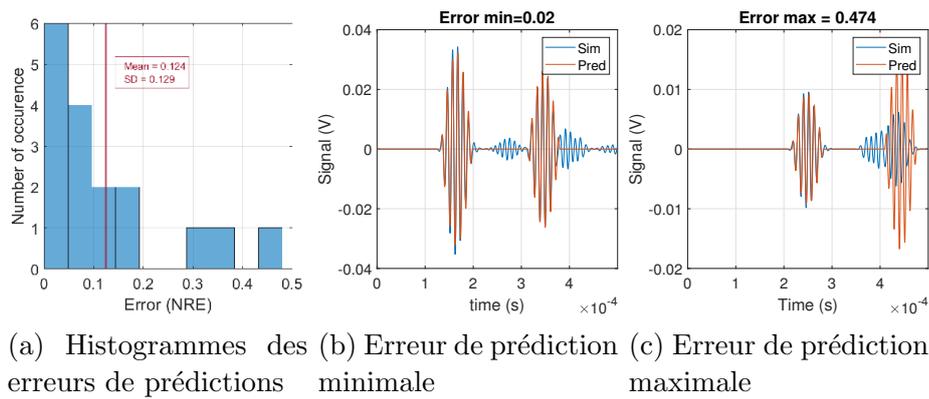


FIGURE B.1 – Évaluation du RBF avec MP sur la structure poutre

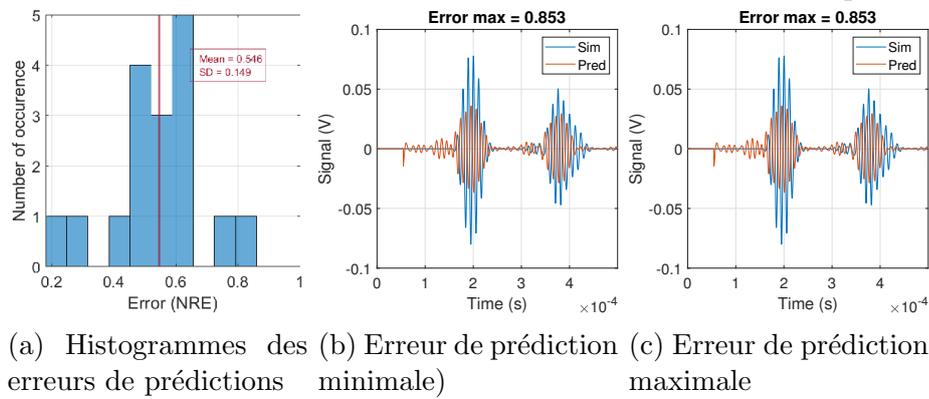


FIGURE B.2 – Évaluation du RBF avec SVD sur la structure poutre

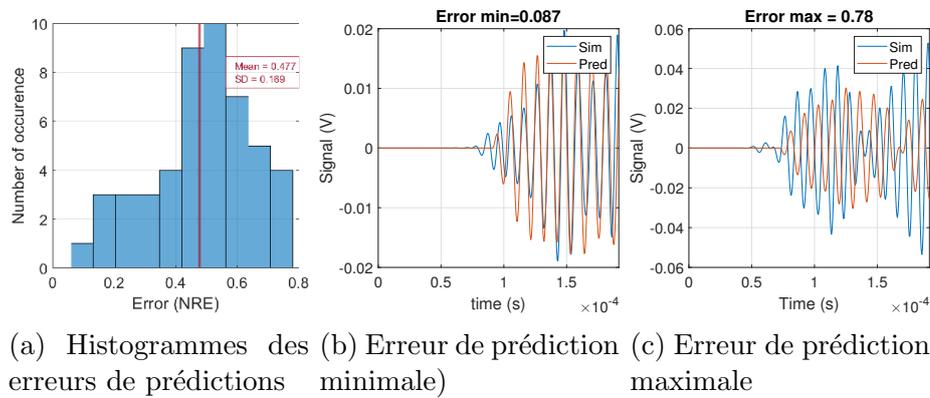


FIGURE B.3 – Évaluation du RBF avec MP sur la structure S2

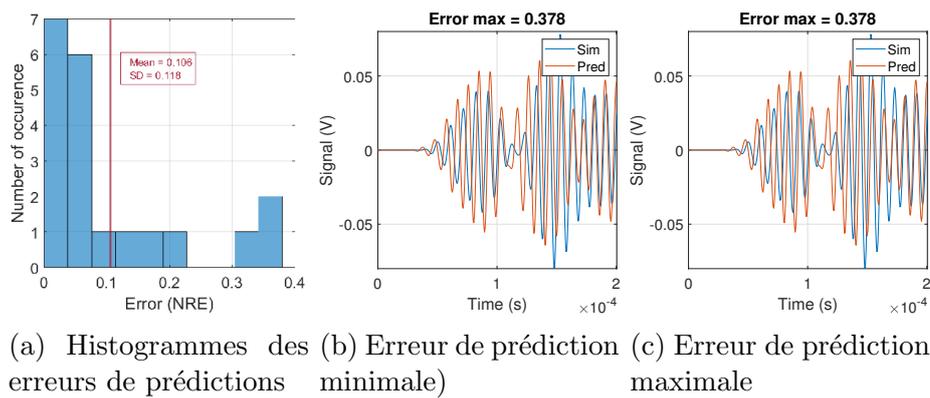


FIGURE B.4 – Évaluation du RBF avec SVD sur la structure S2

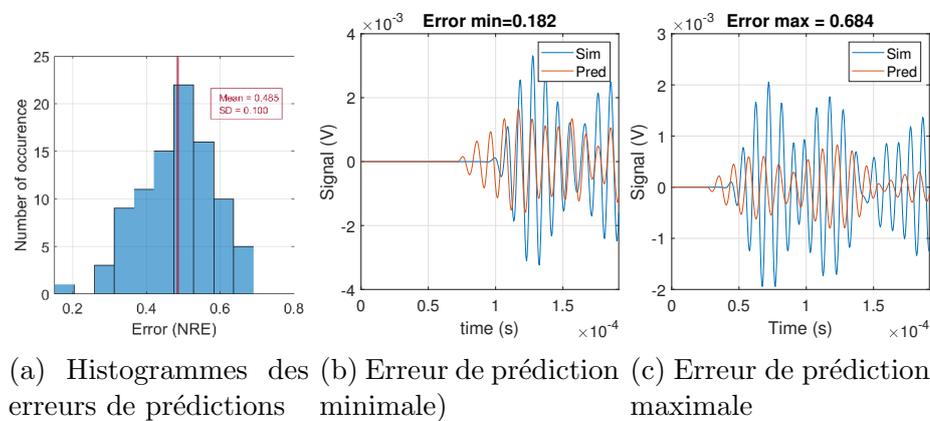


FIGURE B.5 – Évaluation du RBF avec MP sur la structure S11

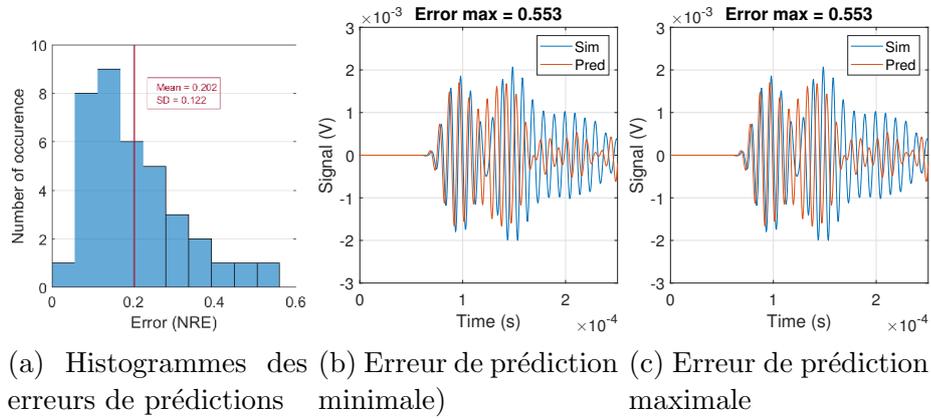


FIGURE B.6 – Évaluation du RBF avec SVD sur la structure S11

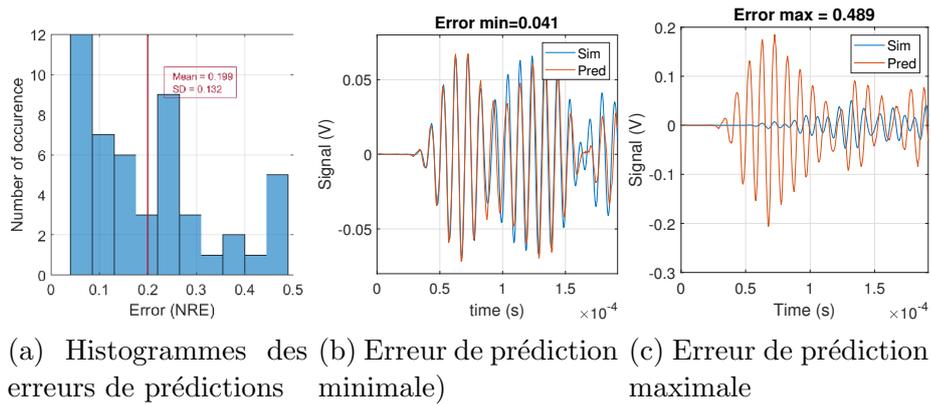


FIGURE B.7 – Évaluation du S-InfoGAN sur la structure S2

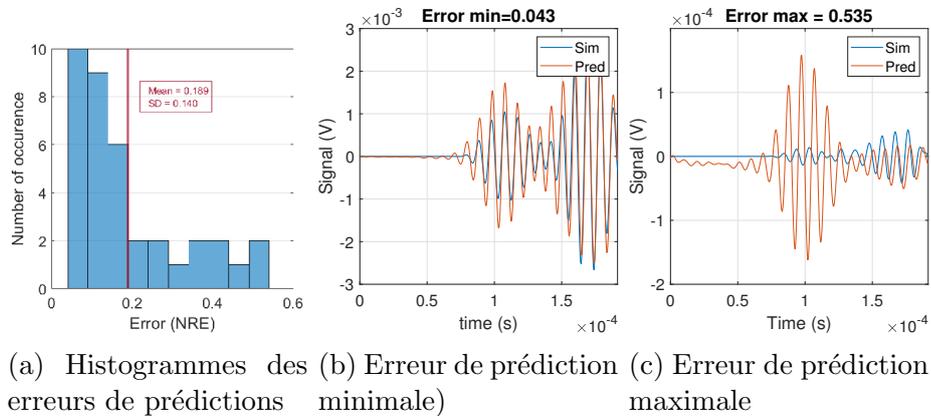


FIGURE B.8 – Évaluation du S-InfoGAN sur la structure S11

C Annexe C : Évaluation des inversions avec des métamodèles

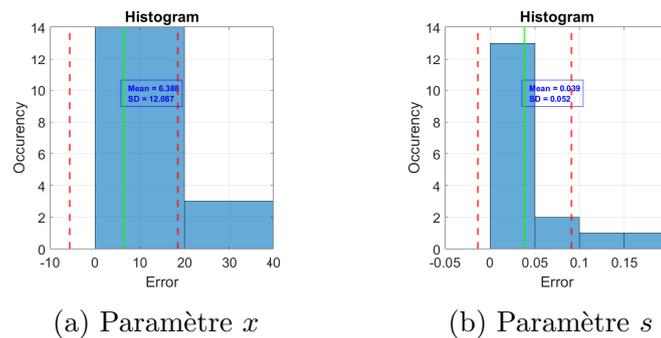


FIGURE C.1 – Histogrammes des erreurs de la résolution inverse sur la Poutre avec RBF et MP

