



**HAL**  
open science

# Aide à la décision pour la détection et l'analyse des défauts de surface dans les structures immergées

Yaya Yannick Sidibé

► **To cite this version:**

Yaya Yannick Sidibé. Aide à la décision pour la détection et l'analyse des défauts de surface dans les structures immergées. Traitement du signal et de l'image [eess.SP]. Université du Havre, 2015. Français. NNT : 2015LEHA0006 . tel-01256830

**HAL Id: tel-01256830**

**<https://theses.hal.science/tel-01256830>**

Submitted on 15 Jan 2016

**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.

## UNIVERSITÉ DU HAVRE

Groupe de Recherche en Électrotechnique et Automatique du Havre  
Laboratoire Ondes et Milieux Complexes

Mémoire de thèse  
Présentée par **Yaya Sidibé**  
Pour l'obtention du diplôme de  
Docteur de l'Université du Havre

Spécialité : Génie Informatique, automatique et traitement de signal

---

### Aide à la décision pour la détection et l'analyse des défauts de surface dans les structures immergées

---

Soutenue le 05 octobre 2015 devant le jury composé de :

<b>Pr. Louis Pascal Tran Huu Hue</b>	INSA Centre val de Loire (Président)
<b>Pr. Frédéric Kratz</b>	INSA Centre val de Loire (Rapporteur)
<b>M. Moamar Sayed Mouchaweh</b>	Ecole Nationale Supérieure des Mines de Douai (Rapporteur)
<b>Pr. Daniel Jolly</b>	Université d'Artois
<b>Pr. Dimitri Lefebvre</b>	Université du Havre (Directeur de thèse)
<b>Pr. Gérard Maze</b>	Université du Havre (Co-directeur de thèse)
<b>M. Fabrice Druaux</b>	Université du Havre
<b>M. Fernand Léon</b>	Université du Havre



## Remerciements

Avant tout, je voudrais remercier tout particulièrement Dimitri Lefebvre et Gérard Maze qui m'ont dirigé tout au long de ces années de thèse. Ils ont toujours été disponible, à l'écoute de mes nombreuses questions, et se sont toujours intéressés à l'avancée de mes travaux. Les nombreuses discussions que nous avons eues ainsi que leurs conseils sont pour beaucoup dans le résultat final de ce travail. Leurs capacités d'analyse ont été d'une importance capitale dans la réussite de ce projet. Leurs rigueurs, leurs nombreuses connaissances m'ont permis de progresser et ont répondu à plusieurs de mes préoccupations. Enfin, leurs nombreuses relectures et corrections des articles ainsi que du présent rapport ont été très appréciables. Je ne vous remercierai jamais assez.

Je remercie Fabrice Druaux et Fernand Leon d'avoir co-encadré ce travail de thèse. C'est grâce à leurs apports que ce projet a été réalisé dans un esprit de transversalité dans les domaines automatique et acoustique. Cette collaboration s'est avéré être une expérience très enrichissante.

Je remercie Jean François Brethé pour son soutien et ses conseils qui m'ont aidés tout au long de la thèse.

Je remercie l'ensemble du personnel du GREAH et du Laboratoire Ondes et Milieux Complexes (LOMC) sans oublier les thésards pour leurs soutiens permanents tout au long de ma thèse.

Je remercie Messieurs Frédéric Kratz et Moamar Sayed Mouchaweh qui ont accepté d'être rapporteurs de cette thèse.

Mes vifs remerciements vont également à Messieurs Daniel Jolly et Louis TRAN HUU HUE d'avoir accepté de participer à ce jury.

Enfin je tiens à remercier ma famille et mes amis qui ont toujours été à mes côtés.



## Production scientifique

[Sidibe et al., 2013a] Sidibe, Y., Druaux, F., Lefebvre, D., Maze, G., and Leon, F. (2013a). Outils d'aide à la décision pour le diagnostic des structures immergées. *JESA*, 47(4-8) :pages 339–360.

[Maze et al., 2014] Maze, G., Leon, F., Farid, C., Decultot, D., Sidibe, Y., Druaux, F., and Lefebvre, D. (2014). Detection of a straight groove in a metal plate by acoustic scattering in water with applications to marine current turbines. *NDTE International*, pages 47 – 53.

[Sidibe et al., 2015] Sidibe, Y., Druaux, F., Lefebvre, D., Leon, F., and Maze, G. (2015). A non contact method for the detection and diagnosis of surface damage in immersed structures. *Advances in Acoustics and Vibration*, 2015.

[Sidibe et al., 2013b] Sidibe, Y., Druaux, F., Lefebvre, D., Leon, F., and Maze, G. (2013b). Active fault diagnosis for immersed structure. In Control, Decision and Information Technologies (IEEE - CoDIT), 2013 International Conference on, Hammamet, Tunisia, 6-8 May 2013, pages 71–75.

[Sidibe et al., 2013c] Sidibe, Y., Lefebvre, D., Druaux, F., Maze, G., and Leon, F. (2013c). Detection, diagnostic et localisation des défauts dans les structures immergées. In Journées doctorales journée nationale Modélisation, Automatic, Control, 11-12 juillet 2013, Strasbourg, France.

[Y. Sidibé, D. Lefebvre, F. Druaux, F. Leon, G. Maze], Damage detection based on wavelet transform and artificial intelligence for underwater metallic structures, 2013, IEEE- ECC, Strasbourg, France.

[Sidibe et al., 2013d] Sidibe, Y., Lefebvre, D., Druaux, F., Maze, G., and Leon, F. (2013d). Localisation de défaut dans un signal ultrasonore. In Qualita, 19-22 Mars 2013, Compiègne, France.

[G. Maze, F. Léon, D. Décultot and F. Chati, Y. Sidibé, F. Druaux, D. Lefebvre] Acoustic scattering of a straight groove on a metal plate immersed in water at low frequency : detection and positioning, in *Detection and classification of Underwater targets* by I. Quidu, V. Myers, B. Zerr, Chap5, Cambridge Scholars Publishing, 2014 ISBN(10) :1-4438-5709-2, ISBN(13) : 978-1-4438-5709-3

# TABLE DES MATIÈRES

<b>1</b>	<b>Introduction générale</b>	<b>19</b>
1.1	Position du problème . . . . .	21
1.2	Contenu de la thèse . . . . .	21
<b>2</b>	<b>Propagation et diffusion acoustique par une plaque limitée</b>	<b>25</b>
2.1	Introduction . . . . .	25
2.2	Génération d'ondes acoustiques . . . . .	25
2.3	Propagation d'ondes dans les milieux liquides et solides . . . . .	27
2.4	Application aux plaques métalliques immergées dans l'eau . . . . .	37
2.4.1	Dispositif expérimental . . . . .	37
2.4.2	Propagation des ondes de Lamb symétriques et antisymétriques . . . . .	39
2.4.3	Calcul du temps de vol pour une plaque saine . . . . .	40
2.4.4	Calcul du temps de vol pour une plaque avec une rainure . . . . .	44
2.4.5	Plage d'angles d'incidence maximum . . . . .	45
2.5	Conclusion . . . . .	47



<b>3</b>	<b>Méthodes et outils d'analyse de l'état de santé des plaques immergées</b>	<b>49</b>
3.1	Introduction . . . . .	49
3.2	Méthodes de détection et de diagnostic sans modèle de référence . . . . .	50
3.2.1	Méthodes de détection à base de reconnaissance des formes . . . . .	50
3.2.2	Méthode de détection à base de système expert . . . . .	53
3.3	Méthodes de détection à base de modèle de référence . . . . .	54
3.3.1	Génération de résidus par estimation paramétrique . . . . .	55
3.3.2	Approche de génération de résidus par les espaces de parité . . . . .	56
3.3.3	Génération de résidus par estimation d'état . . . . .	58
3.4	Outils de traitement des signaux . . . . .	58
3.4.1	Transformée de Hilbert . . . . .	59
3.4.2	Transformée en ondelettes continues . . . . .	61
3.4.3	Normalisation . . . . .	64
3.4.4	Analyse en composantes principales . . . . .	64
3.4.5	Réseaux gaussiens de classification . . . . .	65
3.5	Conclusion . . . . .	72
<b>4</b>	<b>Détection et localisation des défauts par modèle de référence</b>	<b>75</b>
4.1	Introduction . . . . .	75
4.2	Choix des échantillons . . . . .	76
4.3	Méthode de détection par seuillage de défauts dans les plaques métalliques immergées . . . . .	77
4.3.1	Algorithme de détection et de localisation de défauts . . . . .	77
4.3.2	Validation expérimentale . . . . .	81

4.3.3	Conclusion . . . . .	85
4.4	Méthode de détection par apprentissage et seuillage . . . . .	87
4.4.1	Estimation des paramètres $\theta$ et $l$ . . . . .	87
4.4.2	Algorithme de détection automatique du segment utile . . . . .	88
4.4.3	Détection des défauts . . . . .	92
4.4.4	Localisation de défauts . . . . .	98
4.5	Détection de défaut par traitement d'image . . . . .	100
4.5.1	Procédure de traitement d'image des signaux acoustiques . . . . .	101
4.5.2	Détection des fissures . . . . .	102
4.5.3	Localisation des défauts . . . . .	104
4.5.4	Résultats et discussion . . . . .	107
4.6	Conclusion . . . . .	111
<b>5</b>	<b>Détection et diagnostic des défauts sans modèle de référence</b>	<b>113</b>
5.1	Introduction . . . . .	113
5.2	Prétraitement des signaux . . . . .	114
5.3	Analyse en composantes principales . . . . .	115
5.4	Classification par réseau de neurones gaussiens . . . . .	116
5.4.1	Algorithme d'apprentissage du réseau de neurones à noyau gaussien . .	116
5.4.2	Adaptation de la position des centres des gaussiennes 117	
5.4.3	Adaptation de la dispersion des gaussiennes . . . . .	118
5.4.4	Adaptation du nombre de gaussiennes associées à chaque classe 119	

5.4.5	Classification d'un échantillon . . . . .	119
5.5	Détection et diagnostic des défauts dans les plaques immergées par réseaux de neurones gaussiens . . . . .	121
5.5.1	Protocole d'expérimentation et constitution de la base d'apprentissage .	121
5.5.2	Résultat de la détection . . . . .	122
5.5.3	Résultat du diagnostic . . . . .	125
5.6	Classification par extraction de la transformée en ondelette continue . . . . .	127
5.6.1	Défaut vertical . . . . .	130
5.6.2	Défaut Oblique . . . . .	132
5.7	Détection et diagnostic par mesures moyennées . . . . .	134
5.7.1	Principe de la méthode . . . . .	134
5.7.2	Résultats obtenus . . . . .	135
5.8	Conclusion . . . . .	139
<b>6</b>	<b>Conclusion générale</b>	<b>141</b>

## TABLE DES FIGURES

2.1	Caractéristiques du transducteur utilisé. (A) écho temporel, (B) bande passante correspondante . . . . .	26
2.2	Plaque métallique immergée dans un fluide . . . . .	28
2.3	Modes de Lamb symétriques et antisymétriques . . . . .	34
2.4	Vitesse de phase des ondes de Lamb. (A) symétrique, (B) antisymétrique . . . . .	35
2.5	Configuration en incidence normale . . . . .	36
2.6	Configuration en incidence oblique . . . . .	37
2.7	Dispositif expérimental . . . . .	38
2.8	(A) Schéma simplifié du dispositif expérimental, (B) Exemple de plaque avec fissure . . . . .	39
2.9	(A) Vitesse de phase de l'onde $S_0$ , (B) vitesse de groupe de l'onde $S_0$ . . . . .	40
2.10	(A) Vitesse de phase de l'onde $A$ , (B) vitesse de groupe de l'onde $A$ . . . . .	41
2.11	Temps de vol de l'onde $S_0$ . . . . .	42
2.12	Temps de vol de l'onde $A$ . . . . .	43
2.13	Parcours de l'onde dans l'eau et dans la plaque en présence de défaut . . . . .	45

2.14	Trajectoires des temps de vol des ondes dans une plaque avec rainure ( $F$ ) . . . . .	46
2.15	Plage d'incidence angulaire à éviter $\delta$ pour différentes valeurs du rapport $L/2l$ . . . . .	47
3.1	Système de reconnaissance de formes . . . . .	51
3.2	Structure d'un système expert de diagnostic . . . . .	54
3.3	Principe de génération de résidus par modèle de référence . . . . .	56
3.4	Principe de génération de résidus par estimation de paramètres . . . . .	57
3.5	Principe général d'un estimateur d'état . . . . .	59
3.6	Signal de rétrodiffusion d'une plaque et son enveloppe extraite par transformée de Hilbert . . . . .	61
3.7	Décomposition en 5 modes de vibration du signal de rétrodiffusion d'une plaque de largeur $60mm$ et d'épaisseur $1.5mm$ sous $10^\circ$ d'incidence . . . . .	62
3.8	Exemple d'ondelette mère : Morlet . . . . .	63
3.9	Neurones biologiques et artificiels . . . . .	65
3.10	Fonctions d'activation courantes. (A) : seuil, (B) :linéaire, (C) : sigmoïde, (D) : gaussienne . . . . .	66
3.11	Exemple de réseau de neurones non bouclé à $n$ entrées, $N_C$ neurones cachés et $N_O$ neurones de sortie . . . . .	68
3.12	Architecture d'un réseau récurrent . . . . .	69
3.13	Architecture du réseau de neurones gaussiens . . . . .	71
3.14	Apprentissage non supervisé des noyaux gaussiens . . . . .	73
4.1	Échantillons de plaque avec fissure utilisés pour la détection à base de modèles de référence . . . . .	76
4.2	Algorithme de détection de défaut par seuillage . . . . .	78

4.3	Exemple constitué des signaux de référence (A) et de test (B) . . . . .	82
4.4	Premier recalage des signaux de référence (A) et de test (B) . . . . .	82
4.5	Deuxième recalage des signaux de référence (A) et de test (B) . . . . .	83
4.6	Enveloppes des signaux de référence (A) et de test (B) . . . . .	83
4.7	Enveloppes lissées des signaux de référence (A) et de test (B) après l'extraction des enveloppes . . . . .	84
4.8	Résultat de la détection pour une plaque avec un défaut à 35 mm . . . . .	85
4.9	Résultat de la détection pour une plaque avec un défaut à 17 mm . . . . .	86
4.10	Estimation de l'angle d'acquisition $\theta$ . . . . .	88
4.11	Estimation de la distance $l$ . . . . .	89
4.12	Algorithme de détection automatique des seuils par apprentissage et adaptation des seuils . . . . .	90
4.13	Classification des extrémités (+) et autres motifs (*). (A) : extrémité $B_1$ , (B) : extrémité $B_2$ . . . . .	91
4.14	Méthode de détection par modèle de référence . . . . .	93
4.15	Exemple de signaux de test et de référence sous incidence angulaire de 20 degré	94
4.16	Estimation des extrémités de la plaque de référence correspondant aux échan- tillons (2) présentés par la figure 4.1. (A) : superpositions des signaux de mesure sous les angles d'incidences allant de $1^\circ$ à $90^\circ$ pour constituer une image B-scan, (B) : résultat obtenu en utilisant l'algorithme de détection et de localisation. . .	95
4.17	Estimation des extrémités et de la position du défaut de la plaque de test ayant un défaut situé à 50 mm de la première extrémité (échantillons (2)), (A) super- positions des signaux de mesure sous les angles d'incidences allant de $1^\circ$ à $90^\circ$ pour constituer une image B-scan, (B) résultat obtenu en utilisant l'algorithme de détection et de localisation. . . . .	96

4.18	Fonction de détection et de diagnostic des défauts de la plaque. (A) fonction de détection pour la plaque saine sous les angles d'incidences allant de 1° à 90°, (B) fonction de détection pour la plaque de test ayant un défaut situé à 50 mm de la première extrémité (échantillons (2)) sous les angles d'incidences allant de 1° à 90° . . . . .	97
4.19	Algorithme de détection de défaut par traitement d'image . . . . .	100
4.20	Signaux de diffusion acoustique en image, (A) les échos temporels en fonction des angles d'incidence, (B) schéma de segmentation de l'image, (C) image de test obtenu. . . . .	102
4.21	Amplitude (A) et histogramme (B) d'une image de test . . . . .	103
4.22	Maximum de l'écho de défaut pour chaque incidence angulaire . . . . .	105
4.23	Illustration de la localisation de défaut . . . . .	106
4.24	Résultats expérimentaux de la méthode proposée. (A) image de test sans défaut, (B) image de test avec une fissure verticale, (C) résultat de la segmentation de (B), (D) élimination des échos d'extrémités de (C), (E) résultat de la binarisation d'image de (D), (F) localisation du maximum de l'écho de défaut. . . . .	108
4.25	Variation de $W_f$ en fonction de la taille de la fenêtre . . . . .	109
4.26	Sélection de la taille optimale de fenêtre pour l'élimination des échos d'extrémités	109
4.27	Échantillon avec une fissure proche de l'extrémité. (A) image de test, (B) résultat de la segmentation, (C) élimination des échos d'extrémités, (D) binarisation de l'image, (E) localisation du maximum de l'écho de défaut . . . . .	110
4.28	choix du seuil de la binarisation de l'image. (A) seuil en fonction du facteur de binarisation, (B) résultat de la binarisation en utilisant différents seuils du haut en bas respectivement pour 0.02,0.1 et 0.15 . . . . .	111

5.1	Schéma général de la détection et du diagnostic de défaut sans modèle de référence dans les plaques métalliques immergées . . . . .	114
5.2	Algorithme d'apprentissage du réseau de neurones à noyau gaussien . . . . .	120
5.3	Projection de l'ensemble $E$ dans le plan (variance, skewness), (A) sans utilisé l'analyse en composantes principales, (B) en utilisant l'analyse en composantes principales . . . . .	123
5.4	Détection des défauts : a) initialisation du réseau ; b) après apprentissage . . . . .	124
5.5	Diagnostic des défauts : domaine d'activation des gaussiennes après apprentissage . . . . .	126
5.6	Procédure de calcul des coefficients d'ondelette pour un défaut vertical sous incidence de $50^\circ$ . . . . .	128
5.7	$P_2$ : (gauche), $P_4$ :( droite) . . . . .	129
5.8	Répartition des échantillons sains et avec fissure verticale sans la transformée en ondelette . . . . .	130
5.9	Répartition des échantillons sains et avec défaut vertical en utilisant la transformée en ondelette . . . . .	131
5.10	Répartition des échantillons issus de la plaque saine et avec défaut oblique sans utiliser la transformée en ondelette . . . . .	132
5.11	Répartition des échantillons de plaque saine et avec défaut oblique en utilisant la transformée en ondelette . . . . .	133
5.12	Influence du nombre de mesures . . . . .	138





## LISTE DES TABLEAUX

4.1	Tableau récapitulatif des erreurs d'estimation de la distance et de l'angle acquisition . . . . .	89
4.2	Influence de la taille $w$ de la fenêtre . . . . .	98
4.3	Tableau récapitulatif de l'influence du seuil $\eta_F$ . . . . .	98
4.4	Résultats expérimentaux de la localisation du défaut pour différents échantillons	111
5.1	Résultats de détection des défauts pour les données d'apprentissage et de validation (Test) . . . . .	125
5.2	Résultats de diagnostic des défauts pour les données d'apprentissage (Appr.) et de validation (Test) . . . . .	127
5.3	Paramètres de la méthode proposée . . . . .	127
5.4	Paramètres des plaques utilisées . . . . .	129
5.5	Matrice confusion : saine et défaut vertical sans transformée en ondelette . . .	131
5.6	Matrice de confusion en utilisant de la transformée en ondelette . . . . .	132
5.7	Matrice de confusion : saine et défaut oblique sans la transformée en ondelette	133

5.8	Matrice de confusion : saine et défaut oblique avec utilisant la transformée en ondelette . . . . .	133
5.9	Paramètres de la méthode proposée . . . . .	134
5.10	Matrice de confusion de la détection du groupe 1 . . . . .	137
5.11	Matrice de confusion du diagnostic du groupe 1 . . . . .	137
5.12	Matrice de confusion de la détection pour le groupe 2 . . . . .	137
5.13	Matrice de confusion de détection du groupe 3 . . . . .	137
5.14	Caractéristiques des différents groupes d'échantillons . . . . .	137

## NOMENCLATURE

$\lambda, \mu$	Coefficient de Lamé
$\nu$	Coefficient de Poisson
$\vec{\psi}$	Potentiel vecteur
$\varphi$	Potentiel scalaire
$c_{Lamb}$	Vitesse de phase des ondes de Lamb
$Ce$	Vitesse de l'onde dans l'eau
$E$	Module de Young
$e$	épaisseur de la plaque



# CHAPITRE 1

## INTRODUCTION GÉNÉRALE

De nos jours, la surveillance des structures concerne de nombreux domaines industriels tels que l'aéronautique, l'automobile, l'énergie, . . . , etc. Devant les contraintes de coût, délai, complexité et d'accessibilité, les techniques utilisées ont connu un fort engouement. Au fil des années, la surveillance est passée d'une simple analyse ou observation humaine à des techniques automatiques. Des efforts considérables ont été réalisés ; les différentes méthodes élaborées permettent d'employer des techniques automatiques/semi automatiques, online/offline ou encore in-situ.

Ces techniques ont porté leurs fruits mais ne tiennent pas compte pour la plupart du temps de l'aspect environnemental du système. C'est le cas des hydroliennes dont le diagnostic se fait toujours hors-immersion et nécessite un arrêt de l'ensemble du système. Cela conduit donc à une intervention invasive sur l'environnement et à une perte en terme de productivité. Les moyens habituellement utilisés pour contrôler l'état de fonctionnement du système comprennent des plate-formes (celles-ci permettent d'amener certains organes à la surface de l'eau), des robots sous marins ou des plongeurs spécialisés en maintenance. Force est de reconnaître que tous ces moyens sont coûteux, pénibles et agressifs pour l'environnement.

Il est donc nécessaire de trouver des techniques pouvant tenir compte à la fois de l'environ-

nement du système (immersion dans l'eau), du coût et du délai de surveillance. Tel est notre objectif. Dans ce contexte, plusieurs techniques peuvent être utilisées, telles que le contrôle par ultrasons, l'émission acoustique, les courants de Foucault, . . . , etc. Ces techniques sont basées sur la génération des ondes guidées à travers la structure et ensuite sur l'analyse des signaux enregistrés. L'information contenue dans ces signaux dépend d'une part de la géométrie de la structure et d'autre part de l'environnement et du signal d'excitation. Dans le domaine du contrôle par ultrasons, technique que nous allons employer, on distingue des ondes de surface et des ondes de volume. Dans cette thèse, seules les ondes de surface sont considérées et en particulier les ondes de Lamb. Ces ondes portent le nom de Horace Lamb [Lamb, 1917] qui les a découvert en 1917 dans le cas d'une plaque.

Depuis, elles ont été largement utilisées. Dans le cas des structures mécaniques, [Deraemaeker and Preumont, 2006] ont introduit la détection des défauts basée sur la vibration des structures en utilisant une matrice de capteurs. [Singh et al., 2003] ont élaboré des stratégies de contrôle modal efficaces pour le contrôle actif des vibrations. De nombreux travaux utilisent ce type de mesures avec des techniques d'écoute passive [Chen et al., 2000, Chin-Hsing et al., 1998]. La détection de défauts dans les plaques a connu un fort engouement et plusieurs travaux ont été réalisés [Ochôa et al., 2015, Harb and Yuan, 2015, Liu and Hong, 2015, Senyurek, 2015, Pai et al., 2015, Li et al., 2014]. Ces avancées, bien qu'elles soient d'une grande importance dans le domaine de la détection de défauts n'ont pas traité les aspects environnementaux de la structure. Ces méthodes utilisent des mesures obtenues par contact avec la plaque, donc restent limitées à des systèmes facilement accessibles. Lorsqu'il s'agit des systèmes en environnement hostiles tels que les hydroliennes, des techniques permettant d'effectuer une analyse sans contact doivent être adoptées.

La méthode proposée permet de générer des impulsions ultrasonores par le biais d'un transducteur. A terme, nous imaginons que ce transducteur pourrait être positionné sous la coque d'un navire. Les impulsions se propagent à travers l'eau et excitent la structure où des ondes de Lamb sont créées. Ces ondes se réfléchissent sur les extrémités de la structure et sont sensibles aux défauts. La motivation de ces travaux est de permettre un contrôle précoce à distance des

défauts mécaniques sur les pales d'une hydrolienne immergée en pleine mer. L'approche proposée facilite l'inspection et devrait contribuer à la planification des opérations de maintenance. Le but de cette étude est d'effectuer la détection des défauts de surface et de classer ces défauts en vue de leur diagnostic sur des plaques métalliques de dimension connue. La propagation de l'onde d'un milieu à un autre fait apparaître des phénomènes de réflexion-transmission (loi de Snell-Descartes). Ce phénomène est observé à chaque extrémité de la plaque [Sidibe et al., 2013c]. Toute anomalie ou inhomogénéité modifie la propagation des ondes. Ainsi, les signaux rétro-diffusés et enregistrés contiennent des informations précieuses capables de caractériser l'état de la plaque et donc d'effectuer une détection et un diagnostic des défauts.

## 1.1 Position du problème

Dans la surveillance des structures immergées, les méthodes développées ont pour but de détecter des défauts quand ils existent. Au cours de cette thèse, nous avons développé une méthode de détection, diagnostic et de classification in-situ par analyse des ondes de Lamb obtenues par échographie ultrasonore. Les signaux traités sont obtenus par excitation de la structure dans une gamme de fréquences précise. Connaissant l'état supposé normal (référence) de la structure, l'objectif est d'analyser les signaux enregistrés pour déduire si la structure présente ou non des défauts. Dans ce cas, il est important de caractériser et de localiser le défaut sur la structure. Compte tenu de la complexité liée à l'exploitation directe des ondes élastiques pour la localisation et la classification, des opérations de post-traitement sont nécessaires, les outils de transformée en ondelettes, d'Hilbert et l'analyse en composantes principales sont utilisés.

## 1.2 Contenu de la thèse

Motivée par l'idée d'exploiter des ondes élastiques guidées pour la détection de défauts dans les structures immergées, la recherche réalisée a permis de développer une technique de



diagnostic in situ, on-line pour des modèles simplifiés d'hélices d'hydroliennes afin de réduire au mieux les contraintes d'accessibilité des données de surveillance pendant le fonctionnement de la station d'hydroliennes. Les opérations de collecte de données, de détection de défauts, de localisation de défauts et de classification sont réalisées par combinaison des outils de traitement du signal et de réseaux de neurones. En effet, les techniques d'Evaluation Non Destructive (NDE) à ultrasons les plus couramment utilisées (par contact) ne sont pas appropriées pour le diagnostic in-situ des structures telles que les hélices d'hydrolienne. De plus, ce travail de recherche consiste à utiliser un seul et unique transducteur sous différents angles contrairement à d'autres techniques qui nécessitent un grand nombre de capteurs et une connaissance précise de leur positionnement. Dans notre étude, les ondes de Lamb sont considérées car elles sont très sensibles aux anomalies structurelles. L'application des ondes de Lamb pour la détection de défauts de structures n'est pas une idée nouvelle. Cependant, il y a plusieurs problèmes pratiques à résoudre, notamment dans l'extraction des caractéristiques significatives.

Contrairement aux travaux antérieurs sur les ondes de Lamb pour l'analyse des défauts de structures, ce travail de recherche met en œuvre certaines techniques avancées de traitement des signaux non stationnaires, qui permettent de révéler les caractéristiques représentatives des signaux. Les informations sont également extraites dans le domaine temps-fréquence pour la classification des défauts structurels potentiels, pouvant causer des dommages graves au cours du temps. Les principales étapes et outils utilisés sont les suivants :

1. Utilisation d'un dispositif de génération et d'acquisition d'ondes de Lamb.
2. Étude approfondie de la propagation d'ondes de Lamb dans les structures en immersion, en particulier dans les plaques métalliques immergées dans l'eau. Caractérisation des signaux pour différents types de défauts.
3. Estimation de l'angle d'acquisition, de la distance (lift-off) du transducteur par rapport au centre de la plaque.
4. Classification des défauts dans les échantillons de laboratoire, en particulier les plaques métalliques et dans une plaque non profilée en forme de croix.

La thèse est composée de quatre chapitres en plus de l'introduction générale.

Dans le chapitre 2, les différentes ondes susceptibles d'exister dans les plaques limitées sont présentées. La théorie de l'élasticité est utilisée pour obtenir les équations des ondes de Lamb symétriques et antisymétriques d'une plaque infinie dans l'eau.

Le chapitre 3 est consacré aux méthodes et outils d'analyse de l'état de santé des plaques immergées. Les méthodes de détection et de diagnostic sans modèle de référence et à base de modèles de référence. Des outils de traitement de signaux tels que la transformée de Hilbert, la transformée en ondelettes continues, l'analyse en composantes principales et les réseaux de neurones gaussiens sont présentés

Le chapitre 4 concerne la détection et le diagnostic de défauts à base de modèle de référence dans une structure métallique immergée. À l'aide d'une mesure monostatique pour exciter nos structures et recueillir les signaux de rétrodiffusion, la signature acoustique de la structure saine est déterminée. Ensuite, ces mesures sont confrontées aux résultats obtenus dans le chapitre 1 afin d'identifier les trajets d'ondes qui se propagent dans la structure.

Le chapitre 5 porte sur la détection et le diagnostic de défauts sans modèle de référence dans une structure métallique immergée. Les réseaux de neurones gaussiens sont utilisés pour la classification des signaux provenant des échantillons d'une même structure. Enfin, des conclusions générales et des perspectives sont présentées à la fin de ce mémoire.



## CHAPITRE 2

# PROPAGATION ET DIFFUSION ACOUSTIQUE PAR UNE PLAQUE LIMITÉE

### 2.1 Introduction

Dans la littérature, de nombreux outils et procédés permettent la génération et la détection d'ondes acoustiques [Sodsri and Choomchuay, 2013, Xingeng and Cunfu, 1997, Newsam and Wegener, 1994, Berer et al., 2012, Li et al., 2009a, Chenu et al., 1995]. Le plus courant est l'utilisation de transducteurs piézoélectriques qui par définition sont des dispositifs permettant la conversion de l'énergie d'une forme donnée à son entrée en une autre forme à sa sortie. En acoustique ultrasonore, la conversion d'énergie la plus fréquente est celle de l'onde mécanique en un signal électrique ou l'inverse. Cette section présente quelques principes de génération d'ondes acoustiques couramment utilisés dans le domaine du Contrôle Non Destructif CND.

### 2.2 Génération d'ondes acoustiques

Au cours de cette thèse, la génération d'ondes est réalisée dans une configuration dite "échographique".

Cette configuration est basée sur l'utilisation d'un seul élément de génération et de réception des ondes. Pour cela, un transducteur à immersion large bande non focalisant de fréquence centrale 200 kHz et de bande passante comprise entre 0 et 400 kHz a été utilisé (figure 2.1).




FIGURE 2.1: Caractéristiques du transducteur utilisé. (A) écho temporel, (B) bande passante correspondante

Les fréquences de coupure basse et haute à -6 dB sont respectivement de 0,074 MHz et 0,286 MHz. Par définition, les ondes de Lamb sont des ondes guidées qui se propagent dans les plaques infinies, homogènes et isotropes. Ce sont des ondes dispersives dont les vitesses de propagation dépendent de la fréquence, de l'épaisseur et des caractéristiques acoustiques du

matériau (vitesses de propagation des ondes longitudinales et transversales).

## 2.3 Propagation d'ondes dans les milieux liquides et solides

La propagation d'une onde nécessite un milieu appelé support. Ce support peut être l'air en basse fréquence, l'eau ou les milieux solides pour les ondes acoustiques. Dans le cas de l'eau, l'onde sonore est une onde de pression. Dans ce fluide, un seul type d'onde peut se propager : c'est l'onde à polarisation longitudinale dont la vitesse égale à  $\frac{1}{\sqrt{\rho\chi}}$ ,  $\rho$  étant la masse volumique du milieu fluide et  $\chi$  le coefficient de compressibilité adiabatique. Dans un solide isotrope, deux types d'ondes se propagent :

- ★ L'onde à polarisation longitudinale ou de compression dont la direction de propagation est parallèle à la direction de vibration,
- ★ L'onde à polarisation transversale ou de cisaillement dont la direction de propagation est perpendiculaire à la direction de vibration.

Les vitesses de propagation de ces deux types d'ondes sont respectivement  $\sqrt{\frac{\lambda+2\mu}{\rho}}$  et  $\sqrt{\frac{\mu}{\rho}}$ ,  $\lambda$  et  $\mu$  étant les coefficients de Lamé. Ces derniers peuvent être exprimés à partir du module de Young  $E$  et du coefficient de poisson  $\nu$  :

$$\lambda = \frac{E\nu}{(1-2\nu)(1+\nu)} \quad (2.1)$$

$$\mu = \frac{E}{1+\nu} \quad (2.2)$$

Dans un solide anisotrope, les constantes élastiques dépendent de la direction considérée. A chaque direction correspond une vitesse longitudinale et une vitesse transversale différentes (par exemple les matériaux composites). Les échantillons de structures utilisés au cours de

cette thèse sont des plaques métalliques inoxydables, homogènes (pour les structures saines) et isotropes. Dans une plaque métallique d'épaisseur  $e = 2h$  immergée dans l'eau (figure 2.2), les ondes de Lamb symétriques et antisymétriques sont générées.

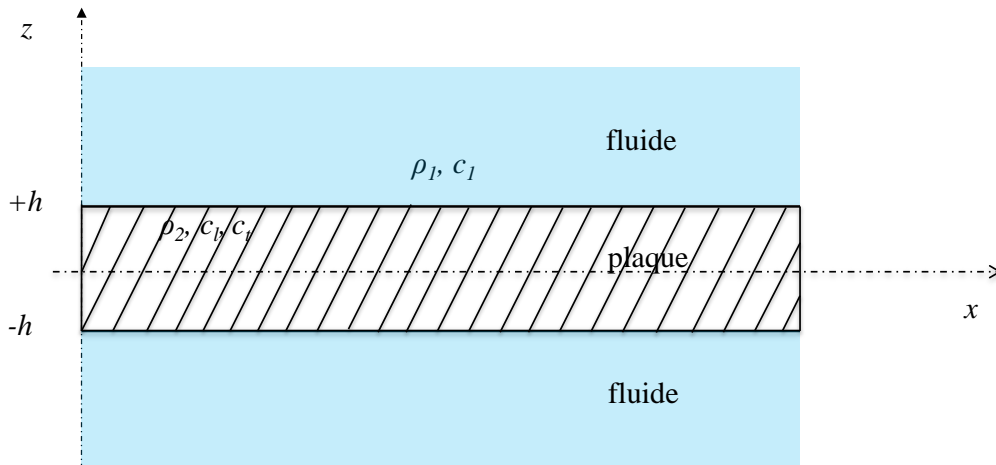


FIGURE 2.2: Plaque métallique immergée dans un fluide

Lorsque le milieu solide est limité, par exemple dans les plaques, des modes guidés peuvent alors se propager : les ondes de Lamb. Ces modes se décomposent en deux types : les ondes à vibrations symétriques  $S_i$  et les ondes à vibrations antisymétriques  $A_i$ . Ces ondes ont une grande importance dans l'étude décrite dans ce mémoire de thèse.

Lorsque les plaques de longueurs infinies sont immergées dans l'eau, ces ondes peuvent être générées sous angle critique  $\theta_c$  défini par la relation de Snell-Descartes (équation 2.3) avec  $\theta_C$  l'angle critique,  $c_e$  la vitesse de propagation de l'onde dans l'eau qui ne dépend pas de la fréquence et  $C_{Lamb}$  la vitesse de phase de l'onde de Lamb qui est fonction de la fréquence. Si cette vitesse de phase est inférieure à la vitesse du son dans l'eau, elle ne peut pas être générée sur une plaque de longueur infinie sans défaut. Si la plaque est de longueur limitée ou/et si des défauts existent, alors l'onde de Lamb peut être générée sur ces défauts soit directement soit après conversion de mode [Cité et al., 2012], [Baillard et al., 2008].

$$\sin \theta_C = \frac{c_e}{C_{Lamb}} \quad (2.3)$$

Dans la littérature, la diffusion des ondes guidées à l'extrémité d'une plaque ou d'un tube a également été étudiée et évaluée à travers des diagrammes angulaires [Fiorito et al., 1979, Maze et al., 2014, Shuyu, 2002, Luppé et al., 1990, Maze et al., 1985].

Afin d'expliquer les phénomènes relatifs à notre cas d'étude, nous considérons les paramètres suivants :  $\rho_1$ ,  $c_e$  respectivement la masse volumique et la célérité du son dans l'eau,  $\rho_2$ ,  $c_l$ ,  $c_t$  respectivement la masse volumique, les vitesses de propagation de l'onde longitudinale et de l'onde transversale dans le matériau de la plaque. Le potentiel de déplacement est donné par l'équation (2.4). Dans notre cas,  $\psi_z = cte$ .

$$\vec{u} = \vec{\nabla}\varphi + \vec{\nabla} \wedge \vec{\psi} \quad (2.4)$$

où  $\varphi$  et  $\psi$  sont respectivement le potentiel scalaire et le potentiel vecteur définis respectivement par les équations 2.5 et 2.6 avec  $\vec{\nabla} \cdot \vec{u}_l = 0$  et  $\vec{\nabla} \wedge \vec{u}_t = 0$ . Soient  $\frac{\partial^2 \varphi}{\partial t^2} - c_l^2 \Delta \varphi = 0$  et  $\frac{\partial^2 \vec{\psi}}{\partial t^2} - c_t^2 \Delta \vec{\psi} = 0$

$$\vec{u}_l = \vec{\nabla}\varphi \quad (2.5)$$

$$\vec{u}_t = \vec{\nabla} \wedge \vec{\psi} \quad (2.6)$$

### Dans la plaque :

En se basant sur la décomposition d'Helmholtz, l'équation 2.6 se décompose en deux parties non couplées et relatives respectivement à l'onde de type longitudinale et à l'onde de type transversale :

$$\frac{\partial^2 \varphi}{\partial x^2} + \frac{\partial^2 \varphi}{\partial z^2} + k_l^2 \varphi = 0. \quad (2.7)$$



$$\frac{\partial^2 \psi}{\partial x^2} + \frac{\partial^2 \psi}{\partial z^2} + k_t^2 \psi = 0. \quad (2.8)$$

Les solutions sont les suivantes :

$$\varphi = F(z)e^{j(\omega t - kx)}, \quad (2.9)$$

$$\psi = G(z)e^{j(\omega t - kx)}. \quad (2.10)$$

Ces solutions obéissent aux équations différentielles :

$$\frac{\partial^2 F}{\partial z^2} - (k^2 - k_l^2)F = 0, \quad (2.11)$$

$$\frac{\partial^2 G}{\partial z^2} - (k^2 - k_t^2)G = 0. \quad (2.12)$$

avec  $k = \frac{\omega}{c_{Lamb}}$ ,  $c_{Lamb}$  étant la vitesse des ondes de Lamb. On posera :  $k^2 - k_l^2 = q^2$  et  $k^2 - k_t^2 = s^2$ . Sous différentes conditions, les solutions peuvent se mettre sous la forme :

★ pour  $(k^2 > k_l^2)$  et  $(k^2 > k_t^2)$  ou  $(c < c_t < c_l)$

$$F(z) = A \sinh qz + B \cosh qz \quad (2.13)$$

$$G(z) = D \sinh sz + E \cosh sz \quad (2.14)$$

★ pour  $(k^2 > k_l^2)$  et  $(k^2 < k_t^2)$  ou  $(c_t < c < c_l)$

$$F(z) = A \sinh qz + B \cosh qz \quad (2.15)$$

$$G(z) = D \sin s'z + E \cos s'z \quad (2.16)$$

★ pour  $(k^2 < k_l^2)$  et  $(k^2 < k_t^2)$  ou  $(c_t < c_l < c)$

$$F(z) = A \sin q'z + B \cos q'z \quad (2.17)$$

$$G(z) = D \sin s'z + E \cos s'z \quad (2.18)$$

où :  $k_l^2 - k^2 = s'^2$ ,  $k_t^2 - k^2 = q'^2$ .  $A$ ,  $B$ ,  $D$  et  $E$  sont des paramètres qui dépendent des conditions aux limites.

**Dans l'eau :**

Seule l'onde de compression existe et se traduit par l'équation suivante :

$$\frac{\partial^2 \phi}{\partial x^2} + \frac{\partial^2 \phi}{\partial z^2} + k_l^2 \phi = 0, \quad (2.19)$$

La solution est du type :  $\phi = H(z)e^{j(\omega t - kx)}$  et obéit à l'équation différentielle suivante :

$$\frac{\partial^2 H}{\partial z^2} - (k^2 - k_l^2)H = 0. \quad (2.20)$$

Les solutions possibles sont les suivantes :

★ pour  $z > 0$

$$H(z) = H_0 e^{-rz}, \quad (2.21)$$

★ pour  $z < 0$

$$H(z) = H_1 e^{rz}. \quad (2.22)$$

où :  $k^2 - k_l^2 = r^2$ ,  $H_0$  et  $H_1$  des paramètres qui dépendent des conditions aux limites. Dans l'ensemble du problème, nous avons six inconnues ( $A, B, D, E, H_0, H_1$ ) à déterminer. Six équations sont donc nécessaires. Les hypothèses suivantes sont considérées en  $z = \pm h$  : en utilisant les conditions aux limites, la continuité des contraintes et des déplacements normaux s'applique à l'interface eau-plaque.