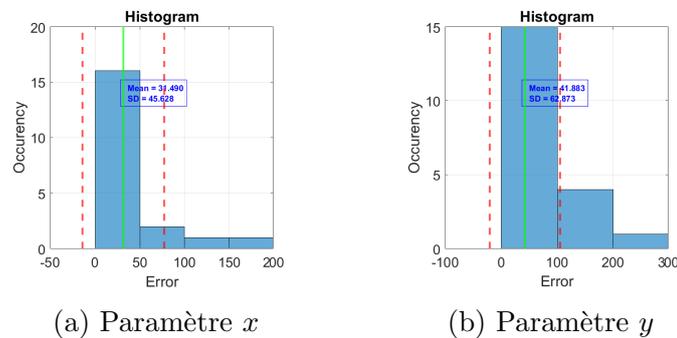


FIGURE C.2 – Histogrammes des erreurs de la résolution inverse sur S2 avec RBF et SVD

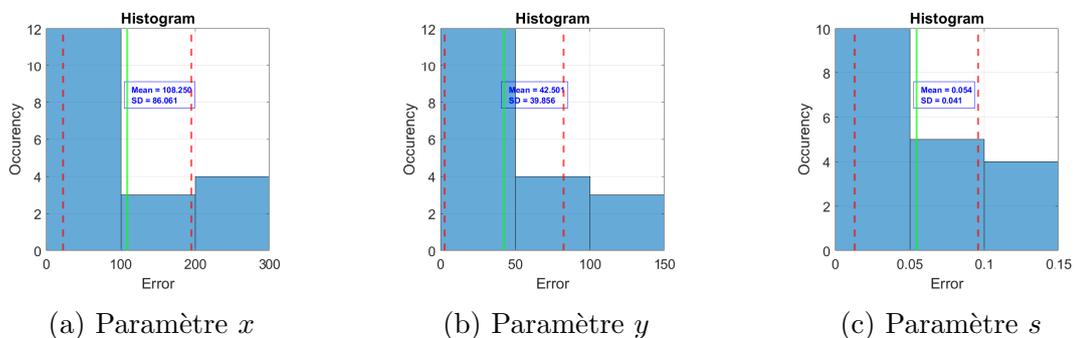
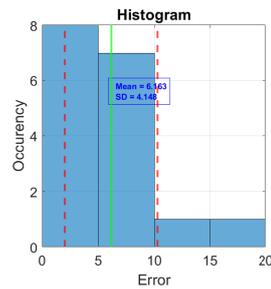
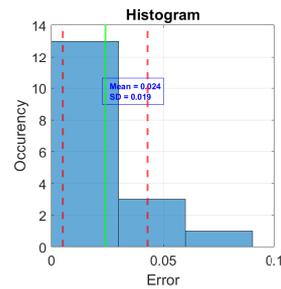


FIGURE C.3 – Histogrammes des erreurs de la résolution inverse sur S11 avec la RBF et SVD

D Annexe D : Évaluation des inversions par des CNNs

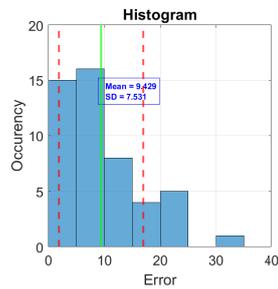


(a) Paramètre x

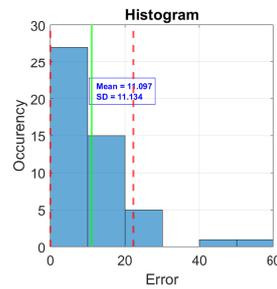


(b) Paramètre s

FIGURE D.1 – Histogrammes des erreurs sur la poutre avec CNN temporel



(a) Paramètre x



(b) Paramètre y

FIGURE D.2 – Histogrammes des erreurs sur S2 avec CNN temporel

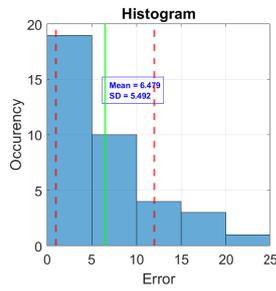
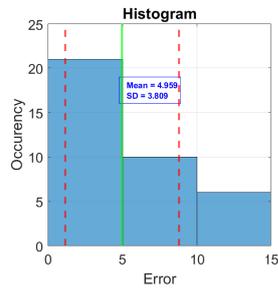
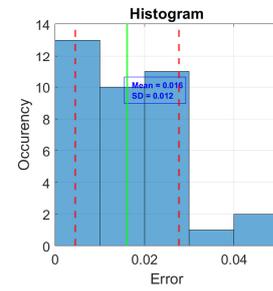
(a) Paramètre x (b) Paramètre y (c) Paramètre s

FIGURE D.3 – Histogramme des erreurs du CNN temporel sur le cas 1

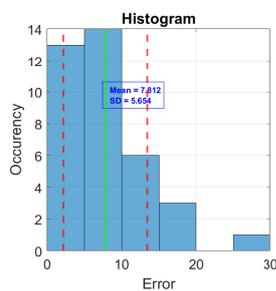
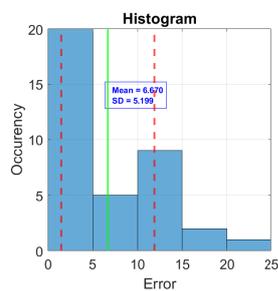
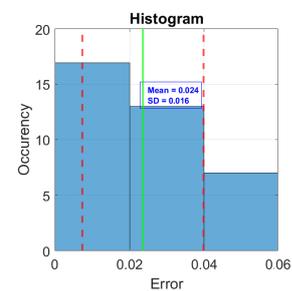
(a) Paramètre x (b) Paramètre y (c) Paramètre s

FIGURE D.4 – Histogrammes des erreurs de la résolution inverse du CNN avec TVDI sur le cas 1

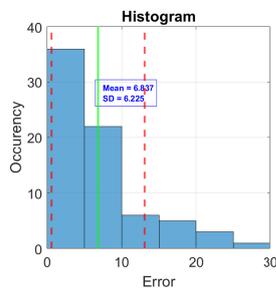
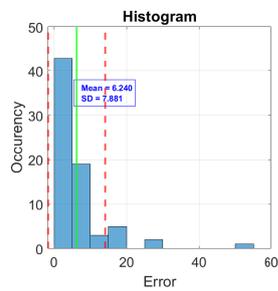
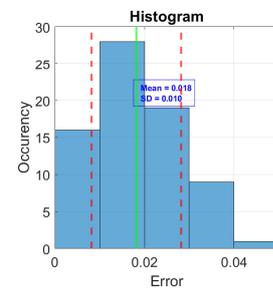
(a) Paramètre x (b) Paramètre y (c) Paramètre s

FIGURE D.5 – Histogrammes des erreurs de la résolution inverse du CNN temporel sur le cas 2

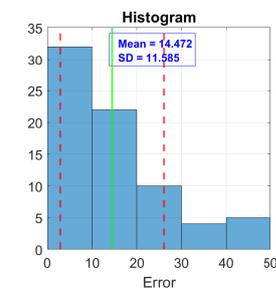
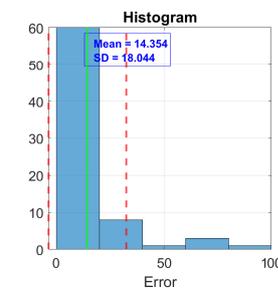
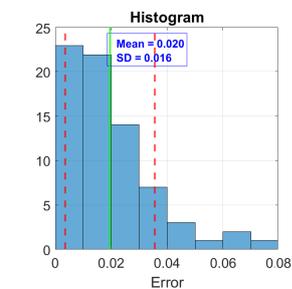
(a) Paramètre x (b) Paramètre y (c) Paramètre s

FIGURE D.6 – Histogrammes des erreurs de la résolution inverse du CNN avec TVDI sur le cas 2

- ANN** Réseau de Neurones Artificiels (*Artificial Neural Network* en anglais). ix, 59, 60, 82, 126, 127
- AT** Contrôle par Émission Acoustique (*Acoustic Emission Testing* en anglais, AT). ix, 12
- BN** Normalisation du lot (*Batch Normalization* en anglais). ix, 67, 77
- CND** Contrôle Non-Destructif (CND). ix, 1, 9, 12, 14, 16, 25, 26, 27, 28, 30, 31, 33, 43, 82, 137
- CNN** Réseau de Neurones Convolutifs (*Convolutional Neural Network* en anglais). ix, 3, 24, 60, 61, 62, 66, 68, 91, 97, 98, 99, 100, 102, 104, 105, 108, 109, 110, 111, 112, 113, 114, 115, 117, 118, 119, 120, 121, 128, 129, 131, 135, 138, 141
- CPD** Décomposition Canonique Polyadique. ix, 24, 65
- DA** Adaptation de Domaine. ix, 120
- DAS** Delay And Sum. ix, 23, 43
- DI** Indicateur d'endommagement. ix, 22, 24, 41, 43, 49, 59, 61, 78, 94, 102, 109, 111, 114, 117, 140
- DYSCO** Dynamique, Structure et Contrôle. ix, 22, 28
- EMI** Impédance Electromécanique. ix
- ET** Contrôle par Courant de Foucault (*Eddy Current Testing* en anglais, ET). ix, 10
- GAN** Réseau Neuronal Adverse Génératif. ix, 62, 66, 70, 72, 73, 88, 119, 126, 129, 140, 141
- GP** Processus Gaussien. ix, 63, 119
- ICNN** Input Convex Neural Network. ix, 111, 126, 127, 128, 129, 138
- InfoGAN** Réseau Neuronal Adverse Génératif maximisant l'information. ix, 62, 70, 72, 87
- JDA** Joint Distribution Adpatation. ix, 118
- JDOT** Joint Distribution Optimal Transport. ix, 121, 123, 128
- KLD** Divergence de Kullback-Leibler. ix