★ Continuité des déplacements :

$$u_z(\text{eau}) = u_z(\text{plaque}) \quad (2.23)$$

avec :

$$u_z = \frac{\partial \varphi}{\partial z} + \frac{\partial \psi}{\partial x} \quad (2.24)$$

★ Continuité des contraintes :

$$T_{ZX}(\text{eau}) = T_{ZX}(\text{plaque}) \quad (2.25)$$

$$T_{ZZ}(\text{eau}) = T_{ZZ}(\text{plaque}) \quad (2.26)$$

avec :

$$T_{zx} = \mu \left( 2 \frac{\partial^2 \varphi}{\partial x \partial z} + \frac{\partial^2 \psi}{\partial x^2} + \frac{\partial^2 \psi}{\partial z^2} \right), \quad (2.27)$$

$$T_{zz} = \lambda \left( \frac{\partial^2 \varphi}{\partial x^2} + \frac{\partial^2 \psi}{\partial z^2} \right) + 2\mu \left( \frac{\partial^2 \varphi}{\partial z^2} + \frac{\partial^2 \psi}{\partial x \partial z} \right). \quad (2.28)$$

Le développement des conditions précédentes dans les cas de propagation de l'onde dans la plaque (équations 2.13, 2.14) et dans l'eau (équations 2.21, 2.22) forme un système de six

équations à six inconnues  $[M][X] = [0]$ .  $X$  est le vecteur colonne composé des paramètres  $A$ ,  $B$ ,  $D$ ,  $E$ ,  $H_0$  et  $H_1$ .  $[M]$  est la matrice suivante :

$$\begin{bmatrix} q \cosh qd & q \sinh qd & -jk \sinh sd & -jk \cosh sd & re^{-rd} & 0 \\ q \cosh qd & -q \sinh qd & jk \sinh sd & -jk \cosh sd & 0 & re^{-rd} \\ -2jkq \cosh qd & -2jkq \sinh qd & -(k^2 + s^2) \sinh sd & -(k^2 + s^2) \cosh sd & 0 & 0 \\ -2jkq \cosh qd & 2jkq \sinh qd & (k^2 + s^2) \sinh sd & -(k^2 + s^2) \cosh sd & 0 & 0 \\ (k^2 + s^2) \sinh qd & (k^2 + s^2) \cosh qd & -2jks \cosh qd & -2jks \sinh sd & Le^{-rd} & 0 \\ -(k^2 + s^2) \sinh qd & (k^2 + s^2) \cosh qd & -2jk \cosh sd & 2jks \sinh sd & 0 & Le^{-rd} \end{bmatrix}$$

avec  $L = \frac{\rho_1 c_1^2}{\rho_2 c_2^2} (k^2 - r^2)$ .

Pour qu'une solution autre que la solution nulle existe, le déterminant du système matriciel doit être nul. Par combinaison des lignes et des colonnes, la matrice peut se mettre sous la forme de deux sous-déterminants indépendants :

$$\begin{bmatrix} -r & q \cosh qd & -jk \cosh sd & 0 & 0 & 0 \\ L & -(k^2 + s^2) \sinh qd & 2jks \sinh sd & 0 & 0 & 0 \\ 0 & -2jkq \sinh qd & -(k^2 + s^2) \cosh sd & 0 & 0 & 0 \\ 0 & 0 & 0 & q \sinh qd & jk \sinh sd & r \\ 0 & 0 & 0 & (k^2 + s^2) \cosh qd & -2jks \sinh(sd) & L \\ 0 & 0 & 0 & -2jkq \sinh qd & -(k^2 + s^2) \cosh qd & 0 \end{bmatrix}$$

Pour que le déterminant soit nul, il suffit que l'un des sous-déterminants soit nul. Cela permet d'obtenir respectivement les vitesses des ondes de Lamb symétriques (équation 2.29) et antisymétriques (équations 2.30) dont les déplacements sont schématisés sur la figure 2.3.




FIGURE 2.3: Modes de Lamb symétriques et antisymétriques

Les courbes de dispersion correspondent à l'évolution des différentes caractéristiques d'un mode en fonction du produit fréquence-épaisseur, telles que les nombres d'ondes  $k$ , la vitesse de phase  $V_\varphi$  et la vitesse de groupe  $V_g$ . Par définition, la vitesse de phase d'une onde est la vitesse à laquelle la phase de l'onde se propage dans l'espace. Un point particulier de l'onde (exemple : la crête) se déplace dans l'espace à la vitesse de phase. Elle s'exprime par l'équation 2.31 avec  $\omega$  la pulsation de l'onde et  $Re(k)$  la partie réelle du vecteur d'onde. La partie imaginaire de  $k$  a un effet uniquement sur l'atténuation de l'amplitude de l'onde. Si plusieurs fréquences sont superposées pour constituer une onde résultante, ce qui est le cas des ondes de Lamb, les vitesses de phase prises séparément peuvent être ignorées. Le paquet d'onde constitué par la superposition des différentes fréquences se propagent à une vitesse globale appelée vitesse de groupe exprimée par l'équation 2.32. Elle représente la vitesse de propagation de l'énergie de l'onde. Pour des ondes non dispersives, la vitesse de groupe est égale à la vitesse de phase. La figure 2.4 représente les courbes de dispersion des vitesses de phase pour les modes de Lamb qui se propagent dans une plaque métalliques homogène. Les différents modes sont repérés par l'indice  $i$  entier allant de 0 à  $n$ . Ainsi les premiers mode de propagation des modes symétriques et antisymétriques sont respectivement  $S_0$  et  $A_0$ .




FIGURE 2.4: Vitesse de phase des ondes de Lamb. (A) symétrique, (B) antisymétrique

$$(k^2 + s^2) \cosh qd \sinh sd - 4k^2qs \cosh sd \sinh qd + \frac{\rho_1 c_l^2 q}{\rho_2 c_l^2 r} (k^2 - s^2)(k^2 - r^2) \sinh qd \sinh sd = 0 \quad (2.29)$$

$$(k^2 + s^2) \sinh qd \cosh sd - 4k^2qs \sinh sd \cosh(qd) + \frac{\rho_1 c_l^2 q}{\rho_2 c_l^2 r} (k^2 - s^2)(k^2 - r^2) \cosh qd \cosh sd = 0 \quad (2.30)$$

$$v\varphi = \frac{\omega}{\text{Re}(k)} \quad (2.31)$$

$$vg = \frac{d\omega}{dk} \quad (2.32)$$

Ce type d'ondes a été largement utilisé dans le domaine du contrôle et de l'évaluation non destructif pour détecter des défauts de structures dans les plaques et les tubes [Lowe et al., 2002, Lowe et al., 1998, Sidibe et al., 2013d]. De nombreux travaux ont été réalisés par l'équipe de l'Imperial College de Londres sur ce sujet. Dans leurs études, un logiciel appelé DISPERSE

a été réalisé pour calculer la vitesse de dispersion des ondes de Lamb dans les structures [Pavlakovic et al., 1997]. Lorsque l'onde se propage d'un milieu à un autre, il y a un phénomène de réflexion et de transmission aux interfaces suivant différentes configurations :

En incidence normale (angle d'incidence  $\theta_i = 90^\circ$ ), il existe une onde transmise et une onde réfléchie (figure 2.5). L'amplitude de l'onde réfléchie change en fonction de la différence d'impédance entre les deux milieux. Si les deux milieux ont des impédances identiques, les ondes sont entièrement transmises.

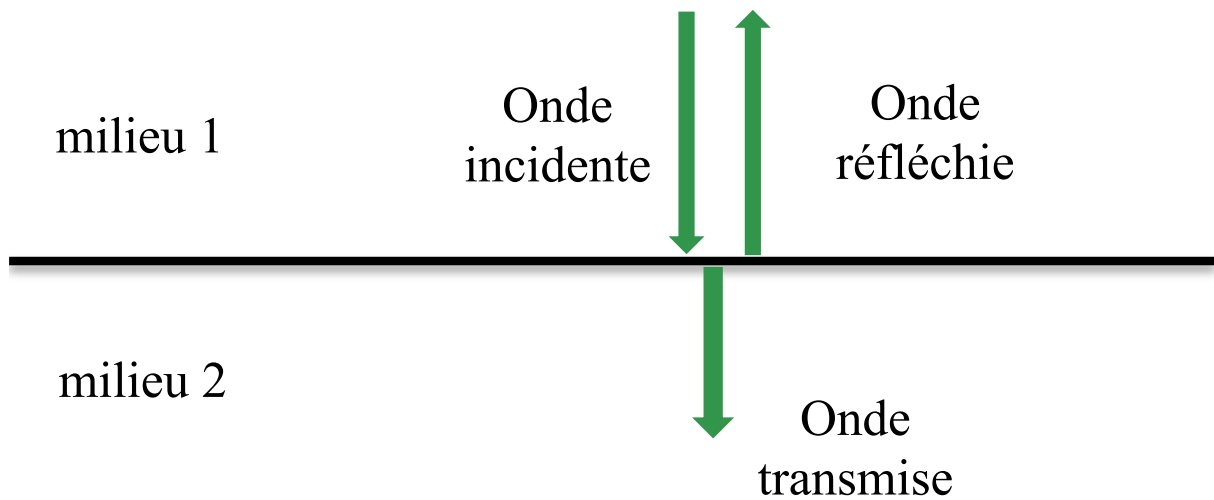


FIGURE 2.5: Configuration en incidence normale

Si le milieu 1 est de l'eau, de l'air ou du gaz et le milieu 2 est solide, la réflexion est totale. En incidence oblique, l'onde incidente donne naissance à deux paires d'ondes longitudinale et transversale en transmission et en réflexion (figure 2.6). La loi de Snell-Descartes s'applique avec  $\theta_{l_1} = \theta_i$ . La notion d'angle critique apparaît avec l'augmentation de l'angle d'incidence  $\theta_i$  qui se traduit par une augmentation des angles de transmission  $\theta_{l_2}$  et  $\theta_{t_2}$  dont la valeur maximale vaut  $90^\circ$ . Les valeurs particulières de l'angle  $\theta_i$  donnant naissance aux angles  $\theta_{l_2} = 90^\circ$  et  $\theta_{t_2} = 90^\circ$  sont appelées angles critiques  $\theta_{l_{2c}}$  et  $\theta_{t_{2c}}$ .

$$\frac{\sin \theta_i}{c_{l_1}} = \frac{\sin \theta_{l_1}}{c_{l_1}} = \frac{\sin \theta_{t_1}}{c_{t_1}} = \frac{\sin \theta_{l_2}}{c_{l_2}} = \frac{\sin \theta_{t_2}}{c_{t_2}} \quad (2.33)$$




FIGURE 2.6: Configuration en incidence oblique

Dans ce travail de thèse, nous exploitons ces connaissances sur la propagation des ondes de Lamb dans les plaques afin d'atteindre les objectifs de détection et de diagnostic de défauts dans un environnement particulier, en l'occurrence "immergé". La dimension des structures considérées permet de satisfaire la condition de propagation des ondes de Lamb dans la plaque. Pour cela l'épaisseur de la plaque est choisie inférieure ou égale à la longueur d'onde de l'onde émise et par hypothèse nous étudions des défauts dont la dimension varie de telle manière que la discontinuité puisse être considérée comme un seul point ou une ligne.

## 2.4 Application aux plaques métalliques immergées dans l'eau

### 2.4.1 Dispositif expérimental

Les structures étudiées sont des plaques métalliques rectangulaires inoxydables. Elles sont suspendues par deux fils de nylon et suspendues à leurs extrémités supérieures dans un réservoir rempli d'eau de 3 m de diamètre et de 2 m de hauteur (figure 2.7). Le transducteur



piézoélectrique  $T$  de fréquence centrale 200 kHz tourne autour de la plaque dans un plan perpendiculaire à la surface de la plaque et par pas de  $1^\circ$  (figure 2.8(A)). À chaque position angulaire  $\theta$ , une série d'émission-acquisitions est réalisée et moyennée. La fréquence d'échantillonnage est  $f_e=10$  MHz et 360 signaux de longueur 10000 points sont enregistrés pour chaque échantillon de plaque. Pour des raisons de symétrie du problème seulement 90 signaux ont été considérés. Les caractéristiques de la plaque sont la vitesse de l'onde longitudinale  $c_l = 5790$  m/s ; la vitesse de l'onde transversale  $c_t = 3100$  m/s. Le milieu ambiant est caractérisé par la vitesse de l'onde ultrasonore dans l'eau  $C_e = 1470$  m/s. La figure 2.8 donne les paramètres géométriques nécessaires à l'élaboration des temps de vol définis par la durée qui sépare l'aller-retour de l'onde du transducteur aux extrémités de la plaque. Les extrémités de la plaque sont appelées  $E_1$  et  $E_2$ . La largeur de la plaque est appelée  $L = E_1E_2$ . La distance entre le défaut et la première extrémité est donnée par  $\delta L$ ,  $\delta \in [0 : 1]$  (figure 2.8(B)).




FIGURE 2.7: Dispositif expérimental

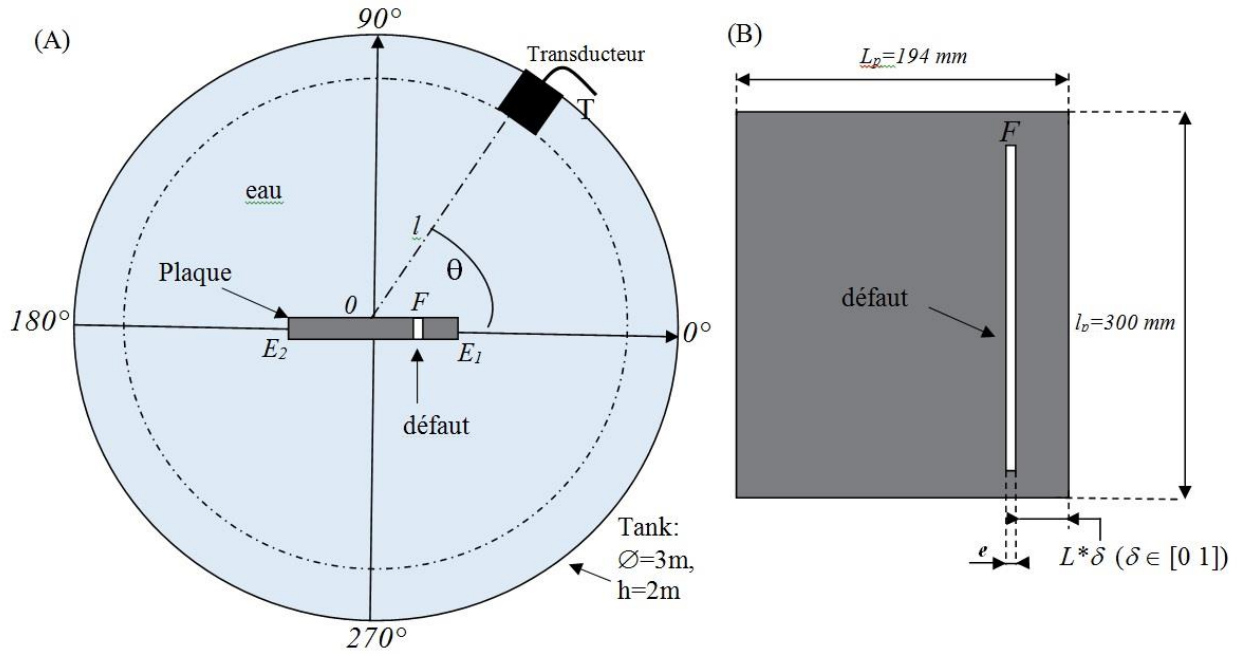


FIGURE 2.8: (A) Schéma simplifié du dispositif expérimental, (B) Exemple de plaque avec fissure

## 2.4.2 Propagation des ondes de Lamb symétriques et antisymétriques

Dans cette section, une attention particulière est portée à la propagation des ondes de Lamb  $A_0$  et  $S_0$ . Les figures 2.9 et 2.10 donnent les courbes de vitesse de phase et de groupe respectivement pour ces deux types d'ondes. Pour l'onde  $S_0$ , la vitesse de phase est quasiment constante dans la plage de fréquences considérées (onde peu dispersive). Elle peut être générée sous incidence critique définie par la loi de Snell-Descartes. L'onde antisymétrique  $A$  est une onde qui apparaît uniquement lorsque la plaque est immergée dans l'eau. Dans ce cas, le mode  $A_0$  de l'onde antisymétrique se découple en deux modes appelés  $A_0^-$  dénommée également  $A$  et  $A_0^+$ . L'onde  $A_0^-$  est celle qui est observable dans le domaine de fréquence de cette étude. Elle se propage avec une vitesse de phase inférieure à celle du son dans l'eau. Elle est générée uniquement aux extrémités de la plaque et permet d'établir un certain nombre de résonances. La deuxième trajectoire est appelée  $A_0^+$  avec une vitesse de phase supérieure à celle du son dans l'eau. Dans notre étude, seules les modes de Lamb  $S_0$  et  $A_0^-$  peuvent se propager. Cela est

dû à la fréquence du transducteur utilisé. La connaissance a priori de leurs vitesses de groupe (figure 2.9(B1) et figure 2.10(B2)) est nécessaire pour déterminer le temps de vol des différents échos lors des étapes de détection et de diagnostic.

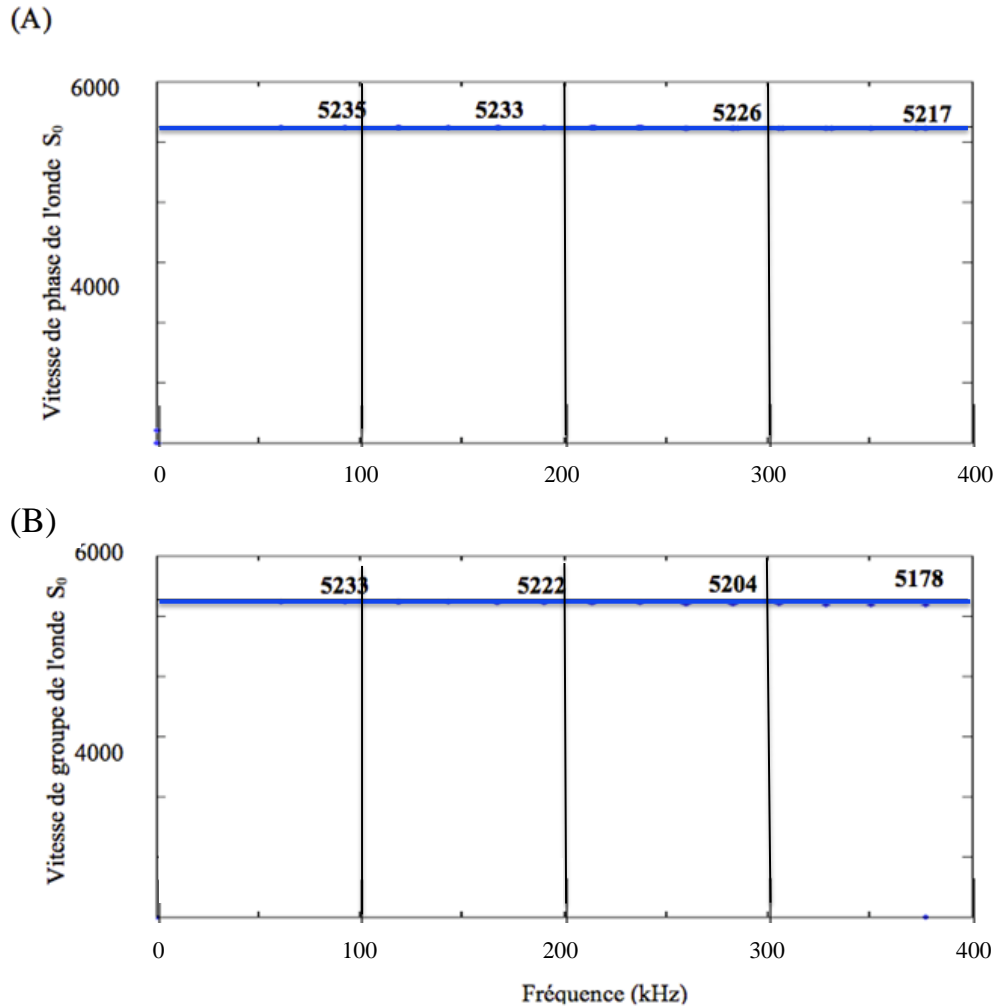


FIGURE 2.9: (A) Vitesse de phase de l'onde  $S_0$ , (B) vitesse de groupe de l'onde  $S_0$ .

### 2.4.3 Calcul du temps de vol pour une plaque saine

Pour une plaque saine de largeur  $L_p=194\text{mm}$ , de longueur  $l_p=300\text{mm}$  et d'épaisseur  $e=1,5\text{mm}$ , les figures 2.11 et 2.12 donnent les temps de vol observés pour des angles d'incidence allant de  $0^\circ$  à  $90^\circ$  avec un pas de  $1^\circ$  (figure 2.8 (B)). Les trajectoires des temps de vol

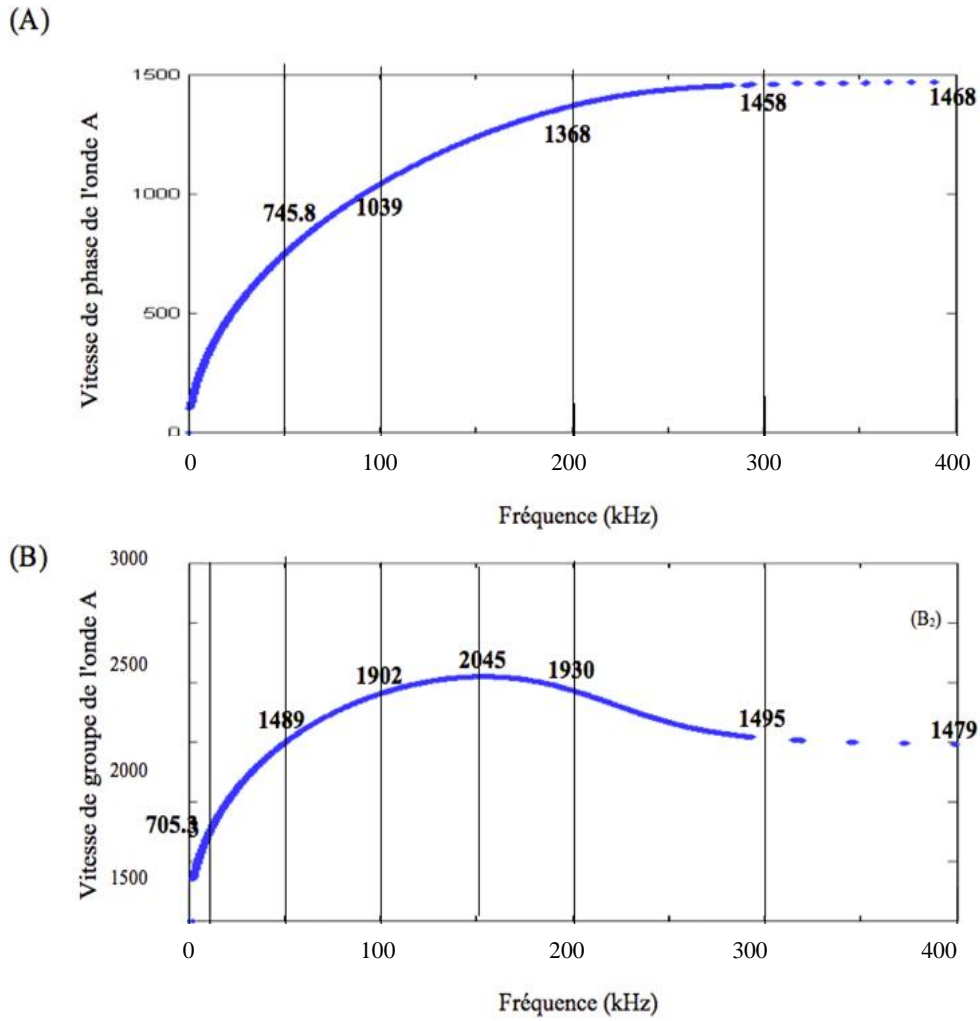


FIGURE 2.10: (A) Vitesse de phase de l'onde A,(B) vitesse de groupe de l'onde A.

des deux échos liés à la diffusion aux extrémités  $E_1$  et  $E_2$  de la plaque sont obtenues à partir des équations 2.34 et 2.35.

Afin de déterminer les autres temps de vol faisant intervenir les propriétés internes de la plaque, les vitesses de groupe utilisés dans les calculs sont  $c_A^{gr} = 2045m/s$  (figure 2.12 B) et  $c_{S_0}^{gr} = 5234m/s$ (figure 2.11 B) respectivement pour l'onde de type A et  $S_0$ . Les valeurs correspondent sont celle obtenues à la fréquence  $f=150$  kHz. Cette fréquence correspond à la fréquence centrale du transducteur utilisé.




FIGURE 2.11: Temps de vol de l'onde  $S_0$

$$t_{E_1} = 2 \frac{\sqrt{l^2 + \frac{L_p^2}{4} - lL_p \cos(\theta)}}{c_e} \quad (2.34)$$

$$t_{E_2} = 2 \frac{\sqrt{l^2 + \frac{L_p^2}{4} + lL_p \cos(\theta)}}{c_e} \quad (2.35)$$

Les trajectoires des temps de vol étiquetées avec (1) dans les figures 2.11 et 2.12 sont obtenues à partir de l'équation 2.36. Les ondes de Lamb  $A$  et  $S_0$  sont générées à l'extrémité  $E_1$  de la plaque, elles se propagent dans la plaque et subissent une réflexion à l'extrémité  $E_2$ . En outre, elles diffusent dans l'eau une partie de l'énergie à partir des extrémités  $E_1$  et  $E_2$ . Le




FIGURE 2.12: Temps de vol de l'onde A

transducteur détecte ensuite le signal temporel rayonné à l'extrémité  $E_1$ . La lettre  $i$  indique le nombre de trajets effectués dans la largeur  $E_1E_2$  de la plaque.

Les trajectoires des temps de vols étiquetés avec (2) sont obtenues à partir de l'équation 2.37. Dans ce cas, les ondes de Lamb A et  $S_0$  sont générées à l'extrémité  $E_1$  (ou  $E_2$ ) de la plaque, elles se propagent dans la plaque jusqu'à l'extrémité  $E_2$  (ou  $E_1$ ) où elles rayonnent dans l'eau en direction du transducteur. La lettre  $j$  qui prend les valeurs 1, 3, 5..., indique le nombre de trajets  $E_1E_2$  (ou  $E_2E_1$ ) effectués. Les trajectoires des temps de vols étiquetées avec (3) sont obtenues à partir de l'équation 2.38. Les ondes de Lamb A et  $S_0$  sont générées à l'extrémité  $E_2$  de la plaque, se propagent dans la plaque et subissent une réflexion à l'extrémité

$E_1$ . Ensuite, elles diffusent dans l'eau une partie de son énergie à partir des extrémités  $E_1$  et  $E_2$ . Le transducteur détecte les signaux temporels diffusés à l'extrémité  $E_2$ . La lettre  $i$  désigne le nombre de trajets  $E_2E_1$  effectués pour une onde  $S_0$ (2.11) ou une onde  $A$ (2.12).

$$t = 2t_{E_1} + 2i \frac{L_p}{c_{A,S_0}^{gr}}. \quad (2.36)$$

$$t = t_{E_1} + j \frac{L_p}{c_{A,S_0}^{gr}} + t_{E_2}. \quad (2.37)$$

$$t = 2t_{E_2} + 2i \frac{L_p}{c_{A,S_0}^{gr}} \quad (2.38)$$

#### 2.4.4 Calcul du temps de vol pour une plaque avec une rainure

Considérons une plaque avec une rainure, insonée par un transducteur comme le montre la figure 2.8 B. Sous les conditions expérimentales précédemment définies, les trajectoires des temps de vol correspondant aux extrémités  $E_1$  et  $E_2$  (équations 2.34, 2.35) restent toujours observables. En plus de ces trajets, la rétrodiffusion directe de l'onde par la rainure est également enregistrée. Ce trajet se traduit par l'équation 2.39.

$$t_F = 2 \frac{\sqrt{l^2 + (\delta - \frac{1}{2})^2 L_p^2 + 2lL_p (\delta - \frac{1}{2}) \cos(\theta)}}{c_e} \quad (2.39)$$

Néanmoins, des trajectoires particulières apparaissent en raison de la présence de la rainure (figure 2.13). Ces trajets peuvent être classés en deux grandes catégories. La première catégorie est celle faisant intervenir la distance entre l'extrémité la plus proche de la plaque ( $E_1$ ) et le défaut (figure 2.13 (D),(F)). La deuxième catégorie est celle portant sur la distance entre l'extrémité la plus éloignée du transducteur ( $E_2$ ) et le défaut (figure 2.13 (C),(E)). Rappelons toutefois que ces deux catégories de trajets d'ondes se produisent avec une onde de type symétrique  $S_0$  ou antisymétrique  $A_0^-$  et coexistent dans le signal de rétrodiffusion enregistré par




FIGURE 2.13: Parcours de l'onde dans l'eau et dans la plaque en présence de défaut

le transducteur. Ce signal est complexe et difficile en terme de représentation et d'exploitation. Pour ces raisons, l'exploitation des signaux enregistrés sera limitée à une plage utile donnée par la figure 2.14.

Cette plage utile est limitée par la réflexion de l'onde sur les extrémités  $E_1$  et  $E_2$  de la plaque. Le temps de vol est donné par l'équation 2.39. Cette trajectoire est repérée dans la plage utile.

### 2.4.5 Plage d'angles d'incidence maximum

En utilisant les équations des temps de vol des échos extrémités de la plaque et au défaut (équations 2.34, 2.35, 2.39), une plage angulaire  $[\theta_{inf} : \theta_{sup}]$  peut être établie. Cette plage est obtenue en se basant sur l'hypothèse donnée par l'équation 2.40. Les équations 2.41 et 2.42






FIGURE 2.14: Trajectoires des temps de vol des ondes dans une plaque avec rainure ( $F$ )

traduisent les limites inférieure et supérieure de cette plage en fonction du rapport  $L/2l$ .

$$t_{E_1} < t_F < t_{E_2} \quad (2.40)$$

La connaissance de cette plage est nécessaire avant toute opération de détection ou de diagnostic. En pratique, on évitera les angles à  $\pm 10\%$  de l'incidence normale ( $90^\circ$ ).

$$\theta_{inf} = \arccos\left(\frac{L}{2l}(1 - \delta)\right) \quad (2.41)$$

$$\theta_{sup} = \arccos\left(\frac{L}{2l}\delta\right) \quad (2.42)$$

La figure 2.15 présente la variation des limites inférieure et supérieure de cette plage en




FIGURE 2.15: Plage d'incidence angulaire à éviter  $\delta$  pour différentes valeurs du rapport  $L/2l$

fonction de  $L=2l$  dans l'intervalle  $[0 :1]$  avec un pas de 0,07. Cette plage varie aussi en fonction de l'orientation du défaut par rapport à la direction du faisceau des signal incidents émanent du transducteur.

## 2.5 Conclusion

Dans ce chapitre, la propagation des ondes dans une plaque a été présentée. Les temps de vol des échos des trajets susceptibles d'apparaître ont été déterminés. La nécessité d'interdire certains angles d'incidence a été montrée afin de réduire les erreurs dans la phase de décision. La présence d'un défaut a également été abordée et conduit à l'apparition de nouveaux trajets. Dans la suite de nos travaux, nous nous proposons d'exploiter ces notions afin de détecter d'éventuels défauts dans les structures immergées plus ou moins complexes. Des comparaisons seront réalisées dans l'identification des trajets d'ondes servant à la détection et au diagnostic

de défauts. Des outils de traitement de signal seront associés aux réseaux de neurones dans le but d'automatiser les tâches de détection et de diagnostic.

## CHAPITRE 3

# MÉTHODES ET OUTILS D'ANALYSE DE L'ÉTAT DE SANTÉ DES PLAQUES IMMERGÉES

### 3.1 Introduction

Par définition, le diagnostic est l'identification de la cause probable des défaillances à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test (AFNOR). Quant à la détection, elle forme une étape en amont du diagnostic et permet de déterminer la présence ou non d'un défaut sur le procédé. A ces deux définitions s'ajoute une étape importante qui est la prise de décision. Cette opération nécessite la connaissance d'un certain nombre de règles. Elle est autant utile avant le diagnostic qu'après (choix de capteur, positionnement sur l'organe à surveiller, programmation d'une intervention, arrêt du système,...,etc). Une fois la détection réalisée, il est parfois nécessaire de procéder à une classification des défauts. Cette opération peut être réalisée avec des réseaux de neurones artificiels présentés dans la section sur les outils de traitement de signaux.

Les procédures de détection et de diagnostic sont abordées de différentes manières. Selon la nature du problème et des objectifs recherchés, ces deux tâches peuvent être effectuées simultanément ou séquentiellement. Dans les travaux présentés dans cette thèse, les deux tâches sont

réalisées séquentiellement comme dans [Bentoumi, 2004]. Par ailleurs, ces opérations peuvent se classer en deux grandes familles : la détection et le diagnostic par modèle de référence et sans modèle de référence. Ces deux approches ont été utilisées dans nos différents travaux et seront détaillées dans les prochains chapitres.

L'organisation de ce chapitre est la suivante. La deuxième section porte sur les méthodes de détection et de diagnostic sans modèle de référence. La troisième section est consacrée aux méthodes de détection et de diagnostic avec modèle de référence. Quelques outils de traitement des signaux acoustiques sont donnés dans la quatrième section. Enfin la dernière section est réservée à la conclusion.

## **3.2 Méthodes de détection et de diagnostic sans modèle de référence**

Les méthodes de détection et de diagnostic sans modèle de référence sont employées pour des systèmes dont le modèle comportemental est difficile à obtenir. Elles reposent sur l'utilisation des données obtenues à partir du système et des données issues de l'expertise humaine (intelligence artificielle, reconnaissance de formes, logique floue, systèmes experts ou à base de connaissances). Dans cette section, quelques méthodes de diagnostic sans modèle a priori sont présentées.

### **3.2.1 Méthodes de détection à base de reconnaissance des formes**

L'objectif de cette méthode est de reproduire les capacités de l'homme à reconnaître des caractères, des objets, des sons ou des signaux temporels. Au départ, cette technique a été utilisée en traitement de signal pour détecter la présence d'un signal ou identifier de multiples sources. L'être humain possède naturellement cette capacité, il reconnaît des visages, des sons ou des formes et cela indépendamment des conditions d'observation. Ainsi, la reconnaissance de formes s'inspire d'une part des connaissances sur la perception humaine et d'autre part

de la collecte d'un maximum de données différentes pour extraire des identifiants caractéristiques des différentes formes. En d'autres termes, il s'agit de définir à quelle classe une forme observée ressemble le plus. Pour cela, il est possible d'utiliser une représentation sophistiquée des formes nécessitant des connaissances explicites sur le domaine d'application ou d'exploiter directement les données sans a priori. Dans un problème de reconnaissance des formes, on suppose que les formes à classer appartiennent à des classes données. Elles forment un nuage de points dans l'espace des paramètres. Selon la ressemblance des formes à classer, des zones d'ambiguïté peuvent apparaître entre les différentes classes. Les principales étapes du système de reconnaissance de formes sont données par la figure 3.1.

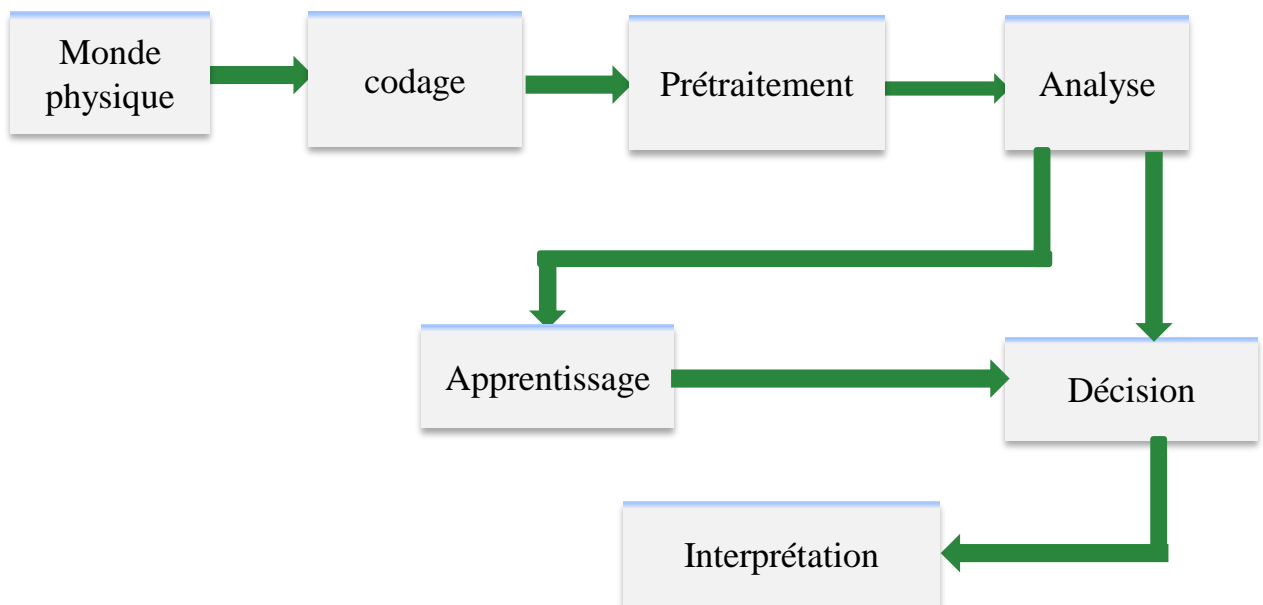


FIGURE 3.1: Système de reconnaissance de formes

Le codage permet de passer de l'espace des formes analogiques à l'espace des représentations discrètes. Le prétraitement est l'ensemble des traitements effectués sur les vecteurs de l'espace discret tels que le filtrage, la normalisation, le seuillage, le rehaussement de contraste et la suppression des redondances. L'étape d'analyse consiste à calculer des caractéristiques, à déterminer et à extraire les indices pour passer de l'espace des représentations à l'espace des paramètres. La phase d'apprentissage consiste à exploiter les connaissances a priori issues de

l'espace des paramètres pour la préparation de l'espace de projection des données de validation. L'étape de décision consiste soit à classer les nouvelles données avec ou sans ambiguïté soit à les rejeter.

Selon le dispositif expérimental présenté dans le chapitre précédent (Propagation et diffusion acoustique par une plaque limitée), plusieurs trajets d'ondes existent dans un enregistrement donné. En plus, le contenu de l'enregistrement diffère selon l'angle d'acquisition. Par exemple la forme de l'écho des extrémités et de défaut n'ont ni la même forme, ni la même amplitude suivant les angles. Donc les méthodes basées sur la classification et la reconnaissance de formes peuvent être considérées en priorité.

Au cours de cette thèse, nous utilisons comme classifieur les réseaux de neurones. Pour cela, la construction d'une base de connaissance sur les différents états (sains et défaillant) des structures étudiées est nécessaire. Cette base de données contient de précieuses informations permettant au réseau de neurones de réaliser les opérations de détection et de diagnostic. La performance de détection et de diagnostic dépend de la richesse de la base de connaissance. Une partie des données de la base est utilisée pour l'apprentissage du réseau et le reste est utilisé dans l'étape de validation. Cette dernière étape réalise une classification automatique des données de la base de connaissance [Chen et al., 2000, Chin-Hsing et al., 1998, Sidibe et al., 2013c, Sidibe et al., 2013b]. Les données de la base sont attribuées à des classes construites lors de l'apprentissage et chaque classe caractérise un état de la structure.

Lorsque la classification sépare les états sains et défaillants du système, on parle de détection. Par contre, lorsqu'elle sépare plusieurs classes de défauts du système, on parle de diagnostic. Les résultats de détection et de diagnostic sont représentés dans un tableau appelé matrice de confusion dont la diagonale représente le taux de bonne classification. Les performances du réseau peuvent être évaluées durant l'étape d'apprentissage et de validation.

L'avantage d'utiliser les réseaux de neurones réside dans leurs capacités à prendre des décisions en ayant une faible quantité de connaissances sur le système. L'un des inconvénients des réseaux de neurones est la nécessité d'une bonne connaissance des défaillances. Pour cela,

plusieurs essais s'imposent dans le but de prendre en compte un maximum d'états possibles du système. Mais, force est de reconnaître qu'il est impossible de répertorier tous les états possibles de dysfonctionnement. Cela traduit une limite d'utilisation de cette méthode.

### **3.2.2 Méthode de détection à base de système expert**

La méthode des systèmes experts est la plus répandue pour la supervision des systèmes complexes. Ce sont des outils de l'intelligence artificielle, utilisés lorsqu'aucune méthode algorithmique exacte n'est adoptée. Ainsi, un spécialiste réalise son diagnostic à l'aide d'une description partielle de la situation. En se basant sur l'historique des diagnostics du système, il peut élaborer de nouvelles mesures, déduire les conclusions possibles et approfondir son diagnostic avec de nouvelles informations issues du système étudié. Un système expert est défini comme étant "un système informatique destiné à résoudre un problème précis à partir d'une analyse et d'une représentation des connaissances et du raisonnement d'un spécialiste. Dans la plupart des cas, les connaissances utilisées pour le développement d'un système expert d'aide au diagnostic, reposent sur l'apprentissage des relations entre les causes et les effets observés pour chaque défaillance du système [Martin, 1999]. Un système expert est constitué essentiellement de deux parties indépendantes (figure 3.2).

#### **La base de connaissances**

C'est la partie stable du système, elle est composée d'une base de faits qui contient les informations, les données concernant le cas traité et d'une base de règles connues qui modélisent la connaissance du domaine considéré.