- KRG** Krigeage. ix, 59, 63, 119
- LHS** Latin Hypercube Sampling. ix, 49, 51, 77, 78, 113
- LSTM** Long Short Term Memory network. ix, 61, 118
- MCMC** Monte Carlo Markov Chain. ix, 57, 60, 123
- MMD** Maximum Mean Discrepancy. ix, 118, 119
- MP** Poursuite de Correspondance (*Matching Pursuit* en anglais, MP). ix, 79, 82, 83, 85, 87, 96, 97, 139, 145, 146, 149
- MSE** Erreur Quadratique Moyenne. ix, 73, 128, 136
- OT** Transport Optimal. ix
- PCA** Analyse en Composante Principale. ix
- PFA** Probabilités de Fausse Alarme. ix
- PGD** Proper Generalized Decomposition. ix, 60, 62, 65, 77, 85, 86, 87
- PIMM** laboratoire Procédé et Ingénierie en Mécanique et Matériaux. ix, 20, 22, 28, 102
- PoD** Probabilité de Detection (*Probability of Detection* en anglais). ix, 26, 59
- POD** Proper Orthogonal Decomposition. ix, 60, 65
- PoL** Probabilité de Localisation (*Probability of Localisation* en anglais). ix, 26
- PoS** Probabilité de Quantification (*Probability of Sizing* en anglais). ix, 26
- PT** Contrôle par Ressuage (*Penetrant Testing* en anglais, RT). ix, 12
- PZT** Transducteur en Titano-Zirconate de Plomb (PZT). ix, 1, 16, 17, 20, 21, 24, 26, 27, 34, 36, 38, 39, 40, 43, 46, 47, 48, 49, 50, 51, 52, 53, 59, 60, 61, 73, 74, 79, 91, 98, 99, 108, 113, 137
- RAPID** Algorithme de Reconstruction pour l'Inspection Probabiliste de Dommage. ix, 24
- RBF** Interpolation par Fonction de Base Radiale. ix, 62, 63, 64, 65, 66, 81, 84, 85, 87, 96, 97, 149
- ResNet** Residual Neural Network. ix, 61
- RT** Contrôle par Radiographie (*Radiographie Testing* en anglais, RT). ix, 12
- SHM** Contrôle de la Santé des Structures (*Structural Health Monitoring* en anglais). ix, 1, 2, 5, 10, 14, 15, 16, 17, 18, 20, 22, 24, 25, 26, 27, 28, 30, 31, 32, 33, 34, 35, 36, 37, 41, 43, 45, 46, 47, 53, 56, 58, 59, 60, 61, 62, 63, 74, 78, 82, 88, 89, 92, 94, 102, 108, 109, 110, 112, 113, 114, 117, 119, 120, 121, 135, 137, 138, 139

- SI** Indice Structurel. ix, 111, 114, 115, 131, 135, 138, 140
- SNR** Rapport Signal sur Bruit (*Signal to Noise Ratio* en anglais, SNR). ix, 99
- ST** Contrôle par Shearographie (*Shearographie Testing* en anglais, ST). ix, 12
- SVD** Décomposition en valeur singulière. ix, 65, 79, 80, 81, 85, 86, 87, 96, 97, 139, 149
- SVM** Machine à Vecteur de Support (*Support Vector Machine* en anglais, SVM). ix, 59, 61, 63, 82
- TCA** Transfer Component Analysis. ix, 119
- TDOA** Time Difference Of Arrival. ix, 23, 43
- TOA** Time Of Arrival. ix, 23, 43
- TOF** Temps de Vol. ix, 22, 23, 78
- TT** Contrôle par Thermographie (*Thermography Testing* en anglais, TT). ix, 12
- TVDI** Indicateur d'endommagement Variant Temporellement. ix, 61, 100, 105, 108, 109, 110
- UT** Contrôle par Ultra-Son (*Ultra-sound Testing* en anglais, UT). ix, 10, 12, 16, 37, 41, 43, 82, 137
- VT** Inspection Visuelle, *Visual Tracking* en anglais (VT). ix, 10, 12
- WGAN** Réseau Neuronal Adverse Génératif de Wasserstein. ix, 70
- XAI** Intelligence Artificielle Explicable. ix, 61

Bibliographie

- [1] V. Giurgiutiu. Structural health monitoring of aerospace composites. Elsevier, Amsterdam, 2016. ISBN 978-0-12-409605-9.
- [2] L. Gornet. Généralités sur les matériaux composites. September 2008, URL <https://cel.archives-ouvertes.fr/cel-00470296>.
- [3] M. R. Wisnom. The role of delamination in failure of fibre-reinforced composites. Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences, 370(1965) :1850–1870, April 2012. doi:10.1098/rsta.2011.0441. Publisher : Royal Society.
- [4] Wronkowicz-Katunin, Katunin, and Dragan. Reconstruction of Barely Visible Impact Damage in Composite Structures Based on Non-Destructive Evaluation Results. Sensors, 19(21) :4629, October 2019. ISSN 1424-8220. doi:10.3390/s19214629.
- [5] K. S. Tan, N. Guo, B. S. Wong, and C. G. Tui. Comparison of Lamb waves and pulse echo in detection of near-surface defects in laminate plates. NDT & E International, 28(4) :215–223, August 1995. ISSN 0963-8695. doi:10.1016/0963-8695(95)00023-Q.
- [6] C. Guo, C. Xu, J. Hao, D. Xiao, and W. Yang. Ultrasonic Non-Destructive Testing System of Semi-Enclosed Workpiece with Dual-Robot Testing System. Sensors, 19(15) :3359, July 2019. ISSN 1424-8220. doi:10.3390/s19153359.
- [7] F. Khodayar, S. Sojasi, and X. Maldague. Infrared thermography and NDT : 2050 horizon. Quantitative InfraRed Thermography Journal, 13(2) :210–231, July 2016. ISSN 1768-6733. doi:10.1080/17686733.2016.1200265. Publisher : Taylor & Francis _eprint : <https://doi.org/10.1080/17686733.2016.1200265>.
- [8] M. GHRIB. Structural Health Monitoring of composite structures : LASER shock delamination generation and machine learning-based quantification. phdthesis, Ecole nationale supérieure d’arts et métiers - ENSAM, December 2017, URL <https://pastel.archives-ouvertes.fr/tel-01881284>.
- [9] W. Cao, H. H. Cudney, and R. Waser. Smart materials and structures. Proceedings of the National Academy of Sciences, 96(15) :8330–8331, 1999. ISSN 0027-8424, 1091-6490. doi:10.1073/pnas.96.15.8330.

- [10] W. Ostachowicz, R. Soman, and P. Malinowski. Optimization of sensor placement for structural health monitoring : a review. Structural Health Monitoring, 18(3) :963–988, May 2019. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921719825601. Number : 3.
- [11] R. Wang, Chencho, S. An, J. Li, L. Li, et al. Deep residual network framework for structural health monitoring. Structural Health Monitoring, 20(4) :1443–1461, July 2021. ISSN 1475-9217. doi:10.1177/1475921720918378. Publisher : SAGE Publications.
- [12] P. Gardner, L. Bull, J. Gosliga, N. Dervilis, and K. Worden. Foundations of population-based SHM, Part III : Heterogeneous populations – Mapping and transfer. Mechanical Systems and Signal Processing, 149 :107142, February 2021. ISSN 08883270. doi:10.1016/j.ymsp.2020.107142.
- [13] S. Qin, Y. Zhang, Y.-L. Zhou, and J. Kang. Dynamic Model Updating for Bridge Structures Using the Kriging Model and PSO Algorithm Ensemble with Higher Vibration Modes. Sensors, 18(6) :1879, June 2018. ISSN 1424-8220. doi:10.3390/s18061879. Number : 6 Publisher : Multidisciplinary Digital Publishing Institute.
- [14] K. Worden, E. J. Cross, and J. M. W. Brownjohn. Switching Response Surface Models for Structural Health Monitoring of Bridges. In S. Koziel and L. Leifsson, editors, Surrogate-Based Modeling and Optimization, pages 337–358. Springer New York, New York, NY, 2013. ISBN 978-1-4614-7550-7 978-1-4614-7551-4. doi:10.1007/978-1-4614-7551-4_14.
- [15] Y. Yuan, F. T. K. Au, D. Yang, and J. Zhang. Active learning structural model updating of a multisensory system based on Kriging method and Bayesian inference. Computer-Aided Civil and Infrastructure Engineering, n/a (n/a). ISSN 1467-8667. doi:10.1111/mice.12822. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1111/mice.12822>.
- [16] C.-C. Comisu, N. Taranu, G. Boaca, and M.-C. Scutaru. Structural health monitoring system of bridges. Procedia Engineering, 199 :2054–2059, January 2017. ISSN 1877-7058. doi:10.1016/j.proeng.2017.09.472.
- [17] S. Bas, N. M. Apaydin, A. Ilki, and F. N. Catbas. Structural health monitoring system-SHMs of the long span bridges in Turkey. In Maintenance, Monitoring, Safety, Risk and Resilience of Bridges and Bridge Networks. CRC Press, 2016. ISBN 978-1-315-20768-1. Num Pages : 1.