#### **La base d'inférence**

Cette base exploite de façon indépendante les informations contenues dans la base de faits, donc dans la base de connaissances, pour fournir une solution au problème posé. Par ailleurs, la base d'inférence produit dans son mécanisme de raisonnement de nouveaux faits qui sont mémorisés dans la base de faits. La base d'inférence utilise les données et les règles pour produire de nouvelles données. Le rôle d'un système expert est donc d'inférer des règles du



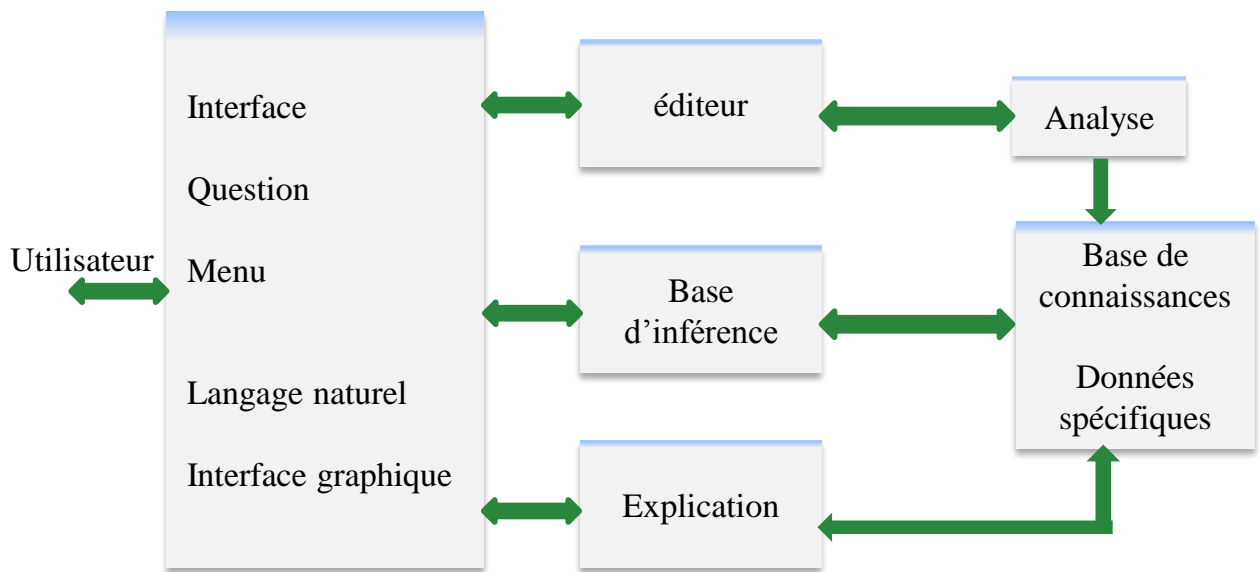


FIGURE 3.2: Structure d'un système expert de diagnostic

type : SI [A="vrai"] ET [A implique B] ALORS [B="vrai"]. L'application des règles entraîne la déduction des nouveaux faits se rajoutant à la base de faits. Le diagnostic par systèmes experts se fonde sur l'expérience disponible sur le système pour construire une table de correspondance qui associe les observations aux diagnostics correspondants [Engin et al., 2014]. L'avantage de cette méthode se situe au niveau de sa simplicité de mise en œuvre et de son efficacité en terme de temps de calcul. L'expérience dont dépendent ces approches est cependant difficile à acquérir et si le système évolue, les règles sont à remettre en cause. Une nouvelle expertise est alors nécessaire.

### 3.3 Méthodes de détection à base de modèle de référence

Développées à partir des années soixante-dix, ces méthodes occupent une place importante dans la détection de défauts des systèmes dynamiques. Elles sont basées sur un modèle mathématique du système. Contrairement aux méthodes de détection et de diagnostic sans modèle de référence, elles ne nécessitent pas d'essais multiples dans l'étape de la construction de la base

de connaissance. Parmi les travaux antérieurs utilisant ces méthodes on peut citer [Xiaoyan et al., 2011] qui ont réalisé une méthode de diagnostic basée sur les modes de vibration de la structure. Le diagnostic local de défaut est réalisée en fonction du déplacement de la fréquence modale et a servi pour traduire l'occurrence de défauts. [Torabi et al., 2012] ont réalisé une méthode de classification basée sur la surveillance en ligne des processus de fraisage à haute fréquence. Pour la mise en œuvre du système de surveillance d'état, des signaux issus du processus d'usinage sont utilisés pour construire un modèle de référence traduisant le fonctionnement du système de façon non intrusive. En outre, la méthode à base de modèle de référence fait également intervenir les techniques de génération de résidus dans les procédures de détection, de diagnostic et de localisation de défauts. La figure 3.3 montre le principe de génération de résidus par modèle de référence. La génération des indicateurs qui contiennent des informations sur les défauts ou dysfonctionnements est la première étape à réaliser. Le principe consiste à mesurer l'écart entre les signaux du procédé, capteurs ou actionneurs, et la valeur théorique fournie par le modèle dans des conditions de fonctionnement nominal. La génération de résidus constitue une étape clef pour assurer les performances des procédures de détection, de localisation et de de diagnostic. Dans la littérature, on distingue trois approches pour la génération de résidus [Frank and Köppen-Seliger, 1997] : les approches par l'estimation de paramètres, les approches par les espaces de parité et les approches à base d'observateurs d'états. Dans l'approche que nous proposons au cours de cette thèse, un modèle de trajets des ondes existe, qui peut servir de point d'ancrage pour la mise en place d'une méthode à base de modèle de référence par génération de résidus.

### **3.3.1 Génération de résidus par estimation paramétrique**

Initialement développées par les automaticiens pour identifier les systèmes industriels, cette approche s'applique dans les cas où l'utilisateur désire surveiller l'évolution de certains paramètres critiques (débit de fuite, polarisation) pour le fonctionnement du système. Elle se base sur le principe d'estimation de ces paramètres afin de détecter les écarts par rapport à des




FIGURE 3.3: Principe de génération de résidus par modèle de référence

valeurs nominales (figure 3.4). Les premiers travaux basés sur cette approche sont les œuvres de [Isermann, 1993, Isermann, 2005, Kimmich et al., 2005].

La modélisation mathématique de cette approche est exprimée par l'équation 3.1 dans laquelle  $u(t)$  représente les commandes du système et  $\theta$  les paramètres du modèle.  $\theta$  dépend des paramètres physiques  $p$  du modèle par la relation  $\theta = g(p)$  et tout changement des paramètres physiques  $p$  traduit une variation des paramètres  $\theta$  du modèle. Le vecteur des résidus est obtenu en faisant la différence entre les paramètres estimés et les valeurs nominales soit à partir des paramètres physiques (équation 3.3) ou à partir des paramètres du modèle (équation 3.2).

$$y(t) = f(u(t), \theta) \quad (3.1)$$

$$r_{\theta}(t) = \theta - \tilde{\theta}(t) \quad (3.2)$$

$$r_p(t) = p - \tilde{p}(t) \quad (3.3)$$

### 3.3.2 Approche de génération de résidus par les espaces de parité

Par définition, l'espace de parité est un espace dans lequel toutes les variables inconnues ont été éliminées. C'est l'une des méthodes de diagnostic à base de modèle explicite les plus




FIGURE 3.4: Principe de génération de résidus par estimation de paramètres

connues [Li et al., 2009b, Ye et al., 2004, Hong-xu et al., 2010, Lee et al., 2012, Hu et al., 2013, Izadi et al., 2008, Tellili et al., 2004]. Elle est basée sur l'utilisation des outils de l'algèbre linéaire, notamment les projections matricielles pour générer les résidus dans le cas des systèmes linéaires. Les équations du modèle sont projetées dans l'espace de parité afin d'éliminer les inconnues à l'aide de redondances. Les équations projetées aussi appelé relations de redondance analytique ou relations de parité ne font intervenir que des variables mesurables (les entrées et les sorties du système) sur une fenêtre d'estimation. Le terme vecteur de parité est souvent employé pour désigner le vecteur des résidus  $x(k)$ . Les relations de parité sont des

relations comportementales statiques ou dynamiques existant entre les grandeurs mesurées. Cette approche a été initialement proposée dans le cas d'une redondance matérielle par [Evans et al., 1969], puis étendue dans le cas de la redondance analytique.

### 3.3.3 Génération de résidus par estimation d'état

Le principe de base reposant sur l'estimateur d'état d'un système est la reconstruction de l'état du système en fonction des mesures de ses entrées et sorties. L'estimation des variables d'état est obtenue à partir des grandeurs d'entrée et de sortie du système. Cela peut se faire par le biais des observateurs [Luenberger, 1971, Adjallah, 1993] dans le cas déterministe ou de filtres dans le cas stochastique (filtre de Kalman [Willsky and Jones, 1976, Nagatsu and Katsura, 2013] ou filtres détecteurs de défauts [Massoumnia, 1986]). Les deux méthodes présentent des analogies dans leur formulation et peuvent être synthétisées par la figure 3.5, leurs différences proviennent du mode de calcul des paramètres de reconstruction en fonction du contexte choisi (continu ou discret, déterministe ou stochastique). Un observateur est un système dynamique qui fournit en sortie une estimation de l'état du processus à partir des entrées, des sorties et du modèle du système et ce, au moyen d'une correction proportionnelle à l'écart entre la sortie mesurée et celle estimée. Le gain de correction pour l'observateur de Luenberger est obtenu en imposant une vitesse de convergence de l'erreur d'estimation. Quant au filtre de Kalman, il exploite les propriétés statistiques du système en vue d'obtenir le gain de correction optimal minimisant la variance de l'erreur d'estimation. La reconstruction d'état pour les systèmes caractérisés par un modèle LTI semble avoir atteint une certaine maturité et nombreux sont les algorithmes de synthèse disponibles.

## 3.4 Outils de traitement des signaux

Dans la littérature, de nombreux outils sont utilisés pour traiter de manière efficace les signaux provenant d'un processus physique. Ces signaux sont porteurs d'informations lors-

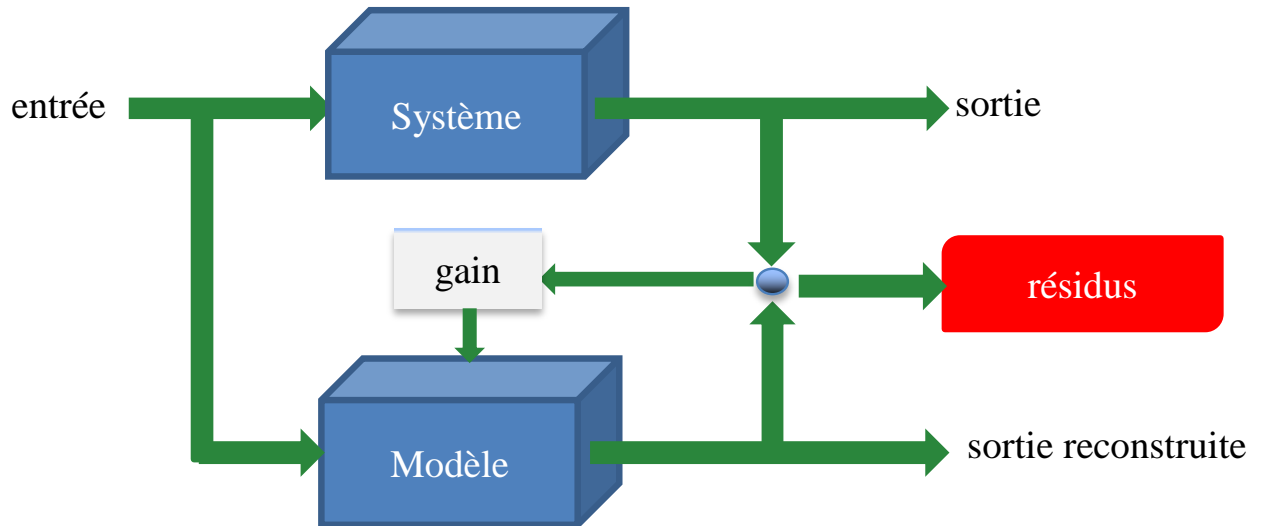


FIGURE 3.5: Principe général d'un estimateur d'état

qu'ils sont acquis de manière conforme aux propriétés physiques et mécaniques de la structure (condition de non destruction) et respecte la bande de fréquence autorisée. Cependant, les outils utilisés sont liés à la nature du signal traité : numérique, analogique, périodique, apériodique, aléatoire, déterministe, harmonique,...,etc. Cette section propose quelques outils de traitement de signal couramment utilisés dans le cadre de la détection et du diagnostic de défauts dans les structures immergées. Parmi ceux ci, une attention particulière est portée aux réseaux de neurones artificiels qui présentent une grande capacité à traiter les signaux indépendamment de leurs natures.

### 3.4.1 Transformée de Hilbert

A tout signal  $x(t)$  réel, on peut associer un signal analytique complexe  $Z_x(t)$  (équation 3.4).  $x(t)$  est la partie réelle du signal de  $Z_x(t)$  et  $H(x(t))$  sa partie imaginaire défini par la transformée de Hilbert de  $x(t)$ .  $x(t)$  et  $H(x(t))$  sont en quadrature de phase.  $H(x(t))$  est définie par l'équation 3.5. C'est une opération de filtrage du signal  $x(t)$  par un système linéaire de réponse impulsionnelle  $g(t) = \frac{1}{\pi t}$ . Il est possible d'exprimer la fréquence instantanée (équation 3.7) et l'amplitude instantanée appelée enveloppe (équation 3.6) du signal. Ces deux paramètres

contiennent souvent des informations pertinentes pouvant être noyées dans le reste du signal. Dans la littérature, cet outil a été d'une grande importance pour la détection de défauts dans les organes tournants tels que les roulements, les engrenages, ..., etc. Il a été utilisé par [McFadden, 1986] pour la détection des fissures dans les engrenages. La technique utilisée porte sur la démodulation d'amplitude et de phase des signaux enregistrés sur les engrenages en fonctionnement. Parmi les travaux de diagnostic de défauts exploitant les signaux acoustiques en utilisant la transformée de Hilbert, on peut citer [Feldman, 2011, Yu et al., 2007, Xun and Yan, 2008] qui ont utilisé cet outil pour construire une autre transformation appelée Hilbert Huang Transform en anglais. Cette méthode permet de décomposer un signal en plusieurs modes de vibration. Cela est très utile dans le traitement des signaux acoustiques obtenus par superposition de plusieurs modes de vibration de la structure. La figure 3.7 donne la décomposition en cinq modes de vibration du signal de rétrodiffusion d'une plaque de largeur 60 mm et d'épaisseur 1.5 mm sous 10° d'incidence. Ce type de décomposition permet la détection d'un événement tel que l'impact d'un défaut dans le signal enregistré à partir d'une structure donnée. Les événements lents tels que la corrosion ou l'effet de vieillissement peuvent être observés pour des modes de vibration plus élevées donc pour de faibles fréquences. Par contre, les changements brusques dans le signal traduisant un événement rapide tel que l'apparition d'une fissure suite à un impact violent sont observés pour des modes d'ordre plus petit correspondant aux fortes fréquences. Le choix du nombre de modes ainsi que le type de phénomène recherché sont très importants dans l'utilisation de cette méthode.

$$Z_x(t) = x(t) - jH(x(t)) \quad (3.4)$$

$$H(x(t)) = VP \left\{ \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau = \int_{\infty}^{+\infty} g(t - \tau)x(\tau) d\tau \right\} \quad (3.5)$$

$$e(x(t)) = |z(t)| \quad (3.6)$$

$$f(x(t)) = \frac{1}{2\pi} \frac{d(\arg Z_x)}{dt}(t) \quad (3.7)$$

L'extraction d'enveloppe en utilisant la transformée de Hilbert d'un signal donné est montrée par la figure 3.6.




FIGURE 3.6: Signal de rétrodiffusion d'une plaque et son enveloppe extraite par transformée de Hilbert

### 3.4.2 Transformée en ondelettes continues

Dans un signal, l'information utile est souvent contenue en même temps dans les fréquences émises et dans la structure temporelle du signal. A cet effet, la représentation qui ne tient






FIGURE 3.7: Décomposition en 5 modes de vibration du signal de rétrodiffusion d'une plaque de largeur  $60\text{mm}$  et d'épaisseur  $1.5\text{mm}$  sous  $10^\circ$  d'incidence

compte que de l'un des aspects (temporel ou fréquentiel) traduira mal l'autre. Ainsi, il devient alors nécessaire de combiner temps et fréquence pour avoir une représentation complète riche en information. Contrairement à la transformée de Fourier classique, la transformée en ondelettes continues est une technique de traitement du signal permettant une décomposition spectrale locale. Elle est adaptée au traitement de signaux de type périodique ou non, ayant des transitions rapides ou des discontinuités. La décomposition d'un signal  $x(t)$  par une ondelette  $\psi(t)$  est donnée par l'équation 3.8. La décomposition en ondelettes continues est définie comme la somme sur le temps du signal multiplié par l'échelle et les versions décalées de la fonction ondelette mère  $\psi(t)$  avec  $a$  l'échelle et  $b$  la position. L'avantage de la transformée en ondelettes se situe au niveau de l'utilisation des fonctions analysantes bien localisées, à support compact

et ne présentant que quelques oscillations. Ceci permet d'accéder à la décomposition en échelle grâce à une dilatation ou contraction purement géométrique à partir de l'ondelette mère (3.9). La figure 3.8 donne l'ondelette mère de Morlet. Le choix de l'ondelette mère est l'une des clés de la bonne utilisation de la transformée en ondelettes.

$$CWT_x^\psi = \frac{1}{\sqrt{a}} \int_{[t_{E1}:t_{E2}]} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (3.8)$$

$$\psi(j, k) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{t - 2^j k}{2^j}\right) \quad (3.9)$$




FIGURE 3.8: Exemple d'ondelette mère : Morlet

### 3.4.3 Normalisation

Dans l'utilisation des réseaux de neurones, la normalisation permet d'observer l'évolution sur une même plage de caractéristiques extraites d'une structure donnée. Chaque caractéristique de la base est normalisée, composante par composante, entre 0 et 1, par rapport aux valeurs minimale et maximale  $x_{MIN}^k$  et  $x_{MAX}^k$ . Pour chaque composante  $x_r^k$ ,  $k = 1, 2$ , la normalisation est réalisée selon l'équation 3.10. Les échantillons normalisés forment la base réduite normalisée  $E_{RN}$ .

$$x_n^k = \frac{x_r^k - x_{Min}^k}{x_{Max}^k - x_{Min}^k} \quad (3.10)$$

### 3.4.4 Analyse en composantes principales

L'analyse en composantes principales (ACP) est une technique statistique permettant d'obtenir une projection des données dans une nouvelle base, de chercher parmi les nouveaux axes de projection ceux qui permettent d'obtenir le maximum d'information et de réduire leur dimensionnalités de sorte que l'information essentielle soit plus facile à analyser. La fonction principale de l'ACP est de transformer un certain nombre de variables corrélées en un ensemble réduit de variables non corrélées. [Harkat et al., 2006, Tharrault et al., 2008]. Cette méthode est essentiellement basée sur une décomposition orthogonale de la matrice de covariance des variables du processus le long des directions qui expliquent la variation maximale des données, autrement dit elle recherche une projection des observations sur des axes orthogonaux. Par conséquent, après la projection de la matrice sur les données brutes, le premier axe retenu est celui qui contient la plus grande inertie (plus grande valeur propre). Le deuxième axe contiendra la seconde plus grande inertie en terme de valeurs propres. En d'autres termes, il s'agit de trouver un ensemble de facteurs appelés composantes ayant une dimension plus petite que celle de l'ensemble original de données et pouvant traduire correctement les tendances principales. La procédure d'une analyse en composantes principales ne tient compte que des variables du processus. Parmi les travaux antérieurs sur l'analyse multi-variable, on peut citer [MacGregor

and Kourti, 1995, Nomikos and MacGregor, 1994] qui ont montré l'application des méthodes statistiques multi-variables telles que les ACP dans l'analyse et la commande de processus, la détection et le diagnostic de défaillances, aussi bien dans le cas de procédés continus que dans les cas des procédés "batch" (continus par lots). L'inconvénient de l'ACP se situe au niveau de l'invariance temporelle de la représentation obtenue alors que la plupart des processus physiques évoluent au cours du temps. Par conséquent, une mise à jour périodique de la représentation est nécessaire. Un autre inconvénient de l'ACP est qu'elle ne possède pas des propriétés de signature pour le diagnostic, ce qui rend l'isolement des défauts difficile.

### 3.4.5 Réseaux gaussiens de classification

Avant de parler des réseaux gaussiens de classification, il est important d'évoquer les notions essentielles relatives aux réseaux de neurones. Comme l'indique son nom, un Réseau de Neurones Artificiels (RNA) est un modèle de calcul inspiré du système nerveux biologique, comme le cerveau humain. La figure 3.9(B) montre le neurone formel inspiré du modèle biologique (figure 3.9(A)) [McCulloch and Pitts, 1943, Minsky and Papert, 1969].




FIGURE 3.9: Neurones biologiques et artificiels

Par définition, un neurone artificiel est une fonction linéaire, paramétrée et bornée. Dans

un réseau de neurones, plusieurs neurones travaillent ensemble afin de résoudre des problèmes spécifiques. Les variables sur lesquelles opèrent le neurone sont les entrées du neurone ( $x_1, x_2, \dots, x_n$ ) et la valeur de la fonction est la sortie ( $y$ ). Cette sortie peut être exprimée d'une part en fonction des entrées du neurone (équation 3.11) ou d'autre part en fonction de la non linéarité du neurone. Dans ce cas,  $f$  est appelée la fonction d'activation du neurone. Elle peut être une fonction seuil, une fonction gaussienne, une fonction linéaire ou une sigmoïde (figure 3.10).

$$y = f(x_1, x_2, \dots, x_n; w_1, w_2, \dots, w_p) \quad (3.11)$$

où les  $x_i$  sont les variables et les  $w_i$  sont les paramètres.

La fonction seuil applique un seuil sur la sortie du neurone entre  $[0,1]$  ou  $[-1,1]$ . Cette fonction sert à prendre des décisions binaires. La fonction linéaire affecte directement la sortie suivant une forme linéaire. La fonction sigmoïde se rapproche d'une fonction linéaire à saturation. La fonction gaussienne n'est utilisée que par les unités cachées de l'architecture d'un réseau de neurones à fonctions de base radiales (RBF).




FIGURE 3.10: Fonctions d'activation courantes. (A) : seuil, (B) : linéaire, (C) : sigmoïde, (D) : gaussienne

### Architecture des réseaux de neurones

L'association de plusieurs neurones forment un réseau de neurones destiné à remplir une fonc-

tion donnée. Un réseau de neurones en couches est essentiellement composé d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches intermédiaires (couches cachées). Dans la littérature, on distingue les réseaux de neurones non bouclés et les réseaux de neurones bouclés.

Dans un réseau de neurones non bouclé, plusieurs neurones sont connectés entre eux pour que l'information se propage de neurones en neurones vers la sortie. Autrement dit, chaque couche ne peut communiquer qu'avec celle qui la suit dans la structure. Ce type de réseau est dit unidirectionnel. Si l'on se déplace dans un tel réseau suivant les connexions à partir d'un neurone quelconque, on ne peut pas revenir au neurone de départ, on dit que le réseau est acyclique. La figure 3.11 présente un exemple de réseau de neurones non bouclé avec  $n$  entrées,  $N_c$  neurones cachés et  $N_o$  neurones de sortie. En absence de cycle, une grande variété de topologies est envisageable avec ce type de réseaux. Par ailleurs, notons que la notion de temps n'a aucune influence sur les réseaux de neurones non bouclés. A une entrée constante, correspond une sortie constante. Ce type de réseaux a été utilisé par [Maki and Loparo, 1997] pour la détection et le diagnostic dans les systèmes industriels. Un classificateur auto-adaptatif (Self Adaptatif Growing Neural Network SAGNN) à base d'un réseau unidirectionnel a été élaboré par [Barakat et al., 2011].

Pour un réseau de neurones bouclé, les neurones d'une même couche peuvent communiquer entre eux, le graphe de connexion est cyclique lorsqu'on se déplace dans le sens des connexions. La communication en arrière est possible entre les neurones d'une même couche ou entre des neurones de différentes couches. Une couche peut agir (transmettre de l'information) sur une couche en arrière tout comme un neurone peut également agir sur lui-même. La mise en œuvre est souvent plus compliquée. Un exemple de ce type de réseaux est donné par la figure 3.12. Ce réseau contient  $n$  entrées, deux couches cachées et une sortie constituée d'un seul neurone. Toutefois, notons que tout réseau bouclé peut se ramener à un réseau non bouclé dont certaines sorties sont ramenées aux entrées par des boucles de retard unité [Nerrand et al., 1993, Nerrand et al., 1994]. [Yibo and Xiaopeng, 2006] ont utilisé un réseau de neurones récurrent pour la classification des particules métalliques d'usure. [Xu and Chen, 2007] ont utilisé ce type de

réseaux pour le diagnostic en ligne des composants d'électronique de puissance.

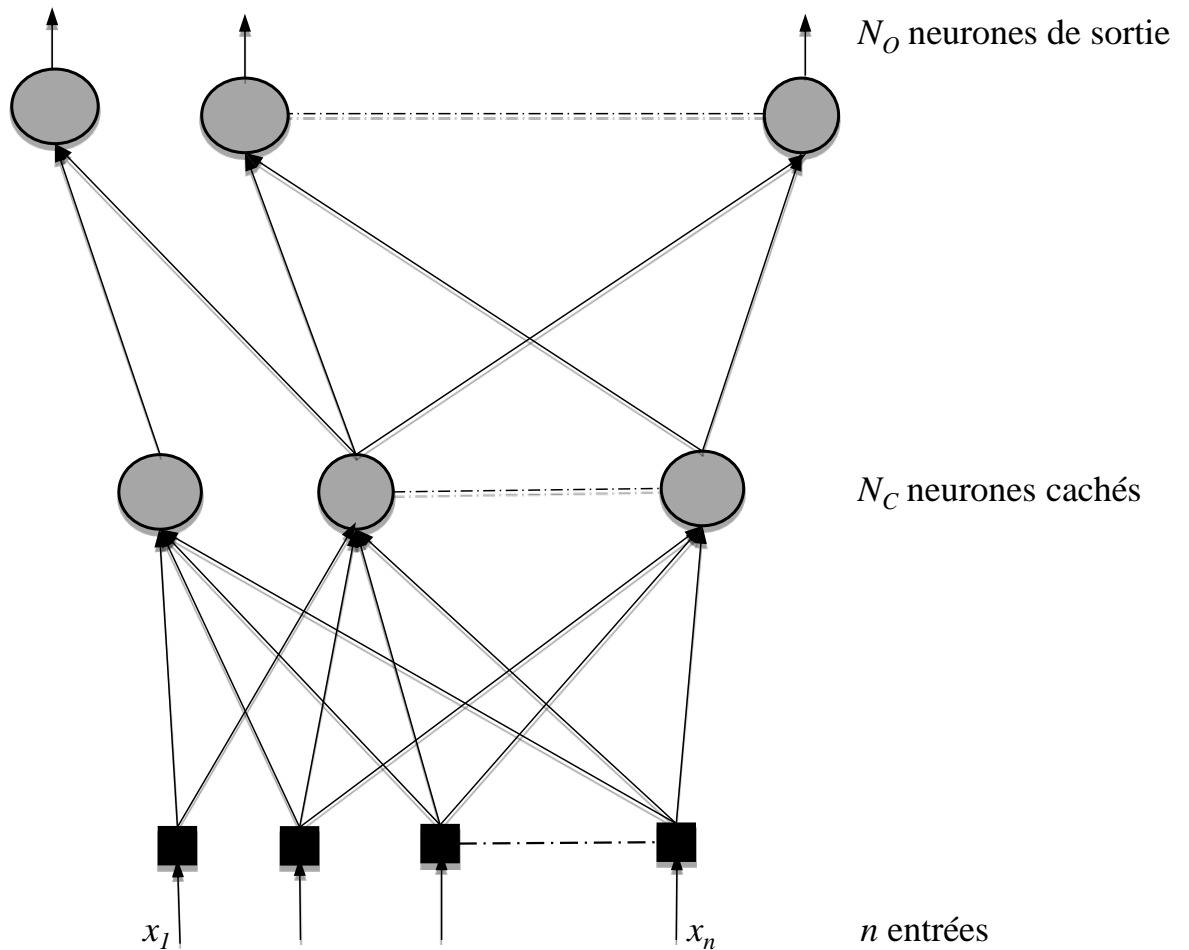


FIGURE 3.11: Exemple de réseau de neurones non bouclé à  $n$  entrées,  $N_C$  neurones cachés et  $N_O$  neurones de sortie

### Apprentissage des réseaux de neurones

L'apprentissage d'un réseau de neurones est une procédure permettant d'optimiser les paramètres des neurones afin d'accomplir la tâche qui lui a été affectée. L'ensemble des règles permettant de réaliser cette opération forme un algorithme d'apprentissage. Les données ayant servi à la procédure d'apprentissage sont appelées des exemples d'apprentissage et l'ensemble




FIGURE 3.12: Architecture d'un réseau récurrent

des exemples d'apprentissage forment la base d'apprentissage. On distingue deux types d'algorithmes d'apprentissage : l'apprentissage supervisé et l'apprentissage non supervisé.

L'apprentissage supervisé nécessite l'obtention a priori des données d'entrée et de sortie du système d'où le terme "supervisé". Une fois la base apprise par le réseau, ce dernier se comporte comme une fonction non linéaire, capable de réaliser une association entre les données d'entrée et de sortie. L'architecture du réseau de neurones non bouclé permet d'établir une relation entrées-sorties. Dans le cas où la relation analytique entrée-sorties est inconnue et qu'on dispose des valeurs issues des mesures réalisées sur le processus physique, chimique,....,etc ; un



apprentissage supervisé est réalisé afin d'établir un modèle statique ou de régression.

L'apprentissage non supervisé, aussi appelé apprentissage auto-organisé, se fait sans connaissance a priori des relations entrées/sorties du système. Il s'appuie sur des règles qui changent les poids synaptiques en fonction des exemples présentés à l'entrée. Les données sont organisées en fonction de leur ressemblance. Il n'y a donc pas de "professeur", car c'est au réseau de découvrir les ressemblances entre les éléments de la base de d'apprentissage, et de les traduire par une proximité dans un espace de projection adéquat. Ce type d'apprentissage peut être utilisé pour résoudre des problèmes pour lesquels l'obtention des informations sur le système est difficile ou pour des systèmes dont le comportement est moins connu. Il peut également être utilisé dans l'analyse des données (exemple : regroupement selon des critères de ressemblance). Des réseaux de neurones non bouclés peuvent être utilisés pour effectuer une tâche similaire en utilisant une base d'apprentissage, décrites par des vecteurs de dimension importante pour trouver une représentation dans un espace de dimension beaucoup plus faible (exemple : dimension 2) tout en conservant les proximités ou ressemblances entre les données. Les réseaux de neurones à apprentissage non supervisé les plus utilisés sont les "cartes auto-organisatrices" ou "cartes de Kohonen". De et Chatterjee [De and Chatterjee, 2002] ont utilisé un réseau carte de Kohonen pour la reconnaissance de motifs de défauts d'impulsion dans les transformateurs.

#### **3.4.5.1 Réseaux à fonction de base radiale**

Communément appelé RBF (Radial Basis Function en anglais), les réseaux à fonctions de base radiales sont utilisés dans des applications de régression et de discrimination. Par définition, une fonction de base radiale est une fonction symétrique autour d'un centre  $c$  avec une dispersion  $\sigma$ . Un réseau RBF est constitué généralement de 3 couches : une couche d'entrée, une couche de sortie et une couche cachée constituée des fonctions de base radiales. La fonction gaussienne est un exemple de fonctions de base radiales dont le noyau est défini par l'équation 3.12.  $\|x - c\|$  est la norme euclidienne de la différence entre le vecteur d'entrée  $x$  et le centre  $c$

de la gaussienne. La figure 3.13 présente un réseau RBF à noyaux gaussiens utilisé durant ces travaux de thèse. Il s'agit d'un réseau non bouclé avec deux entrées,  $N_c$  sorties et une couche cachée constituée de  $N_g$  noyaux gaussiens. L'apprentissage de ce réseau consiste à définir son architecture, le nombre de gaussiennes, la dispersion et la position des centres des noyaux gaussiens. Son apprentissage est différent de celui des autres types de réseaux. Il s'effectue selon deux phases : la première consiste à ajuster les poids de connexion  $W_{ij}$  et la deuxième permet d'optimiser les paramètres de la couche RBF ( $N_g, C, \sigma$ ). L'ajustement des poids de connexion est de type supervisé tandis que l'optimisation de la couche de noyaux gaussiens est de type non supervisé. On dit que l'apprentissage des réseaux à fonctions de base radiales est hybride lorsque l'algorithme d'apprentissage modifie en même temps les poids de connexion et la couche de noyaux gaussiens.

$$G(X) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(\frac{-\|x - c\|^2}{2\sigma^2}\right) \quad (3.12)$$




FIGURE 3.13: Architecture du réseau de neurones gaussiens

## Apprentissage des réseaux de neurones RBF à noyaux gaussiens

Le poids des connexions  $W_{ij}$ , le nombre de noyaux gaussiens  $N_g$ , les centres et les dispersions des noyaux gaussiens  $(C, \sigma)$  sont les paramètres modifiés au cours de cette phase d'apprentissage. Plusieurs méthodes d'apprentissage peuvent être utilisées pour cela. Les grandes étapes sont les suivantes :

1. Création de  $N_g$  neurones gaussiens ;
2. Initialisation aléatoire ou non des centres  $C$  et dispersions  $\sigma$  des noyaux gaussiens ;
3. Apprentissage non supervisé de la couche cachée.

L'entrée du réseau retransmet les vecteurs de la base d'apprentissage. La couche à noyaux gaussiens effectue une transformation non linéaire des entrées selon l'équation 3.12. Pour une entrée  $X$ , la sortie du neurone RBF est le niveau d'activation de la gaussienne en ce point. Il n'existe pas de technique spécifique pour déterminer le nombre de noyaux gaussiens  $N_g$ .

Au cours des travaux réalisés dans cette thèse, une méthode d'ajout automatique de noyaux gaussiens a été présentée pour la détection de défauts dans les plaques métalliques immergées [Sidibe et al., 2013a]. Cette méthode améliore les performances de détection et de diagnostic. La sortie du réseau est une combinaison linéaire des sorties des noyaux gaussiens. Dans un problème de classification dans lequel il existe autant de sorties que de classes, les sorties correspondent aux probabilités d'appartenance aux différentes classes. La figure 3.14 donne un exemple de quatre noyaux gaussiens et une entrée  $X$  donnée. Tenant compte des niveaux d'activation attribués aux différents noyaux, le vecteur  $X$  sera classé comme appartenant à la classe représenté par la gaussienne 1.

## 3.5 Conclusion

Dans ce chapitre, nous avons présenté deux familles de méthodes habituellement utilisées en détection et diagnostic de défauts dans les systèmes : les méthodes à base de modèles et les méthodes sans modèle de référence. Quelques outils de traitement des signaux utiles pour




FIGURE 3.14: Apprentissage non supervisé des noyaux gaussiens

la détection et le diagnostic des défauts ont aussi été présentés, en particulier les réseaux de neurones. Les prochains chapitres sont consacrés à l'application de ces deux familles de méthodes pour la détection et le diagnostic de défauts dans les plaques métalliques immergées. Une première méthode à base de modèle de référence par génération de résidus sera utilisée. Une deuxième méthode sans modèle de référence en utilisant un réseau de neurones à noyaux gaussiens sera mise en œuvre pour la classification des défauts dans les plaques immergées.



## CHAPITRE 4

# DÉTECTION ET LOCALISATION DES DÉFAUTS PAR MODÈLE DE RÉFÉRENCE

### 4.1 Introduction

Dans ce chapitre, la détection de défauts de surface dans les plaques immergées est réalisée par comparaison des mesures avec un modèle de référence. On dispose des signaux issus de la plaque de référence et des signaux mesurés de la structure testée. Deux méthodes de génération de résidus ont été adoptées.

La première méthode consiste à mettre en forme les deux ensembles de signaux par extraction de l'enveloppe et lissage au moyen d'un filtre gaussien. Cette étape est suivie de l'utilisation d'un seuil de détection pour extraire le segment utile limité par les échos provenant des extrémités dans les signaux enregistrés. La génération de résidus est réalisée par la différence entre les enveloppes des signaux de test et de référence. Les résultats obtenus sont présentés dans nos travaux [Sidibe et al., 2013d] et [Sidibe et al., 2013c].

La deuxième méthode associe à la méthode précédente un réseau de neurones gaussiens pour l'extraction du segment utile limité par les échos d'extrémités dans les signaux enregistrés. La

détection et la localisation de défauts sont réalisées par seuillage. Cette méthode permet de plus d'estimer l'angle d'acquisition ( $\theta$ ) et la distance qui sépare le transducteur et le centre de la plaque ( $l$ ).

L'organisation du chapitre est la suivante : La première section détaille le choix des échantillons de plaques utilisés et leurs caractéristiques. La deuxième section présente la méthode de détection de défauts dans les plaques métalliques immergées basée sur l'utilisation des seuils et la génération de résidus. La troisième section porte sur la détection de défauts par combinaison de réseaux de neurones et du seuillage. La quatrième et dernière section est réservée à la conclusion.

## 4.2 Choix des échantillons

L'une des difficultés majeures rencontrée au cours de cette étude a été le choix d'une méthode globale de traitement automatique des données. Le dispositif expérimental utilisé présente deux caractéristiques qui constituent à la fois la nouveauté et la difficulté dans la procédure de détection des défauts dans les plaques.




FIGURE 4.1: Échantillons de plaque avec fissure utilisés pour la détection à base de modèles de référence

La première caractéristique est la variation de l'angle d'acquisition des signaux qui induit un fort changement du signal acquis en terme de contenu fréquentiel. La deuxième caractéristique est la mesure sans contact réalisée par le transducteur. Cette caractéristique constitue également un avantage pour une détection rapide et peu coûteuse pour les structures immergées dont l'accès est limité. Les échantillons étudiés contiennent des défauts externes tels que des fissures et de trous de taille égale ou supérieure à la longueur d'onde du signal émis. Les plaques avec fissure utilisées sont présentées dans la figure 4.1.

### 4.3 Méthode de détection par seuillage de défauts dans les plaques métalliques immergées

La méthode développée utilise les outils du traitement du signal et le modèle simplifié de propagation des ondes de Lamb dans la plaque présentée dans le chapitre 1. L'algorithme proposé permet de détecter et de localiser à distance des défauts de surface dans des plaques métalliques immergées.

#### 4.3.1 Algorithme de détection et de localisation de défauts

L'algorithme de détection et de localisation permet dans un premier temps d'extraire le segment utile  $[E_1 E_2]$  des signaux de mesure et ensuite de déterminer la position du défaut par analyse du résidu résultant des enveloppes des segments utiles. On appelle  $S$  et  $D$  les signaux de mesures enregistrés respectivement pour les plaques de référence et de test, de taille respective  $N$  et  $O$  points. L'algorithme de la figure 4.2 donne les différentes étapes de la méthode de détection et localisation des défauts.

##### Étape 1 : Premier recalage

Pour générer le résidu, les signaux issus de la plaque de référence et de test doivent être conditionnés afin de calculer leur différence. Pour cela un premier recalage des signaux est nécessaire et permet d'avoir le même origine qui coïncide avec l'écho correspondant à la réflexion du si-



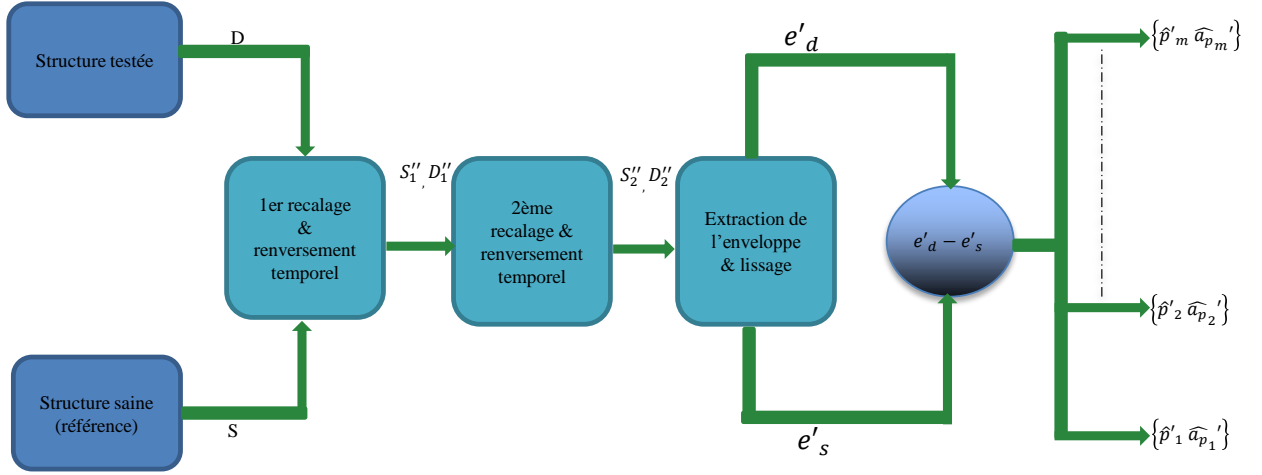


FIGURE 4.2: Algorithme de détection de défaut par seuillage

gnal émis sur l'extrémité la plus proche du transducteur. Il faut noter toutefois, un décalage peut apparaître entre deux signaux acquis dans les mêmes conditions et sous le même angle d'incidence. L'enregistrement reste instable et ce phénomène est lié aux opérations de changement de cibles (plaques). D'autres paramètres tels que la température peuvent aussi avoir une influence sur l'enregistrement. Ces derniers ne sont pas pris en compte dans notre étude. Soient  $E(S)$  et  $E(D)$  les ensembles d'indices  $i$  et  $j$  respectivement des signaux  $S$  et  $D$  pour lesquels l'amplitude est supérieure au seuil  $\eta = \mu + k\sigma$ , avec  $\mu$  et  $\sigma$  respectivement la moyenne et l'écart type du signal de référence  $S$ .  $k$  est un paramètre d'ajustement choisi par l'utilisateur.

$$E(S) = \{i \geq 1 \text{ tel que } |s_i| \geq \eta\} \quad (4.1)$$

$$E(D) = \{j \geq 1 \text{ tel que } |d_j| \geq \eta\} \quad (4.2)$$

Soient  $S'_1$  et  $D'_1$  les sous ensembles des signaux  $S$  et  $D$ , définis selon les équations 4.3 et 4.4 avec  $i_s = \min(E(S))$  et  $i_d = \min(E(D))$ .  $Ne = \min(N - i_s, O - i_d)$  est la plus petite longueur des deux signaux résiduels obtenus par suppression des  $i_s - 1$  et  $i_d - 1$  premiers points. Les équations 4.5 et 4.6 correspondent aux signaux 4.3 et 4.4 réfléchis.

$$S'_1 = \{s_i \in S \text{ tel que } i \in [i_s, i_s + N_e]\} \quad (4.3)$$

$$D'_1 = \{d_i \in D \text{ tel que } i \in [i_d, i_d + N_e]\} \quad (4.4)$$

$$S''_1 = \{s'_{N_e}, s'_{N_e-1}, \dots, s'_1\} \quad (4.5)$$

$$D''_1 = \{d'_{N_e}, d'_{N_e-1}, \dots, d'_1\} \quad (4.6)$$

## Étape 2 : Deuxième recalage

Cette étape permet d'obtenir la deuxième extrémité du segment utile ( $E_2$ ). Elle est nécessaire d'une part pour limiter la taille des signaux étudiés à la plage dite "segment utile" et d'autre part pour la mise à l'échelle des signaux de référence et de test après le premier recalage et renversement. On définit les ensembles d'indices  $i$  et  $j$  des termes des signaux recalés lors de la première étapes (équations 4.5, 4.6) pour des amplitudes supérieures au seuil  $\alpha = \mu' + k'\sigma'$  (équations 4.7, 4.8) avec  $\mu'$  et  $\sigma'$  respectivement la moyenne et l'écart type du signal de référence  $S''_1$ .  $k'$  est un paramètre d'ajustement choisi par l'utilisateur.

$$E''(S''_1) = \{i \geq 1 \text{ tel que } |s''_i| \geq \alpha\} \quad (4.7)$$

$$E''(D''_1) = \{j \geq 1 \text{ tel que } |d''_j| \geq \alpha\} \quad (4.8)$$

Soient  $S'_2$  et  $D'_2$  les sous ensembles des signaux  $S''_1$  et  $D''_1$ , définis par les équations 4.9 et 4.10 avec  $i''_S = \min(E(S''_1))$  et  $i''_D = \min(E''(D''_1))$ .  $Me = \min(i''_S, i''_D)$  est la plus petite longueur des deux signaux  $S'_2$  et  $D'_2$ . Les équations 4.11 et 4.12 correspondent aux équations 4.9 et 4.10

réfléchis.

$$S'_2 = \{s''_i \in S''_1 \text{ tel que } i \in [M_e, M_e + N_e]\} \quad (4.9)$$

$$D'_2 = \{d''_i \in D''_1 \text{ tel que } i \in [M_e, M_e + N_e]\} \quad (4.10)$$

$$S''_2 = \{s'_{M_e}, s'_{M_e-1}, \dots, s'_1\} \quad (4.11)$$

$$D''_2 = \{d'_{M_e}, d'_{M_e-1}, \dots, d'_1\} \quad (4.12)$$

### Étape 3 : Extraction des enveloppes des segments utiles des signaux de référence et de test

L'extraction des enveloppes des signaux recalés est réalisée avec la transformée de Hilbert. Cette opération permet de simplifier la quantité d'information contenue dans l'enregistrement en ne gardant que son énergie sans perte des informations utiles à la détection et la localisation du défaut. Les expressions des enveloppes sont appelées  $e_s(t)$  et  $e_d(t)$  respectivement pour les signaux  $S''_2$  et  $D''_2$ .