- [18] H. Sarmadi and K.-V. Yuen. Structural health monitoring by a novel probabilistic machine learning method based on extreme value theory and mixture quantile modeling. Mechanical Systems and Signal Processing, 173 :109049, July 2022. ISSN 0888-3270. doi:10.1016/j.ymsp.2022.109049.
- [19] S. M. H. Pooya and A. Massumi. A novel damage detection method in beam-like structures based on the relation between modal kinetic energy and modal strain energy and using only damaged structure data. Journal of Sound and Vibration, 530 :116943, July 2022. ISSN 0022460X. doi:10.1016/j.jsv.2022.116943.
- [20] Y. Li, T. Bao, Z. Gao, X. Shu, K. Zhang, et al. A new dam structural response estimation paradigm powered by deep learning and transfer learning techniques. Structural Health Monitoring, page 147592172110097, May 2021. ISSN 1475-9217, 1741-3168. doi:10.1177/14759217211009780.
- [21] S. Wang, C. Xu, Y. Liu, and B. Wu. A spatial association-coupled double objective support vector machine prediction model for diagnosing the deformation behaviour of high arch dams. Structural Health Monitoring, 21(3) :945–964, May 2022. ISSN 1475-9217. doi:10.1177/14759217211017030. Publisher : SAGE Publications.
- [22] S.-X. Chen, L. Zhou, Y.-Q. Ni, and X.-Z. Liu. An acoustic-homologous transfer learning approach for acoustic emission-based rail condition evaluation. Structural Health Monitoring, 20(4) :2161–2181, July 2021. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921720976941.
- [23] D. A. Ramatlo, C. S. Long, P. W. Loveday, and D. N. Wilke. Physics-based modeling and simulation of reverberating reflections in ultrasonic guided wave inspections applied to welded rail tracks. Journal of Sound and Vibration, 530 :116914, July 2022. ISSN 0022-460X. doi:10.1016/j.jsv.2022.116914.
- [24] J. Gosliga, P. Gardner, L. Bull, N. Dervilis, and K. Worden. Foundations of Population-based SHM, Part II : Heterogeneous populations – Graphs, networks, and communities. Mechanical Systems and Signal Processing, 148 :107144, February 2021. ISSN 08883270. doi:10.1016/j.ymsp.2020.107144.
- [25] T. Khuc and F. N. Catbas. Completely contactless structural health monitoring of real-life structures using cameras and computer vision. Structural Control and Health Monitoring, 24(1) :e1852, 2017. ISSN 1545-2263. doi:10.1002/stc.1852. eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/stc.1852>.
- [26] D. Goutaudier, D. Gendre, V. Kehr-Candille, and R. Ohayon. Long-range impact localization with a frequency domain triangulation technique : Application to a large

- aircraft composite panel. Composite Structures, 238 :111973, April 2020. ISSN 0263-8223. doi:10.1016/j.compstruct.2020.111973.
- [27] M. Ho, S. El-Borgi, D. Patil, and G. Song. Inspection and monitoring systems subsea pipelines : A review paper. Structural Health Monitoring, 19(2) :606–645, March 2020. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921719837718.
- [28] T. Druet. Tomographie passive par ondes guidées pour des applications de contrôle santé intégré. page 199.
- [29] T. Druet, B. Chapuis, M. Jules, G. Laffont, and E. Moulin. Passive SHM System for Corrosion Detection by Guided Wave Tomography. In B. Chapuis and E. Sjerve, editors, Sensors, Algorithms and Applications for Structural Health Monitoring, pages 21–29. Springer International Publishing, Cham, 2018. ISBN 978-3-319-69232-6 978-3-319-69233-3. doi:10.1007/978-3-319-69233-3_3. Series Title : IIW Collection.
- [30] M. B. Rao, M. R. Bhat, C. R. L. Murthy, K. V. Madhav, and S. Asokan. Structural Health Monitoring (SHM) Using Strain Gauges, PVDF Film and Fiber Bragg Grating (FBG) Sensors : A Comparative Study, 2006.
- [31] K. Loupos and A. Amditis. Structural Health Monitoring Fiber Optic Sensors. In I. R. Matias, S. Ikezawa, and J. Corres, editors, Fiber Optic Sensors : Current Status and Future Possibilities, Smart Sensors, Measurement and Instrumentation, pages 185–206. Springer International Publishing, Cham, 2017. ISBN 978-3-319-42625-9. doi:10.1007/978-3-319-42625-9_9.
- [32] P. Cawley and R. D. Adams. The location of defects in structures from measurements of natural frequencies. The Journal of Strain Analysis for Engineering Design, 14(2) :49–57, April 1979. ISSN 0309-3247. doi:10.1243/03093247V142049. Publisher : IMECHE.
- [33] B. Pavlack, J. Paixão, S. da Silva, A. Cunha, and D. García Cava. Polynomial Chaos-Kriging metamodel for quantification of the debonding area in large wind turbine blades. Structural Health Monitoring, 21(2) :666–682, March 2022. ISSN 1475-9217. doi:10.1177/14759217211007956. Publisher : SAGE Publications.
- [34] M. Awadallah and A. El-Sinawi. Effect and detection of cracks on small wind turbine blade vibration using special Kriging analysis of spectral shifts. Measurement, 151 : 107076, February 2020. ISSN 02632241. doi:10.1016/j.measurement.2019.107076.
- [35] D. Goutaudier, D. Gendre, V. Kehr-Candille, and R. Ohayon. Single-sensor approach for impact localization and force reconstruction by using discriminating vibra-

- tion modes. Mechanical Systems and Signal Processing, 138 :106534, 2020. Publisher : Elsevier.
- [36] W.-J. Yan, D. Chronopoulos, S. Cantero-Chinchilla, K.-V. Yuen, and C. Papadimitriou. A fast Bayesian inference scheme for identification of local structural properties of layered composites based on wave and finite element-assisted metamodeling strategy and ultrasound measurements. Mechanical Systems and Signal Processing, 143 : 106802, September 2020. ISSN 08883270. doi:10.1016/j.ymssp.2020.106802.
- [37] D. C. Betz, G. Thursby, B. Culshaw, and W. J. Staszewski. Structural Damage Location with Fiber Bragg Grating Rosettes and Lamb Waves. Structural Health Monitoring, 6(4) :299–308, December 2007. ISSN 1475-9217. doi:10.1177/1475921707081974. Publisher : SAGE Publications.
- [38] M. de Oliveira, A. Monteiro, and J. Vieira Filho. A New Structural Health Monitoring Strategy Based on PZT Sensors and Convolutional Neural Network. Sensors, 18 (9) :2955, September 2018. ISSN 1424-8220. doi:10.3390/s18092955.
- [39] D. R. Gonçalves, J. d. R. V. d. Moura Jr., P. E. C. Pereira, M. V. A. Mendes, and H. S. Diniz-Pinto. Indicator kriging for damage position prediction by the use of electromechanical impedance-based structural health monitoring. Comptes Rendus. Mécanique, 349(2) :225–240, April 2021. ISSN 1873-7234. doi:10.5802/crmeca.81.
- [40] E. Lizé. Détection d’endommagement sans état de référence et estimation de la température pour le contrôle santé intégré de structures composites par ondes guidées. phdthesis, Paris, ENSAM, December 2018, URL <https://www.theses.fr/2018ENAM0058>.
- [41] A. Rytter. Vibrational Based Inspection of Civil Engineering Structures. PhD Thesis, Dept. of Building Technology and Structural Engineering, Aalborg University, Denmark, 1993. Issue : 44 Series : Fracture and Dynamics.
- [42] H. Lamb. On waves in an elastic plate. Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character, 93(648) : 114–128, March 1917. ISSN 0950-1207, 2053-9150. doi:10.1098/rspa.1917.0008.
- [43] M. Rucka. Guided wave propagation in structures. Modelling, experimental studies and application to damage detection, 2011, URL <https://mostwiedzy.pl/pl/publication/guided-wave-propagation-in-structures-modelling-experimental-studies-and-application> 115815-1. Pages : 1-182 Publisher : Politechnika Gdańska.

- [44] X. Li. Propagation des ondes de Lamb dans des structures composites en présence de délaminage générés par LASER : simulation et expérimentations. phdthesis, HESAM Université, December 2021, URL <https://pastel.archives-ouvertes.fr/tel-03688066>.
- [45] C. FENDZI. Structural Health Monitoring of Composite Structures : application to the Monitoring of Aeronautical Nacelles. phdthesis, Ecole nationale supérieure d'arts et métiers - ENSAM, December 2015, URL <https://pastel.archives-ouvertes.fr/tel-01264825>.
- [46] F. Lambinet and Z. Sharif Khodaei. Measurement platform for structural health monitoring application of large scale structures. Measurement, 190 :110675, February 2022. ISSN 0263-2241. doi:10.1016/j.measurement.2021.110675.
- [47] A. Kulakovskiy. Développement d'un système SHM pour aéronef par ondes élastiques guidées. PhD thesis, 2019, URL <http://www.theses.fr/2019SACLX021/document>.
- [48] V. Memmolo, L. Maio, N. D. Boffa, E. Monaco, and F. Ricci. Damage detection tomography based on guided waves in composite structures using a distributed sensor network. Optical Engineering, 55(1) :011007, October 2015. ISSN 0091-3286. doi:10.1117/1.OE.55.1.011007.
- [49] X. Zhao, H. Gao, G. Zhang, B. Ayhan, F. Yan, et al. Active health monitoring of an aircraft wing with embedded piezoelectric sensor/actuator network : I. Defect detection, localization and growth monitoring. Smart Materials and Structures, 16(4) : 1208–1217, June 2007. ISSN 0964-1726. doi:10.1088/0964-1726/16/4/032. Publisher : IOP Publishing.
- [50] P. K. Motamed, A. Abedian, and M. Nasiri. Optimal sensors layout design based on reference-free damage localization with lamb wave propagation. Structural Control and Health Monitoring, 27(4), April 2020. ISSN 1545-2255, 1545-2263. doi:10.1002/stc.2490.
- [51] S. Wang, W. Wu, Y. Shen, Y. Liu, and S. Jiang. Influence of the PZT Sensor Array Configuration on Lamb Wave Tomography Imaging with the RAPID Algorithm for Hole and Crack Detection. Sensors, 20(3) :860, January 2020. ISSN 1424-8220. doi:10.3390/s20030860. Number : 3 Publisher : Multidisciplinary Digital Publishing Institute.
- [52] C. FENDZI, J. Morel, M. REBILLAT, M. GUSKOV, N. MECHBAL, et al. Optimal Sensors Placement to Enhance Damage Detection in Composite Plates. In 7th