### Étape 4 : Lissage des enveloppes

Le lissage est réalisé par convolution des enveloppes  $e_s(t)$  et  $e_d(t)$  avec une gaussienne  $G(t)$  similaire à celle de l'équation 3.12 dont les paramètres doivent être correctement choisis par l'utilisateur. Tout comme l'extraction de l'enveloppe permet d'éviter les pics aberrants dans le résidu, le lissage permet aussi de limiter les variations brusques dans les enveloppes qui peuvent engendrer des fausses détections. Les enveloppes lissées sont données par les équations 4.13 et 4.14.

$$e'_s(t) = G(t) * e_s(t) \quad (4.13)$$

$$e'_d(t) = G(t) * e_d(t) \quad (4.14)$$

### Étape 5 : Détection et localisation des défauts par génération de résidus

La détection et la localisation des défauts sont obtenues par analyse du résidu (équation 4.15) résultant de la différence des enveloppes lissées des équations 4.13 et 4.14. L'analyse consiste à extraire l'indice  $i'$  (équation 4.16) correspondant à l'amplitude maximale du résidu. Cette estimation permet d'obtenir la position estimée  $\hat{p}$  (équation 4.17) du défaut dans le signal de test.

$$R = e'_d(t) - e'_s(t) \quad (4.15)$$

$$i' = \operatorname{argmax}(R) \quad (4.16)$$

$$\hat{p}' = i' + i''_D \quad (4.17)$$

On notera que la méthode de détection et de localisation peut également être appliquée sur les enveloppes non lissées. Mais on obtiendra alors des estimations de la position du défaut et de son amplitude moins précises.

### 4.3.2 Validation expérimentale

Considérons l'exemple constitué d'un signal de référence (figure 4.3(A)) et d'un signal de test (figure 4.3(B)). Le premier seuil  $\eta$  est fixé avec une valeur de  $k$  égale à 3 (figure 4.4). Le deuxième seuil  $\alpha$  est fixé avec une valeur de  $k'$  égale à 7. La valeur de ce seuil est en général largement supérieure à  $\eta$  à cause de la superposition des différents échos.

La figure 4.5 donne le résultat obtenu à l'issu de cette étape. La figure 4.6 représente les




FIGURE 4.3: Exemple constitué des signaux de référence (A) et de test (B)




FIGURE 4.4: Premier recalage des signaux de référence (A) et de test (B)

enveloppes des signaux après le premier et le deuxième recalage. Il faut noter que cette nouvelle représentation limite les signaux à leurs modules en utilisant la transformée de Hilbert. Sur les




FIGURE 4.5: Deuxième recalage des signaux de référence (A) et de test (B)




FIGURE 4.6: Envelopes des signaux de référence (A) et de test (B)

envelopes des signaux présentées par la figure 4.6, on peut remarquer encore des variations dans le module qui peuvent induire des maximas dans le résidu.

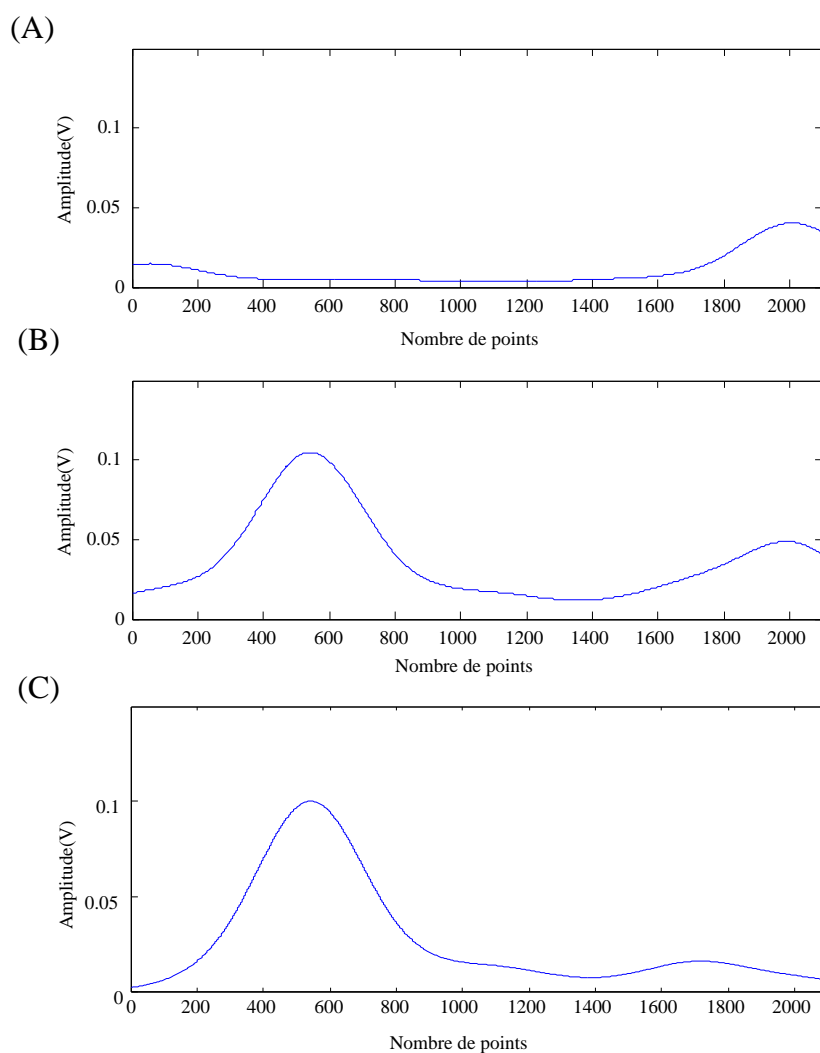


FIGURE 4.7: Envelopes lissées des signaux de référence (A) et de test (B) après l'extraction des enveloppes

Pour éviter ce phénomène pouvant introduire des erreurs de détection, un lissage par gaussienne est réalisée (figure 4.7). Le résidu obtenu par soustraction des enveloppes lissées est donné par la figure 4.7(C). Le maximum de ce résidu représente la position estimée du défaut dans le signal de test. Les résultats de détection et de localisation sont obtenus pour des échantillons de la plaque avec des défauts situés à 35 mm et à 17 mm de la première extrémité (figure 4.8, 4.9). Les signatures théoriques sont en trait continu pour les extrémités ainsi que le défaut et les valeurs mesurées sont représentées avec des symboles (\*). Les valeurs théoriques

et mesurées ont été superposées pour permettre une évaluation qualitative des performances de la méthode. On remarque que ces deux courbes se superposent sous la plupart des angles d'incidence. On observe aussi un léger décalage dans le résultat de la détection de la première extrémité de la plaque dont le défaut est très proche (17 mm) : figure 4.9. Cela est dû à l'interférence des échos émanant de l'extrémité de la plaque et du défaut, ce qui entraîne la génération d'un écho plus large en terme de dispersion et conduit par conséquent à une décision erronée dans la procédure de détection.




FIGURE 4.8: Résultat de la détection pour une plaque avec un défaut à 35 mm

### 4.3.3 Conclusion

On notera une bonne adéquation générale du modèle et des mesures pour un large secteur angulaire [20° ; 160°] excepté autour de 90°. Dans ce cas, les extrémités de la plaque sont équidistantes et les signaux de rétrodiffusion interfèrent avec ceux du défaut. Le premier écho est facilement localisé à partir du signal acquis. Il faut noter qu'une valeur trop importante






FIGURE 4.9: Résultat de la détection pour une plaque avec un défaut à 17 mm

du seuil  $\eta$  engendre la non-détection du premier écho. Le deuxième écho est plus difficile à localiser à cause de l'interférence de plusieurs modes induits par la réflexion des ondes de Lamb sur le défaut. Une valeur trop faible du seuil engendre la non-détection du deuxième écho. On remarque que le défaut est correctement localisé et que sa position temporelle est fonction de l'angle d'acquisition. L'inconvénient de cette méthode est la sensibilité des performances au choix des seuils qui doivent être déterminés manuellement. Cette détermination est réalisée par multiples essais et s'avère fastidieuse pour une opération de détection de défaut nécessitant une prise de décision rapide. La méthode proposée dans la prochaine section utilise un réseau de neurones gaussiens pour la détection automatique des extrémités de la plaque et résout donc cette difficulté.

## 4.4 Méthode de détection par apprentissage et seuillage

Dans cette section, l'extraction du segment utile de la plaque est réalisée au moyen d'un réseau de neurones gaussiens. Cette méthode permet de plus une estimation des paramètres essentiels de l'expérience.

### 4.4.1 Estimation des paramètres $\theta$ et $l$

L'analyse de signaux avec les techniques sans contact est sensible à la position du transducteur par rapport à l'objet. Dans notre cas d'étude, cette position est définie par la distance  $l$  par rapport au centre de la plaque et le transducteur, l'angle d'incidence  $\theta$  dans le plan de la trajectoire du transducteur et l'angle  $\psi$  de ce plan par rapport à la direction perpendiculaire à la plaque. Ce dernier angle est supposé être nul et la largeur de la plaque  $L_p$  est supposée être connue. L'objectif dans cette section est d'estimer la distance  $l$  et l'angle d'incidence  $\theta$ . Ces estimations résultent de la mesure du temps  $t_{E_1}$  et de la durée  $t_{E_2} - t_{E_1}$ . Pour mesurer ces temps, les réflexions directes sur les extrémités de la plaque (premier et deuxième échos) et la plage utile sont isolés avec la méthode de seuillage. L'estimation de la distance est donnée par l'équation 4.18. De la même manière, l'estimation de l'angle est donnée par l'équation 4.19. A des fins de validation, une variation sinusoïdale de la distance  $l$  a été simulée en enlevant une partie variable du signal avant la réflexion sur la première extrémité de la plaque (il faut noter que notre dispositif expérimental convient uniquement pour des trajectoires circulaires du transducteur avec une distance constante). Les figures 4.10 et 4.11 fournissent la valeur exacte (en pointillés) et leurs valeurs estimées (traits pleins) et les erreurs d'estimation. Les estimations sont très bonnes excepté dans la plage  $[70^\circ : 80^\circ]$  où de nombreuses interférences entre plusieurs réflexions perturbent la détection des extrémités de la plaque. En raison d'erreurs importantes, la plage  $[70^\circ : 80^\circ]$  sera omise pour une utilisation pratique. Le tableau 4.1 résume les erreurs d'estimation pour les quatre plaques dans la plage  $[10^\circ : 70^\circ]$ .  $P_1$  est la plaque de référence.  $P_2$ ,  $P_3$  et  $P_4$  sont les plaques avec une fissure située respectivement à 52mm, 35mm et 17mm de l'extrémité  $E_1$ .

$$\hat{l} = \frac{\sqrt{\frac{c_e^2}{2}((t_{E_1})^2 + (t_{E_2})^2) - L_p^2}}{2} \quad (4.18)$$

$$\hat{\theta} = \arccos\left(\frac{C_e^2}{8\hat{l}L_p}((t_{E_2})^2 - (t_{E_1})^2)\right) \quad (4.19)$$




FIGURE 4.10: Estimation de l'angle d'acquisition  $\theta$

#### 4.4.2 Algorithme de détection automatique du segment utile

Un calcul adaptatif des paramètres des seuils  $\eta$  et  $\mu$  est proposé dans cette section selon l'algorithme présenté par la figure 4.12. Cet algorithme est basé sur la méthode de classification décrite par le réseau de neurones gaussiens. Pour chaque signal de mesure et chaque extrémité




FIGURE 4.11: Estimation de la distance  $l$

		$P_1$	$P_2$	$P_3$	$P_4$
$\theta$	Erreur moyenne	1.3	3	3.22	1.7
	Erreur maximale	8	19	14	12
$l$	Erreur moyenne	1.9	3.8	2.8	4.5
	Erreur maximale	9.8	22	15	8.5

TABLE 4.1: Tableau récapitulatif des erreurs d'estimation de la distance et de l'angle acquisition

$E_1$  et  $E_2$ , un motif de taille  $2w$  est extrait à partir du signal de référence  $S$ . Le motif  $P_h = \{s_i \text{ tel que } i \in [i_h - w : i_h + w - 1]\}$  est classé en utilisant un réseau de détection gaussien afin de décider si  $P_h$  est une extrémité ou non. L'algorithme commence avec des petites valeurs de paramètres  $k_1$  et  $k_2$  ( $k_1 = 1$  et  $k_2 = 1$ ). Si  $P_h$  appartient à la classe des extrémités de la plaque, le processus s'arrête, sinon les valeurs des paramètres  $k_1$  et  $k_2$  sont incrémentés et l'extraction des

caractéristiques est effectuée sur un nouveau motif pour une nouvelle classification. La figure 4.13 donne le résultat de la séparation des échos d'extrémités d'un échantillon de référence correspondant au groupe (2). On remarque que les motifs de la première extrémité sont bien séparés des motifs en aval avant la deuxième extrémité. Par contre une zone de confusion apparaît pour la séparation des motifs de la deuxième extrémité par rapport au reste du signal. Cela est dû à la superposition des ondes de Lamb observées dans les signaux de mesures.

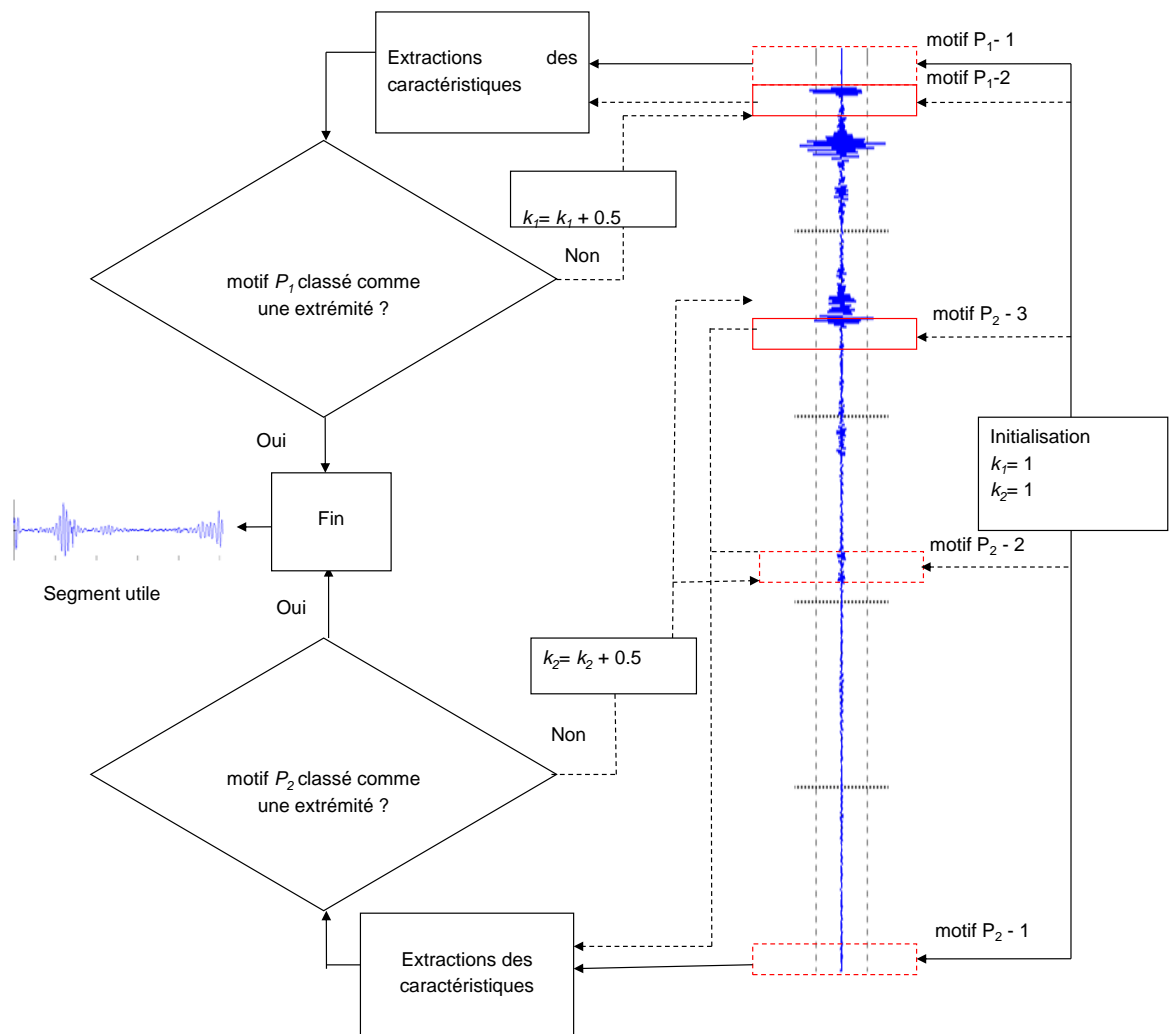


FIGURE 4.12: Algorithme de détection automatique des seuils par apprentissage et adaptation des seuils





FIGURE 4.13: Classification des extrémités (+) et autres motifs (\*). (A) : extrémité  $B_1$ , (B) : extrémité  $B_2$

### 4.4.3 Détection des défauts

Une fois les paramètres  $l$  et  $\theta$  estimés, la détection et la localisation des défauts sont obtenues par comparaison des signaux mesurés et des signaux de référence obtenus à partir d'une plaque saine. Ces signaux de référence sont stockés dans une base de données pour chaque valeur possible de l'angle  $\theta$  et pour une valeur spécifique de la distance  $l$ . Le résidu généré est identique à celui donné par l'équation 4.14. L'ensemble de la méthode de détection est donné par l'algorithme proposé par la figure 4.14. La figure 4.15 donne un exemple de signaux de référence et de test pour un défaut situé à 50 mm de l'extrémité  $E_1$  et un angle d'incidence de  $20^\circ$ . La détection de défaut est obtenue par seuillage et le seuil  $\eta_F$  (équation 4.20) est calculé à partir de la valeur moyenne de l'enveloppe du signal de référence.

$$\eta_F = \eta_0 = \max \left( H e'_s(t)(\hat{\theta}) \right) \quad (4.20)$$

Comme les seuils  $\eta_1$  et  $\eta_2$  utilisés pour détecter les extrémités de la plaque, le seuil  $\eta_F$  est aussi automatiquement adapté pour chaque échantillon et sous chaque angle du fait de la variation de l'amplitude de l'écho émanant du défaut. Les résultats de détection et de localisation sont présentés pour les échantillons de plaques (2) respectivement pour l'échantillon de référence et un échantillon avec une fissure situé à 52 mm (figure 4.17).