- European Workshop on Structural Health Monitoring, pages 1–8, France, July 2014. URL <https://hal.archives-ouvertes.fr/hal-01001844>.
- [53] E. Flynn and M. Todd. Optimal Placement of Piezoelectric Actuators and Sensors for Detecting Damage in Plate Structures. Journal of Intelligent Material Systems and Structures - J INTEL MAT SYST STRUCT, 21 :265–274, 2010. doi:10.1177/1045389X09338080.
- [54] R. Soman and P. Malinowski. A Real-Valued Genetic Algorithm for Optimization of Sensor Placement for Guided Wave-Based Structural Health Monitoring. Journal of Sensors, 2019 :1–10, December 2019. ISSN 1687-725X, 1687-7268. doi:10.1155/2019/9614630.
- [55] S. Venkat, C. Boller, N. Ravi, N. Chakraborty, G. Kamalakar, et al. Optimized Actuator/Sensor Combinations for Structural Health Monitoring : Simulation and Experimental Validation. In Structural Health Monitoring 2015. Destech Publications, 2015. doi:10.12783/SHM2015/128.
- [56] S. Cantero-Chinchilla, J. L. Beck, M. Chiachío, J. Chiachío, D. Chronopoulos, et al. Optimal sensor and actuator placement for structural health monitoring via an efficient convex cost-benefit optimization. Mechanical Systems and Signal Processing, 144 : 106901, 2020. ISSN 0888-3270. doi:<https://doi.org/10.1016/j.ymssp.2020.106901>.
- [57] K. S. Alguri, C. C. Chia, and J. B. Harley. Sim-to-Real : Employing ultrasonic guided wave digital surrogates and transfer learning for damage visualization. Ultrasonics, 111 :106338, March 2021. ISSN 0041-624X. doi:10.1016/j.ultras.2020.106338.
- [58] L. Chehami, E. Moulin, J. De Rosny, C. Prada, O. Bou Matar, et al. Detection and localization of a defect in a reverberant plate using acoustic field correlation. Journal of Applied Physics, 115 :104901–1–7, 2014. doi:10.1063/1.4867522. Publisher : American Institute of Physics.
- [59] W. Briand. Lamb waves based active sparse tomography for damage size quantification in composite structures : data-driven and parameter inversion methods Tomographie active répartie par ondes de Lamb pour la quantification de taille de dommage dans les structures composites : méthodes basées sur les données et par identification de paramètres. These de doctorat, Paris, HESAM, March 2022, URL <https://www.theses.fr/2022HESAE027>.
- [60] N. Quaegebeur, P. Masson, D. Langlois-Demers, and P. Micheau. Dispersion-based imaging for structural health monitoring using sparse and compact arrays. Smart

- Materials and Structures, 20(2) :025005, February 2011. ISSN 0964-1726, 1361-665X. doi:10.1088/0964-1726/20/2/025005.
- [61] J. E. Michaels. Effectiveness of in situ damage localization methods using sparse ultrasonic sensor arrays. 6935 :693510, March 2008. doi:10.1117/12.775788. Conference Name : Health Monitoring of Structural and Biological Systems 2008 ADS Bibcode : 2008SPIE.6935E..10M.
- [62] M. Rébillat and N. Mechbal. Damage localization in composite plates using canonical polyadic decomposition of Lamb wave difference signals tensor. IFAC-PapersOnLine, 51(24) :668 – 673, 2018. ISSN 2405-8963. doi:https://doi.org/10.1016/j.ifacol.2018.09.647. Number : 24.
- [63] M. Rebillat and N. Mechbal. Dimension Reduction Algorithms in the Damage Indexes Space for Damage Size Quantification in Aeronautic Composite Structures. In Structural Health Monitoring 2019, volume 0, 2019. doi:10.12783/shm2019/32279. Number : 0.
- [64] W. Briand, M. REBILLAT, M. GUSKOV, and N. MECHBAL. Damage size quantification in aeronautic composite structures based on imaging results post-processing. In IX ECCOMAS Thematic Conference on Smart Structures and Materials, pages 1–12, Paris, France, July 2019. A. Benjeddou, N. Mechbal and J.F. Deu, URL <https://hal.archives-ouvertes.fr/hal-03012957>.
- [65] P. Cawley. Structural health monitoring : Closing the gap between research and industrial deployment. Structural Health Monitoring, 17(5) :1225–1244, September 2018. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921717750047. Number : 5.
- [66] J. Hua, F. Gao, L. Zeng, and J. Lin. Modified sparse reconstruction imaging of lamb waves for damage quantitative evaluation. NDT & E International, 107 :102143, October 2019. ISSN 09638695. doi:10.1016/j.ndteint.2019.102143.
- [67] J. Moriot, N. Quaegebeur, A. Le Duff, and P. Masson. A model-based approach for statistical assessment of detection and localization performance of guided wave-based imaging techniques. Structural Health Monitoring, 17(6) :1460–1472, November 2018. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921717744679. Number : 6.
- [68] A. De Fenza, A. Sorrentino, and P. Vitiello. Application of Artificial Neural Networks and Probability Ellipse methods for damage detection using Lamb waves. Composite Structures, 133 :390–403, December 2015. ISSN 0263-8223. doi:10.1016/j.compstruct.2015.07.089.

- [69] Z. Zhang, J. Pan, W. Luo, K. R. Ramakrishnan, and H. K. Singh. Vibration-based delamination detection in curved composite plates. Composites Part A : Applied Science and Manufacturing, 119 :261–274, April 2019. ISSN 1359835X. doi:10.1016/j.compositesa.2019.02.002.
- [70] H. Luo and S. Hanagud. Delamination detection using dynamic characteristics of composite plates. In 36th Structures, Structural Dynamics and Materials Conference, New Orleans, LA, U.S.A., April 1995. American Institute of Aeronautics and Astronautics. doi:10.2514/6.1995-1172.
- [71] Mohammad Salmanpour, Zahra Sharif Khodaei, and M. Aliabadi. Impact Damage Localisation with Piezoelectric Sensors under Operational and Environmental Conditions. Sensors, 17(5) :1178, May 2017. ISSN 1424-8220. doi:10.3390/s17051178. Number : 5.
- [72] R. James, V. Giurgiutiu, and M. Flores. Challenges of generating controlled one-inch impact damage in thick CFRP composites. In AIAA Scitech 2020 Forum, Orlando, FL, January 2020. American Institute of Aeronautics and Astronautics. ISBN 978-1-62410-595-1. doi:10.2514/6.2020-0723.
- [73] C. M. Schubert Kabban, B. M. Greenwell, M. P. DeSimio, and M. M. Derriso. The probability of detection for structural health monitoring systems : Repeated measures data. Structural Health Monitoring : An International Journal, 14(3) :252–264, May 2015. ISSN 1475-9217, 1741-3168. doi:10.1177/1475921714566530. Number : 3.
- [74] F. Falcatelli, N. Yue, R. Di Sante, and D. Zarouchas. Probability of detection, localization, and sizing : The evolution of reliability metrics in Structural Health Monitoring. Structural Health Monitoring, page 14759217211060780, December 2021. ISSN 1475-9217. doi:10.1177/14759217211060780.
- [75] R. Gorgin, Y. Luo, and Z. Wu. Environmental and operational conditions effects on Lamb wave based structural health monitoring systems : A review. Ultrasonics, 105 : 106114, July 2020. ISSN 0041624X. doi:10.1016/j.ultras.2020.106114.
- [76] R. ECAULT. Experimental and numerical investigations on the dynamic behaviour of aeronautic composites under laser shock - Optimization of a shock wave adhesion test for bonded composites. Theses, ISAE-ENSMA Ecole Nationale Supérieure de Mécanique et d'Aérotechnique - Poitiers, December 2013, URL <https://tel.archives-ouvertes.fr/tel-01242721>. Issue : 2013ESMA0031.

- [77] M. Sagnard. Detection of Weak Bonds in Bond ed CFRP Assemblies using Symmetrical LAsER Shock Adhesion Test (S-LASAT). These de doctorat, Paris, ENSAM, May 2019, URL <https://www.theses.fr/2019ENAM0022>.
- [78] D. Balageas, C.-P. Fritzen, and A. Güemes, editors. Structural health monitoring. ISTE, London ; Newport Beach, CA, 2006. ISBN 978-1-905209-01-9. OCLC : ocm62493224.
- [79] B. Poddar and V. Giurgiutiu. Fast and accurate analytical model to solve inverse problem in SHM using Lamb wave propagation. In Nondestructive Characterization and Monitoring of Advanced Materials, Aerospace, and Civil Infrastructure 2016, volume 9804, pages 283–302. SPIE, April 2016. doi:10.1117/12.2218143.
- [80] J. Mckeon and M. Hinders. LAMB WAVE SCATTERING FROM A THROUGH HOLE. Journal of Sound and Vibration, 224(5) :843–862, July 1999. ISSN 0022460X. doi:10.1006/jsvi.1999.2164. Number : 5.
- [81] J. Hadamard. Sur les problèmes aux dérivés partielles et leur signification physique. Princeton University Bulletin, 13 :49–52, 1902.
- [82] S. Guo, M. Rebillat, and N. Mechbal. Dichotomy property of dispersion equation of guided waves propagating in anisotropic composite plates. Mechanical Systems and Signal Processing, 164 :108212, February 2022. ISSN 08883270. doi:10.1016/j.ymssp.2021.108212.
- [83] A. Paolozzi and I. Peroni. Detection of Debonding Damage in a Composite Plate through Natural Frequency Variations. Journal of Reinforced Plastics and Composites, 9(4) :369–389, July 1990. ISSN 0731-6844, 1530-7964. doi:10.1177/073168449000900405. Number : 4.
- [84] W. K. Hastings. Monte Carlo sampling methods using Markov chains and their applications. page 13.
- [85] A. Iwasaki, A. Todoroki, S. Izumi, and S. Sakai. Diagnostic Method for Delamination Monitoring of CFRP Plate Using Kriging Interpolation Method. Key Engineering Materials, 353-358 :1422–1426, 2007. ISSN 1662-9795. doi:10.4028/www.scientific.net/KEM.353-358.1422. Conference Name : Progresses in Fracture and Strength of Materials and Structures ISBN : 9780878494569 Publisher : Trans Tech Publications Ltd.
- [86] E. J. Joy, A. S. Menon, and N. Biju. Implementation of Kriging Surrogate Models for Delamination Detection in Composite Structures. Advanced Composites

- Letters, 27(6) :096369351802700, November 2018. ISSN 0963-6935, 0963-6935. doi:10.1177/096369351802700604. Number : 6.
- [87] A. T. Eshghi, S. Lee, H. Jung, and P. Wang. Design of structural monitoring sensor network using surrogate modeling of stochastic sensor signal. Mechanical Systems and Signal Processing, 133 :106280, November 2019. ISSN 08883270. doi:10.1016/j.ymssp.2019.106280.
- [88] P. Borate, G. Wang, and Y. Wang. Data-Driven Structural Health Monitoring Approach Using Guided Lamb Wave Responses. Journal of Aerospace Engineering, 33(4) :04020033, July 2020. ISSN 0893-1321, 1943-5525. doi:10.1061/(ASCE)AS.1943-5525.0001145. Number : 4.
- [89] G. Quaranta. Efficient simulation tools for real-time monitoring and control using model order reduction and data-driven techniques. phdthesis, École centrale de Nantes; Universitat politècnica de Catalunya, September 2019, URL <https://tel.archives-ouvertes.fr/tel-02449724>.
- [90] P.-B. Rubio. Stratégies numériques innovantes pour l’assimilation de données par inférence bayésienne. phdthesis, Université Paris-Saclay, October 2019, URL <https://tel.archives-ouvertes.fr/tel-02345367>.
- [91] T. A. El Moselhy and Y. M. Marzouk. Bayesian inference with optimal maps. Journal of Computational Physics, 231(23) :7815–7850, October 2012. ISSN 0021-9991. doi:10.1016/j.jcp.2012.07.022.
- [92] M. Parno and Y. Marzouk. Transport map accelerated Markov chain Monte Carlo. SIAM/ASA Journal on Uncertainty Quantification, 6(2) :645–682, January 2018. ISSN 2166-2525. doi:10.1137/17M1134640. arXiv : 1412.5492.
- [93] I. Tabian, H. Fu, and Z. S. Khodaei. A Convolutional Neural Network for Impact Detection and Characterization of Complex Composite Structures. Sensors, 19(22) : 4933, November 2019. ISSN 1424-8220. doi:10.3390/s19224933.
- [94] V. Ewald, R. Groves, and R. Benedictus. DeepSHM : A Deep Learning Approach for Structural Health Monitoring Based on Guided Lamb Wave Techniques. March 2019. doi:10.1117/12.2506794.
- [95] N. Lu and T. Yin. Transferable common feature space mining for fault diagnosis with imbalanced data. Mechanical Systems and Signal Processing, 156 :107645, July 2021. ISSN 08883270. doi:10.1016/j.ymssp.2021.107645.

- [96] B. Yang, Y. Lei, F. Jia, N. Li, and Z. Du. A Polynomial Kernel Induced Distance Metric to Improve Deep Transfer Learning for Fault Diagnosis of Machines. IEEE Transactions on Industrial Electronics, 67(11) :9747–9757, November 2020. ISSN 0278-0046, 1557-9948. doi:10.1109/TIE.2019.2953010.
- [97] L. Xu, Y. Qingyun, Q. Chen, and J. Ren. Guided Wave-Convolutional Neural Network Based Fatigue Crack Diagnosis of Aircraft Structures. Sensors, 19 :3567, August 2019. doi:10.3390/s19163567.
- [98] S. Zhang, C. M. Li, and W. Ye. Damage localization in plate-like structures using time-varying feature and one-dimensional convolutional neural network. Mechanical Systems and Signal Processing, 147 :107107, January 2021. ISSN 0888-3270. doi:10.1016/j.ymsp.2020.107107.
- [99] C. Su, M. Jiang, S. Lv, S. Lu, L. Zhang, et al. Improved Damage Localization and Quantification of CFRP Using Lamb Waves and Convolution Neural Network. IEEE Sensors Journal, 19(14) :5784–5791, July 2019. ISSN 1558-1748. doi:10.1109/JSEN.2019.2908838. Conference Name : IEEE Sensors Journal.
- [100] M. Rautela and S. Gopalakrishnan. Ultrasonic guided wave based structural damage detection and localization using model assisted convolutional and recurrent neural networks. Expert Systems with Applications, 167 :114189, April 2021. ISSN 0957-4174. doi:10.1016/j.eswa.2020.114189.
- [101] P. Pandey, A. Rai, and M. Mitra. Explainable 1-D convolutional neural network for damage detection using Lamb wave. Mechanical Systems and Signal Processing, 164 :108220, February 2022. ISSN 0888-3270. doi:10.1016/j.ymsp.2021.108220.
- [102] H. Zhang, J. Lin, J. Hua, and T. Tong. Interpretable convolutional sparse coding method of Lamb waves for damage identification and localization. Structural Health Monitoring, page 14759217211044806, October 2021. ISSN 1475-9217. doi:10.1177/14759217211044806. Publisher : SAGE Publications.
- [103] M. Heesch, Z. Dworakowski, and K. Mendrok. Generative Adversarial Neural Networks for Guided Wave Signal Synthesis. In P. Rizzo and A. Milazzo, editors, European Workshop on Structural Health Monitoring, Lecture Notes in Civil Engineering, pages 14–23, Cham, 2021. Springer International Publishing. ISBN 978-3-030-64908-1. doi:10.1007/978-3-030-64908-1_2.
- [104] M. Heesch, M. Dziendzikowski, K. Mendrok, and Z. Dworakowski. Diagnostic-Quality Guided Wave Signals Synthesized Using Generative Adversarial Neural Net-

- works. Sensors, 22(10) :3848, January 2022. ISSN 1424-8220. doi:10.3390/s22103848. Number : 10 Publisher : Multidisciplinary Digital Publishing Institute.
- [105] T. Karras, S. Laine, and T. Aila. A Style-Based Generator Architecture for Generative Adversarial Networks, March 2019, URL <http://arxiv.org/abs/1812.04948>. arXiv :1812.04948 [cs, stat].
- [106] Z. Zhang, C. Sun, and B. Guo. Transfer-learning guided Bayesian model updating for damage identification considering modeling uncertainty. Mechanical Systems and Signal Processing, 166 :108426, March 2022. ISSN 0888-3270. doi:10.1016/j.ymssp.2021.108426.
- [107] S. Dabetwar, S. Ekwaro-Osire, and J. P. Dias. Fatigue Damage Diagnostics of Composites Using Data Fusion and Data Augmentation With Deep Neural Networks. Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, 5(2), August 2021. ISSN 2572-3901. doi:10.1115/1.4051947.
- [108] S. Agarwal and M. Mitra. Lamb wave based automatic damage detection using matching pursuit and machine learning. Smart Materials and Structures, 23(8) :085012, August 2014. ISSN 0964-1726, 1361-665X. doi:10.1088/0964-1726/23/8/085012.
- [109] C. Feng, H. Zhang, S. Wang, Y. Li, H. Wang, et al. Structural Damage Detection using Deep Convolutional Neural Network and Transfer Learning. KSCE Journal of Civil Engineering, 23(10) :4493–4502, October 2019. ISSN 1976-3808. doi:10.1007/s12205-019-0437-z.
- [110] B. Zhang, X. Hong, and Y. Liu. Distribution adaptation deep transfer learning method for cross-structure health monitoring using guided waves. Structural Health Monitoring, page 147592172110107, May 2021. ISSN 1475-9217, 1741-3168. doi:10.1177/14759217211010709.
- [111] P. Gardner, L. Bull, N. Dervilis, and K. Worden. Overcoming the problem of repair in structural health monitoring : Metric-informed transfer learning. Journal of Sound and Vibration, page 116245, June 2021. ISSN 0022460X. doi:10.1016/j.jsv.2021.116245.
- [112] A. Kulakovskiy. Développement d'un système SHM pour aéronef par ondes élastiques guidées. PhD Thesis, 2019, URL <http://www.theses.fr/2019SACLX021/document>.

- [113] B. Schölkopf and A. J. Smola. Learning with Kernels : Support Vector Machines, Regularization, Optimization, and Beyond. The MIT Press, 2018. ISBN 978-0-262-25693-3. doi:10.7551/mitpress/4175.001.0001.
- [114] J.-P. Chilès and N. Desassis. Fifty Years of Kriging. In B. Daya Sagar, Q. Cheng, and F. Agterberg, editors, Handbook of Mathematical Geosciences, pages 589–612. Springer International Publishing, Cham, 2018. ISBN 978-3-319-78998-9 978-3-319-78999-6. doi:10.1007/978-3-319-78999-6_29.
- [115] R. L. Hardy. Multiquadric equations of topography and other irregular surfaces. Journal of Geophysical Research, 76(8) :1905–1915, March 1971. ISSN 01480227. doi:10.1029/JB076i008p01905. Number : 8.
- [116] M. Guo and J. S. Hesthaven. Data-driven reduced order modeling for time-dependent problems. Computer Methods in Applied Mechanics and Engineering, 345 : 75–99, March 2019. ISSN 0045-7825. doi:10.1016/j.cma.2018.10.029.
- [117] L. Sorber, M. Van Barel, and L. De Lathauwer. Optimization-Based Algorithms for Tensor Decompositions : Canonical Polyadic Decomposition, Decomposition in Rank- $(L_r, L_r, 1)$ Terms, and a New Generalization. SIAM Journal on Optimization, 23(2) :695–720, January 2013. ISSN 1052-6234, 1095-7189. doi:10.1137/120868323. Number : 2.
- [118] E. Cueto, D. González, and I. Alfaro. Proper Generalized Decompositions. SpringerBriefs in Applied Sciences and Technology. Springer International Publishing, Cham, 2016. ISBN 978-3-319-29993-8 978-3-319-29994-5. doi:10.1007/978-3-319-29994-5.
- [119] R. Ibáñez, E. Abisset-Chavanne, A. Ammar, D. González, E. Cueto, et al. A Multidimensional Data-Driven Sparse Identification Technique : The Sparse Proper Generalized Decomposition. Complexity, 2018 :1–11, November 2018. ISSN 1076-2787, 1099-0526. doi:10.1155/2018/5608286.
- [120] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. Nature, 521(7553) :436–444, May 2015. ISSN 0028-0836, 1476-4687. doi:10.1038/nature14539.
- [121] F. Anselmi, J. Z. Leibo, L. Rosasco, J. Mutch, A. Tacchetti, et al. Unsupervised Learning of Invariant Representations in Hierarchical Architectures. arXiv :1311.4158 [cs], March 2014, URL <http://arxiv.org/abs/1311.4158>. arXiv : 1311.4158.
- [122] K. Simonyan and A. Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv :1409.1556 [cs], April 2015, URL <http://arxiv.org/abs/1409.1556>. arXiv : 1409.1556.

- [123] K. He, X. Zhang, S. Ren, and J. Sun. Deep Residual Learning for Image Recognition. [arXiv :1512.03385 \[cs\]](https://arxiv.org/abs/1512.03385), December 2015, URL <http://arxiv.org/abs/1512.03385>. arXiv : 1512.03385.
- [124] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, et al. Generative Adversarial Nets. In *Advances in Neural Information Processing Systems*, volume 27. Curran Associates, Inc., 2014, URL <https://papers.nips.cc/paper/2014/hash/5ca3e9b122f61f8f06494c97b1afccf3-Abstract.html>.
- [125] S. Ioffe and C. Szegedy. Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift. [arXiv :1502.03167 \[cs\]](https://arxiv.org/abs/1502.03167), March 2015, URL <http://arxiv.org/abs/1502.03167>. arXiv : 1502.03167.
- [126] Y. Bengio. Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning*, 2(1) :1–127, 2009. ISSN 1935-8237, 1935-8245. doi:10.1561/2200000006.
- [127] D. P. Kingma and J. Ba. Adam : A Method for Stochastic Optimization. [arXiv :1412.6980 \[cs\]](https://arxiv.org/abs/1412.6980), January 2017, URL <http://arxiv.org/abs/1412.6980>. arXiv : 1412.6980.
- [128] K. Team. Keras documentation : Keras FAQ, URL <https://keras.io/getting-started/faq/#how-should-i-cite-keras>.
- [129] L. B. Rall. *Automatic differentiation : techniques and applications*. Number 120 in *Lecture notes in computer science*. Springer-Verlag, Berlin ; New York, 1981. ISBN 978-3-540-10861-0.
- [130] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, et al. Analyzing and Improving the Image Quality of StyleGAN. [arXiv :1912.04958 \[cs, eess, stat\]](https://arxiv.org/abs/1912.04958), March 2020, URL <http://arxiv.org/abs/1912.04958>. arXiv : 1912.04958.
- [131] R. R. Shetty, M. Fritz, and B. Schiele. Adversarial Scene Editing : Automatic Object Removal from Weak Supervision. In *Advances in Neural Information Processing Systems*, volume 31. Curran Associates, Inc., 2018, URL <https://proceedings.neurips.cc/paper/2018/hash/c911241d00294e8bb714eee2e83fa475-Abstract.html>.
- [132] R. Durall, A. Chatzimichailidis, P. Labus, and J. Keuper. Combating Mode Collapse in GAN training : An Empirical Analysis using Hessian Eigenvalues, December 2020, URL <http://arxiv.org/abs/2012.09673>. arXiv :2012.09673 [cs].

- [133] J. Kim and H. Park. OA-GAN : Overfitting Avoidance Method of GAN oversampling based on xAI. In 2021 Twelfth International Conference on Ubiquitous and Future Networks (ICUFN), pages 394–398, August 2021. doi:10.1109/ICUFN49451.2021.9528594. ISSN : 2165-8536.
- [134] Y. Zhou, K. Gu, and T. Huang. Unsupervised Representation Adversarial Learning Network : from Reconstruction to Generation. arXiv :1804.07353 [cs, stat], April 2019, URL <http://arxiv.org/abs/1804.07353>. arXiv : 1804.07353.
- [135] X. Chen, Y. Duan, R. Houthoof, J. Schulman, I. Sutskever, et al. InfoGAN : Interpretable Representation Learning by Information Maximizing Generative Adversarial Nets. In Advances in Neural Information Processing Systems, volume 29. Curran Associates, Inc., 2016, URL <https://proceedings.neurips.cc/paper/2016/hash/7c9d0b1f96aebd7b5eca8c3edaa19ebb-Abstract.html>.
- [136] R. Houthoof, X. Chen, X. Chen, Y. Duan, J. Schulman, et al. VIME : Variational Information Maximizing Exploration. In Advances in Neural Information Processing Systems, volume 29. Curran Associates, Inc., 2016, URL <https://proceedings.neurips.cc/paper/2016/hash/abd815286ba1007abfbb8415b83ae2cf-Abstract.html>.
- [137] A. Spurr, E. Aksan, and O. Hilliges. Guiding InfoGAN with Semi-Supervision. CoRR, abs/1707.04487, 2017, URL <http://arxiv.org/abs/1707.04487>. arXiv : 1707.04487.
- [138] F. Chinesta, E. Cueto, E. Abisset-Chavanne, J. L. Duval, and F. E. Khaldi. Virtual, Digital and Hybrid Twins : A New Paradigm in Data-Based Engineering and Engineered Data. Archives of Computational Methods in Engineering, November 2018. ISSN 1886-1784. doi:10.1007/s11831-018-9301-4.
- [139] J. P. Kleijnen. Kriging metamodeling in simulation : A review. European Journal of Operational Research, 192(3) :707–716, February 2009. ISSN 03772217. doi:10.1016/j.ejor.2007.10.013. Number : 3.
- [140] S. M. A. Sbai. Traitement des signaux parcimonieux et applications. page 130.
- [141] S. Mallat and Zhifeng Zhang. Matching pursuits with time-frequency dictionaries. IEEE Transactions on Signal Processing, 41(12) :3397–3415, December 1993. ISSN 1053587X. doi:10.1109/78.258082. Number : 12.
- [142] S. Agarwal and M. Mitra. Lamb wave based automatic damage detection using matching pursuit and machine learning. Smart Materials and Structures,

- 23(8) :085012, August 2014. ISSN 0964-1726, 1361-665X. doi:10.1088/0964-1726/23/8/085012.
- [143] J.-C. Hong, K. H. Sun, and Y. Y. Kim. The matching pursuit approach based on the modulated Gaussian pulse for efficient guided-wave damage inspection. Smart Materials and Structures, 14(4) :548–560, August 2005. ISSN 0964-1726, 1361-665X. doi:10.1088/0964-1726/14/4/013. Number : 4.
- [144] C. M. Yeum, H. Sohn, H. J. Lim, and J. B. Ihn. Reference-free delamination detection using Lamb waves. Structural Control and Health Monitoring, 21(5) : 675–684, 2014. ISSN 1545-2263. doi:10.1002/stc.1594. eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/stc.1594>.
- [145] D. Rodat. Simulation opérationnelle en contrôle non destructif. phd-thesis, Université Paris Saclay (COmUE), December 2018, URL <https://tel.archives-ouvertes.fr/tel-03225641>.
- [146] J. A. Scales and A. Gersztenkorn. Robust methods in inverse theory. Inverse Problems, 4(4) :1071–1091, October 1988. ISSN 0266-5611, 1361-6420. doi:10.1088/0266-5611/4/4/010.
- [147] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, et al. A Comprehensive Survey on Transfer Learning. CoRR, abs/1911.02685, 2019, URL <http://arxiv.org/abs/1911.02685>. arXiv : 1911.02685.
- [148] K. Weiss, T. M. Khoshgoftaar, and D. Wang. A survey of transfer learning. Journal of Big Data, 3(1) :9, December 2016. ISSN 2196-1115. doi:10.1186/s40537-016-0043-6. Number : 1.
- [149] S. J. Pan and Q. Yang. A Survey on Transfer Learning. IEEE Transactions on Knowledge and Data Engineering, 22(10) :1345–1359, October 2010. ISSN 1041-4347. doi:10.1109/TKDE.2009.191. Number : 10.
- [150] L. Ambrosio and N. Gigli. A User’s Guide to Optimal Transport. In Modelling and Optimisation of Flows on Networks, volume 2062, pages 1–155. Springer Berlin Heidelberg, Berlin, Heidelberg, 2013. ISBN 978-3-642-32159-7 978-3-642-32160-3. doi:10.1007/978-3-642-32160-3_1. Series Title : Lecture Notes in Mathematics.
- [151] C. Villani. Optimal transport : old and new. Number 338 in Grundlehren der mathematischen Wissenschaften. Springer, Berlin, 2009. ISBN 978-3-540-71049-3. OCLC : ocn244421231.

- [152] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, et al. A Survey on Deep Transfer Learning, August 2018. arXiv :1808.01974 [cs, stat].
- [153] W. Dai, Q. Yang, G.-R. Xue, and Y. Yu. Boosting for transfer learning. In Proceedings of the 24th international conference on Machine learning - ICML '07, pages 193–200, Corvallis, Oregon, 2007. ACM Press. ISBN 978-1-59593-793-3. doi:10.1145/1273496.1273521.
- [154] Y. Xu, S. J. Pan, H. Xiong, Q. Wu, R. Luo, et al. A Unified Framework for Metric Transfer Learning. IEEE Transactions on Knowledge and Data Engineering, 2017. doi:10.1109/TKDE.2017.2669193.
- [155] T. Han, C. Liu, W. Yang, and D. Jiang. Deep transfer network with joint distribution adaptation : A new intelligent fault diagnosis framework for industry application. ISA Transactions, 97 :269–281, February 2020. ISSN 0019-0578. doi:10.1016/j.isatra.2019.08.012.
- [156] M. Long, J. Wang, G. Ding, J. Sun, and P. S. Yu. Transfer Feature Learning with Joint Distribution Adaptation. In 2013 IEEE International Conference on Computer Vision, pages 2200–2207, Sydney, Australia, December 2013. IEEE. ISBN 978-1-4799-2840-8. doi:10.1109/ICCV.2013.274.
- [157] N. Courty, R. Flamary, A. Habrard, and A. Rakotomamonjy. Joint Distribution Optimal Transportation for Domain Adaptation, October 2017. arXiv :1705.08848 [cs, stat].
- [158] B. B. Damodaran, B. Kellenberger, R. Flamary, D. Tuia, and N. Courty. DeepJ-DOT : Deep Joint Distribution Optimal Transport for Unsupervised Domain Adaptation. arXiv :1803.10081 [cs], September 2018, URL <http://arxiv.org/abs/1803.10081>. arXiv : 1803.10081.
- [159] S. J. Pan, I. W. Tsang, J. T. Kwok, and Q. Yang. Domain Adaptation via Transfer Component Analysis. IEEE Transactions on Neural Networks, 22(2) :199–210, February 2011. ISSN 1045-9227, 1941-0093. doi:10.1109/TNN.2010.2091281.
- [160] T. G. Ritto, K. Worden, D. J. Wagg, F. A. Rochinha, and P. Gardner. A transfer learning-based digital twin for detecting localised torsional friction in deviated wells. Mechanical Systems and Signal Processing, 173 :109000, July 2022. ISSN 0888-3270. doi:10.1016/j.ymsp.2022.109000.
- [161] K. Simonyan, A. Vedaldi, and A. Zisserman. Deep Inside Convolutional Networks : Visualising Image Classification Models and Saliency Maps. arXiv :1312.6034 [cs], April 2014, URL <http://arxiv.org/abs/1312.6034>. arXiv : 1312.6034.

- [162] S. Montaha, S. Azam, A. K. M. R. H. Rafid, P. Ghosh, M. Z. Hasan, et al. Breast-Net18 : A High Accuracy Fine-Tuned VGG16 Model Evaluated Using Ablation Study for Diagnosing Breast Cancer from Enhanced Mammography Images. Biology, 10(12) : 1347, December 2021. ISSN 2079-7737. doi:10.3390/biology10121347.
- [163] E. Tzeng, J. Hoffman, K. Saenko, and T. Darrell. Adversarial Discriminative Domain Adaptation. arXiv :1702.05464 [cs], February 2017, URL <http://arxiv.org/abs/1702.05464>. arXiv : 1702.05464.
- [164] M. Long, Z. Cao, J. Wang, and M. I. Jordan. Conditional Adversarial Domain Adaptation. Technical Report arXiv :1705.10667, arXiv, December 2018, URL <http://arxiv.org/abs/1705.10667>. arXiv :1705.10667 [cs] type : article.
- [165] L. Bull, P. Gardner, J. Gosliga, T. Rogers, N. Dervilis, et al. Foundations of population-based SHM, Part I : Homogeneous populations and forms. Mechanical Systems and Signal Processing, 148 :107141, February 2021. ISSN 08883270. doi:10.1016/j.ymsp.2020.107141.
- [166] A. Korotin, L. Li, J. Solomon, and E. Burnaev. Continuous Wasserstein-2 Barycenter Estimation without Minimax Optimization. Technical Report arXiv :2102.01752, arXiv, February 2021, URL <http://arxiv.org/abs/2102.01752>. arXiv :2102.01752 [cs, stat] type : article.
- [167] A. Makkuva, A. Taghvaei, S. Oh, and J. Lee. Optimal transport mapping via input convex neural networks. In Proceedings of the 37th International Conference on Machine Learning, pages 6672–6681. PMLR, November 2020, URL <https://proceedings.mlr.press/v119/makkuva20a.html>. ISSN : 2640-3498.
- [168] R. J. McCann. Existence and uniqueness of monotone measure-preserving maps. Duke Mathematical Journal, 80(2), November 1995. ISSN 0012-7094. doi:10.1215/S0012-7094-95-08013-2.
- [169] H. Knothe. Contributions to the theory of convex bodies. Michigan Mathematical Journal, 4(1), January 1957. ISSN 0026-2285. doi:10.1307/mmj/1028990175.
- [170] M. Rosenblatt. Remarks on a Multivariate Transformation. The Annals of Mathematical Statistics, 23(3) :470–472, September 1952. ISSN 0003-4851. doi:10.1214/aoms/1177729394.
- [171] L. Kantorovitch. On the Translocation of Masses. Management Science, 5(1) :1–4, 1958, URL <http://www.jstor.org/stable/2626967>.

- [172] M. Cuturi. Sinkhorn Distances : Lightspeed Computation of Optimal Transportation Distances. [arXiv :1306.0895 \[stat\]](https://arxiv.org/abs/1306.0895), June 2013, URL <http://arxiv.org/abs/1306.0895>. arXiv : 1306.0895.
- [173] R. Flamary and N. Courty. POT Python Optimal Transport library. page 91.
- [174] S. P. Boyd and L. Vandenberghe. Convex optimization. Cambridge University Press, Cambridge, UK ; New York, 2004. ISBN 978-0-521-83378-3.
- [175] Y. Brenier. Polar factorization and monotone rearrangement of vector-valued functions. Communications on Pure and Applied Mathematics, 44(4) :375–417, 1991. ISSN 1097-0312. doi:10.1002/cpa.3160440402. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpa.3160440402>.
- [176] A. Taghvaei and A. Jalali. 2-Wasserstein Approximation via Restricted Convex Potentials with Application to Improved Training for GANs. [arXiv :1902.07197 \[cs, math, stat\]](https://arxiv.org/abs/1902.07197), February 2019, URL <http://arxiv.org/abs/1902.07197>. arXiv : 1902.07197.
- [177] L. Rout, A. Korotin, and E. Burnaev. Generative Modeling with Optimal Transport Maps. CoRR, abs/2110.02999, 2021, URL <https://arxiv.org/abs/2110.02999>. arXiv : 2110.02999.
- [178] J. Fan, S. Liu, S. Ma, Y. Chen, and H. Zhou. Scalable Computation of Monge Maps with General Costs. Technical Report [arXiv :2106.03812](https://arxiv.org/abs/2106.03812), arXiv, November 2021, URL <http://arxiv.org/abs/2106.03812>. arXiv :2106.03812 [cs, math] type : article.
- [179] M. Arjovsky, S. Chintala, and L. Bottou. Wasserstein GAN. [arXiv :1701.07875 \[cs, stat\]](https://arxiv.org/abs/1701.07875), December 2017, URL <http://arxiv.org/abs/1701.07875>. arXiv : 1701.07875.
- [180] A. Mallasto, J. Frellsen, W. Boomsma, and A. Feragen. (q,p)-Wasserstein GANs : Comparing Ground Metrics for Wasserstein GANs, February 2019, URL [http://arxiv.org/abs/1902.03642](https://arxiv.org/abs/1902.03642). Number : arXiv :1902.03642 arXiv :1902.03642 [cs, stat].
- [181] N. Dam, Q. Hoang, T. Le, T. D. Nguyen, H. Bui, et al. Three-Player Wasserstein GAN via Amortised Duality. In Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence, pages 2202–2208, Macao, China, August 2019. International Joint Conferences on Artificial Intelligence Organization. ISBN 978-0-9992411-4-1. doi:10.24963/ijcai.2019/305.
- [182] J. Leygonie, J. She, A. Almahairi, S. Rajeswar, and A. C. Courville. Adversarial Computation of Optimal Transport Maps. CoRR, abs/1906.09691, 2019, URL <http://arxiv.org/abs/1906.09691>. arXiv : 1906.09691.

- [183] Y. Chen, M. Telgarsky, C. Zhang, B. Bailey, D. Hsu, et al. A Gradual, Semi-Discrete Approach to Generative Network Training via Explicit Wasserstein Minimization. In Proceedings of the 36th International Conference on Machine Learning, pages 1071–1080. PMLR, May 2019, URL <https://proceedings.mlr.press/v97/chen19h.html>. ISSN : 2640-3498.
- [184] V. Seguy, B. B. Damodaran, R. Flamary, N. Courty, A. Rolet, et al. Large-Scale Optimal Transport and Mapping Estimation. In ICLR 2018 - International Conference on Learning Representations, pages 1–15, Vancouver, Canada, April 2018. URL <https://hal.inria.fr/hal-01956354>.
- [185] A. Korotin, V. Egiazarian, A. Asadulaev, A. Safin, and E. Burnaev. Wasserstein-2 Generative Networks. September 2020, URL https://openreview.net/forum?id=bEoxzW_EXsa.
- [186] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. In 2017 IEEE International Conference on Computer Vision (ICCV), pages 2242–2251, October 2017. doi:10.1109/ICCV.2017.244. ISSN : 2380-7504.
- [187] B. Amos, L. Xu, and J. Z. Kolter. Input Convex Neural Networks. arXiv :1609.07152 [cs, math], June 2017, URL <http://arxiv.org/abs/1609.07152>. arXiv : 1609.07152.
- [188] S. Sivaprasad, A. Singh, N. Manwani, and V. Gandhi. The Curious Case of Convex Neural Networks. arXiv :2006.05103 [cs, stat], July 2021, URL <http://arxiv.org/abs/2006.05103>. arXiv : 2006.05103.
- [189] Y. Chen, Y. Shi, and B. Zhang. Optimal Control Via Neural Networks : A Convex Approach, 2018.

Résumé : Le Contrôle de la Santé des Structures (ou *Structural Health Monitoring*, SHM en anglais) accompagne le déploiement de la maintenance prédictive en surveillant *in situ* et en temps réel les structures aéronautiques. La technologie retenue dans ces travaux s'appuie sur des propagations d'ondes de Lamb mesurées par des transducteurs piézoélectriques. Les dommages sont alors caractérisés par des méthodes avancées de traitement du signal et d'apprentissage automatique. Un procédé innovant de délaminages induits par des chocs Laser est exploité dans ces travaux pour valider un modèle par éléments finis et pour évaluer les algorithmes de SHM sur des endommagements réalistes et entièrement maîtrisés.

La représentation d'un dispositif de SHM en système est exploitée afin de proposer des stratégies de résolution du problème direct et inverse par des méthodes d'apprentissage. Plusieurs approximations du problème direct sont évaluées afin de prédire rapidement des résultats de simulations numériquement coûteuses. De plus, une stratégie d'apprentissage profond est proposée pour la résolution du problème avec une bonne capacité de généralisation et une robustesse aux incertitudes expérimentales.

L'apprentissage dépend cependant des données d'entraînement et tout changement structurel, environnemental ou opératoire courant en SHM détériore les prédictions. Une approche innovante d'apprentissage par transfert exploitant la théorie du transport optimale propose alors de capitaliser sur les connaissances acquises sur structure pour les transférer à une autre à l'aide des potentiels de Kantorovich. Cette approche ouvre la voie à des modèles d'apprentissage profond hybrides mélangeant des données numériques riches avec des données expérimentales.

Mots clés : SHM, Choc Laser, Apprentissage profond, Transport Optimal, Apprentissage par Transfert

Abstract : The Structural Health Monitoring (SHM) accompanies the deployment of predictive maintenance by monitoring aeronautical structures in real time. The technology used in this work is based on Lamb wave propagation measured by piezoelectric transducers. The damages are then characterized by advanced methods of signal processing and machine learning. An innovative laser shock induced delamination process is used in this work to validate a finite element model and to evaluate SHM algorithms on realistic and fully controlled damage.

The representation of a SHM device as a system is exploited to propose strategies for solving the direct and inverse problem by learning methods. Several approximations of the direct problem are evaluated to quickly predict the results of numerically expensive simulations. Moreover, a deep learning approach is proposed to solve the inverse problem with a very good generalization capacity and robustness to experimental uncertainties.

However, the learning depends on the training data and any structural, environmental, or operational change deteriorates the predictions. An innovative transfer learning approach based on the optimal transport theory proposes to capitalize on the knowledge acquired on a structure to transfer it to another through Kantorovich potentials. This approach opens the way to hybrid deep learning models mixing rich numerical data with experimental data in SHM.

Keywords : SHM, Shock Laser, Deep Learning, Optimal Transport, Transfer Learning