Une image B-scan résultant de la superposition des signaux temporels est construite (figures 4.16 (A) et 4.17(C)). Cette représentation permet d'obtenir les temps de vol pour les signaux d'un même échantillon acquis sous différents angles d'incidence. Le code couleur de cette figure est tel que les échos de forte amplitude sont représentés en noir et les échos de faible amplitude en bleu. Des travaux similaires [Maze et al., 2014], [Cité et al., 2012], [Maze et al., 1985], [Léon et al., 1992], [Décultot et al., 1993] portant sur la détection de défauts dans les plaques métalliques immergées ont été réalisés par l'équipe acoustique acoustique du laboratoire LOMC.

La position théorique des extrémités de la plaque est représentée en trait continu et super-

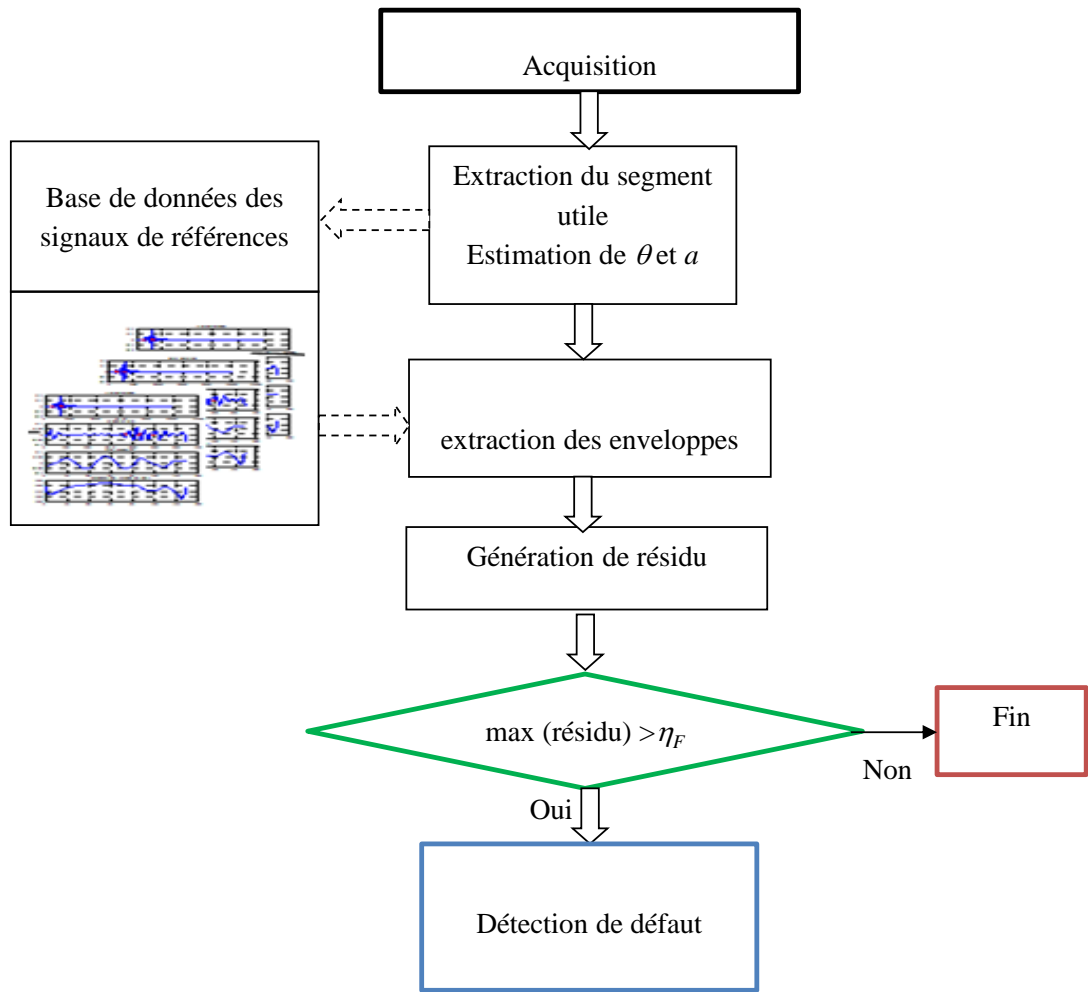


FIGURE 4.14: Méthode de détection par modèle de référence

posée aux extrémités détectées par l'algorithme (points '+') (figures 4.16 et 4.17). La position théorique du défaut est également représentée en trait continu et superposée avec le défaut détecté par l'algorithme avec le symbole 'o'.

Il faut noter que les extrémités  $E_1$ ,  $E_2$  des plaques et également les défauts  $F$  sont détectés correctement sauf dans les plages  $[70^\circ : 80^\circ]$  et  $[30^\circ : 40^\circ]$ . Pour ces plages, la deuxième extrémité de la plaque  $P_1$  coïncide avec une réflexion qui apparaît plus tard dans l'étape d'acquisition. Ainsi la deuxième extrémité est mal détectée et l'écho dû à la réflexion de la deuxième extrémité est vu comme un défaut (figure 4.16 (A) et 4.16 (B)). Ce phénomène conduit à de fausses alarmes. Pour la plaque  $P_2$ , le même problème se produit dans la gamme  $[70^\circ : 80^\circ]$ . Dans






FIGURE 4.15: Exemple de signaux de test et de référence sous incidence angulaire de 20 degré

l'intervalle  $[30^\circ : 40^\circ]$ , le défaut détecté et la première extrémité coïncident. Ce phénomène conduit parfois à des non détections (figure 4.17 (D) et 4.16 (B)). Une fonction de détection de défaut est calculée pour les plaques  $P_1$  et  $P_2$  (figure 4.18). La valeur de la fonction est 0 si aucun défaut n'est pas détecté, et la valeur est 1, lorsqu'un défaut est détecté. Lorsque le segment utile extrait du signal est trop court ( $\theta$  tend vers  $90^\circ$ ), l'algorithme ne fournit aucune décision et la valeur de la fonction vaut -1.

Pour résumer les performances obtenues pour les différents échantillons de plaques, le taux de détection moyen est de 7 %, le taux de fausses alarmes est de 23 % et le taux de non décision est de 3% pour  $w = 100$  et  $\eta_F = \max(e'(S(\hat{\theta})))$ . Le tableau 4.2 illustre l'influence de la taille  $w$  des fenêtres sur les performances de l'algorithme. Il faut noter qu'il est nécessaire d'optimiser  $w$




FIGURE 4.16: Estimation des extrémités de la plaque de référence correspondant aux échantillons (2) présentés par la figure 4.1. (A) : superpositions des signaux de mesure sous les angles d'incidences allant de  $1^\circ$  à  $90^\circ$  pour constituer une image B-scan, (B) : résultat obtenu en utilisant l'algorithme de détection et de localisation.

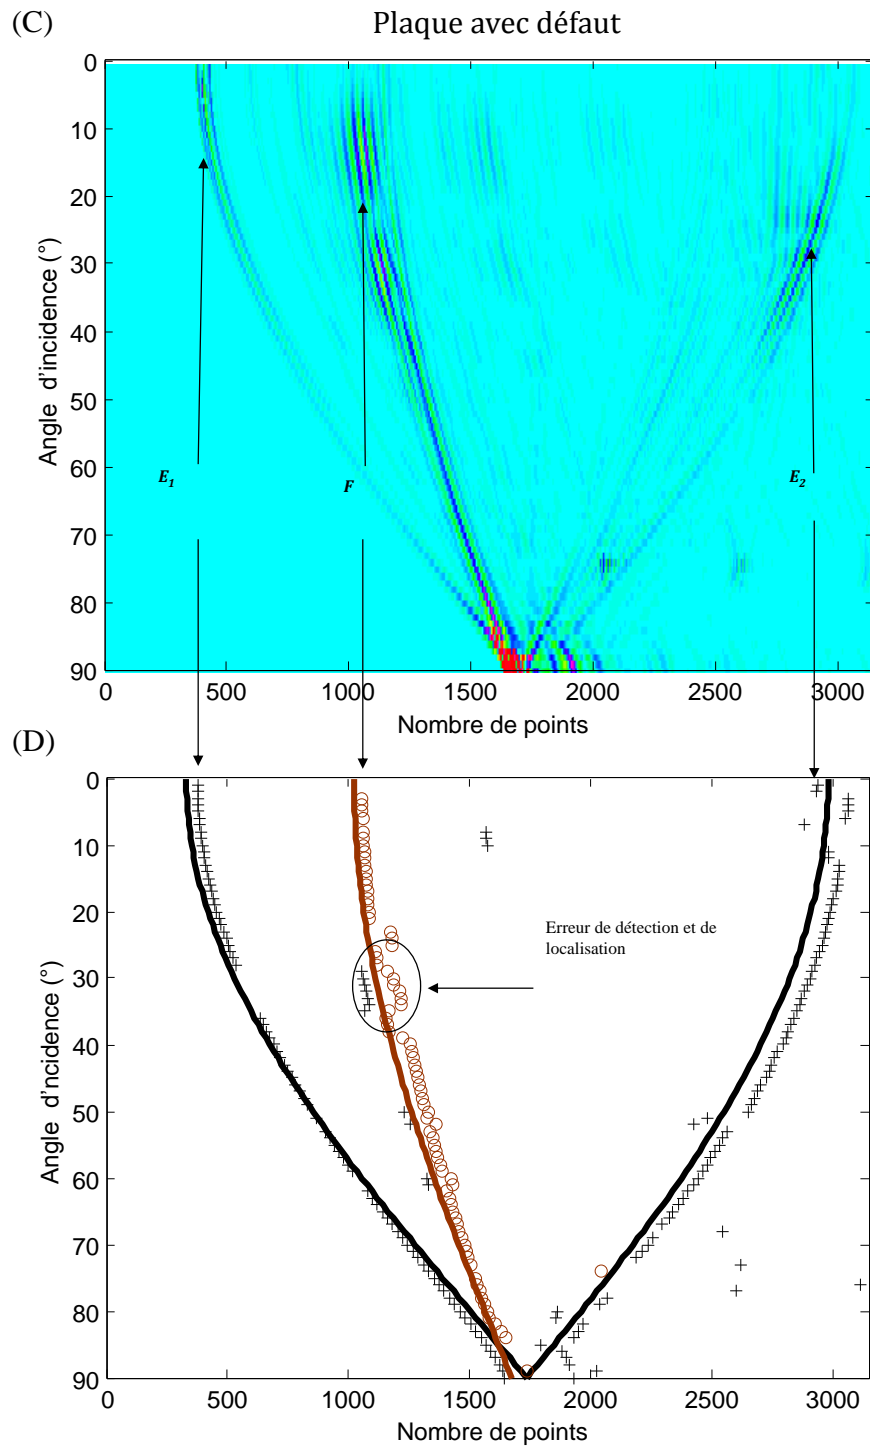


FIGURE 4.17: Estimation des extrémités et de la position du défaut de la plaque de test ayant un défaut situé à 50 mm de la première extrémité (échantillons (2)), (A) superpositions des signaux de mesure sous les angles d'incidences allant de  $1^\circ$  à  $90^\circ$  pour constituer une image B-scan, (B) résultat obtenu en utilisant l'algorithme de détection et de localisation.

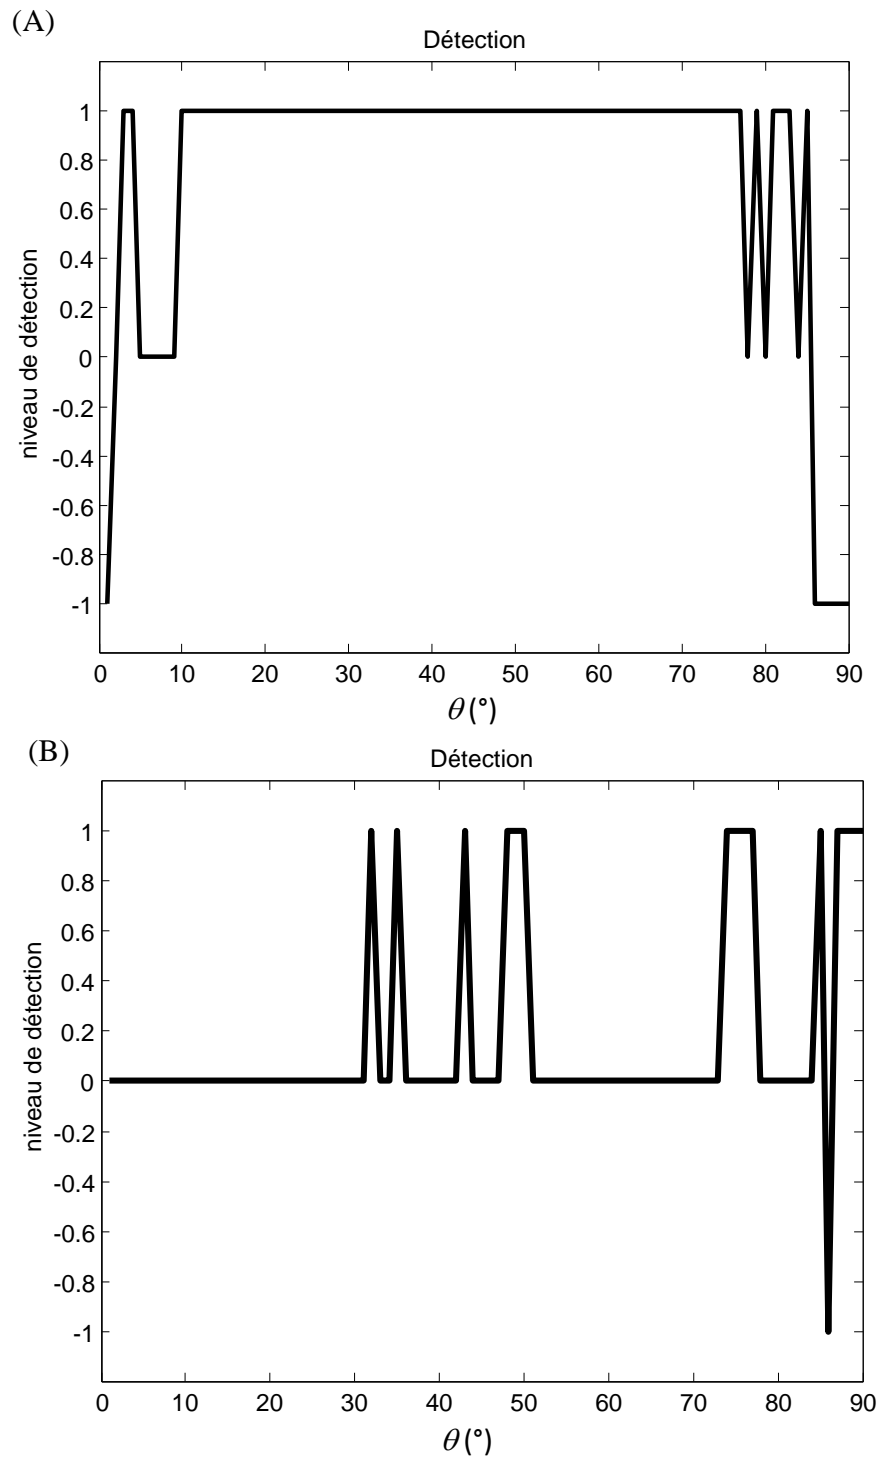


FIGURE 4.18: Fonction de détection et de diagnostic des défauts de la plaque. (A) fonction de détection pour la plaque saine sous les angles d'incidences allant de  $1^{\circ}$  à  $90^{\circ}$ , (B) fonction de détection pour la plaque de test ayant un défaut situé à 50 mm de la première extrémité (échantillons (2)) sous les angles d'incidences allant de  $1^{\circ}$  à  $90^{\circ}$ .

pour avoir les meilleures performances d'analyse et dans notre étude cette valeur correspond à  $w = 100$ . Une valeur trop faible de  $w$  peut ralentir la procédure d'analyse contrairement à une valeur assez élevée. Ce choix peut se faire en testant différentes valeurs de  $w$  et en choisissant celle qui minimise les taux de fausse alarme, de non détection et de non décision.

$w$	25	50	100	200
Fausse alarme	29%	45%	23%	30%
Taux de non détection	25%	9%	7%	10%
Taux de non décision	7%	0%	3%	11%

TABLE 4.2: Influence de la taille  $w$  de la fenêtre

Le tableau 4.3 illustre l'influence du seuil  $\eta_F$  sur les performances de l'algorithme, soit  $\eta_0 = \max(\max(e(S(\hat{\theta})))$ . Il faut noter que, si le seuil  $\eta_F$  augmente, les taux de non-détection et de fausse alarme diminuent.  $w = 100$  et  $\eta_F = \eta_0$  donnent le meilleur compromis afin de limiter fortement les taux de non détection sans dégrader considérablement le taux de fausse alarme.

$\eta_F$	$0.5\eta_0$	$\eta_0$	$1.5\eta_0$	$2\eta_0$	$3\eta_0$
Fausse alarme	63%	23%	17%	10%	4%
Taux de non détection	0%	7%	15%	22%	33%
Taux de non décision	3%	3%	2%	3%	3%

TABLE 4.3: Tableau récapitulatif de l'influence du seuil  $\eta_F$

#### 4.4.4 Localisation de défauts

La localisation de défauts est réalisée en utilisant le maximum d'amplitude du résidu (équation 4.21). L'estimation du temps de vol  $t_F$  (équation 2.39) résulte directement de la détermination du maximum de résidus et de la fréquence d'échantillonnage  $f_e : t_F(\hat{\delta}) = f_e * i_{max} + t_{delay}$ . avec  $f_e$  la fréquence d'échantillonnage,  $i_{max}$  : l'indice du maximum dans le résidu,  $t_{delay}$  : le décalage dans le signal de test et  $\delta$  la distance entre la première extrémité de la plaque et le défaut. Ensuite, l'estimation  $\hat{\delta}$  de  $\delta$  est obtenue à partir du calcul de  $t_F$  (par résolution de

l'équation (4.22) en fonction de  $(\hat{\delta} - \frac{1}{2})$ . La solution positive de cette résolution est donnée par l'équation 4.23. Finalement,  $\delta\hat{L}_p$  est l'estimation de la position du défaut par rapport à l'extrémité  $E_1$ .

$$i_{max} = \max(R) \quad (4.21)$$

$$\left(\hat{\delta} - \frac{1}{2}\right)^2 + \left(\frac{2\hat{l}\cos(\hat{\theta})}{L_p}\right)\left(\hat{\delta} - \frac{1}{2}\right) + \left(\frac{\hat{l}}{L_p}\right)^2 - \left(\frac{t_F(\hat{\delta})c_e}{2L_p}\right)^2 = 0 \quad (4.22)$$

$$\hat{\delta} = 0.5 \left( 1 + \frac{\hat{2}l}{L_p} \sqrt{\left(\frac{t_F(\hat{\delta})c_e}{2\hat{l}}\right)^2 - (\sin(\hat{\theta}))^2 - \cos(\hat{\theta})} \right) \quad (4.23)$$

Nous avons pu montrer sur un exemple (figures 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9) comment la méthode peut être utilisée in situ lorsque l'angle d'incidence de la mesure n'est pas connu (par exemple si les acquisitions sont réalisées en mer depuis un navire en déplacement au dessus du site inspecté). Pour cela, un signal est pris au hasard parmi les acquisitions de la deuxième plaque de la famille 2 des échantillons utilisés. Les extrémités  $E_1$  et  $E_2$  sont déterminées. Le signal de test est ensuite recalé. A l'issu de cette étape, on obtient un angle d'acquisition égale à  $31^\circ$ . La plaque étant symétrique, on tient compte uniquement des angles compris dans l'intervalle  $[0^\circ; 90^\circ]$ . Une fois l'angle déterminé, on récupère le signal de référence correspondant et on applique l'algorithme de localisation pour déterminer la position temporelle du défaut. Cette position correspond à 1,064 ms. La connaissance de ce couple (position-angle) permet de déduire la position réelle du défaut. La valeur estimée de  $\delta$  est ainsi obtenue et est égale à 0,26. Le produit  $\delta * L_p = 50,7$  mm est très proche de la valeur réelle (50 mm). L'erreur de localisation est inférieure à 2% [Sidibe et al., 2013d].

## 4.5 Détection de défaut par traitement d'image

Il y a eu d'énormes progrès dans la technique d'imagerie acoustique au cours des dernières décennies. Des méthodes plus sophistiquées sont appliquées à un large éventail de domaines tels que l'imagerie médicale, le contrôle non destructif, l'imagerie sous-marine et la prospection géophysique. La méthode proposée est illustrée par l'organigramme proposée par la figure 4.19. Cette procédure comporte quatre phases essentielles : l'imagerie et prétraitement, l'élimination des échos d'extrémités, la détection de défauts et la localisation des défauts.

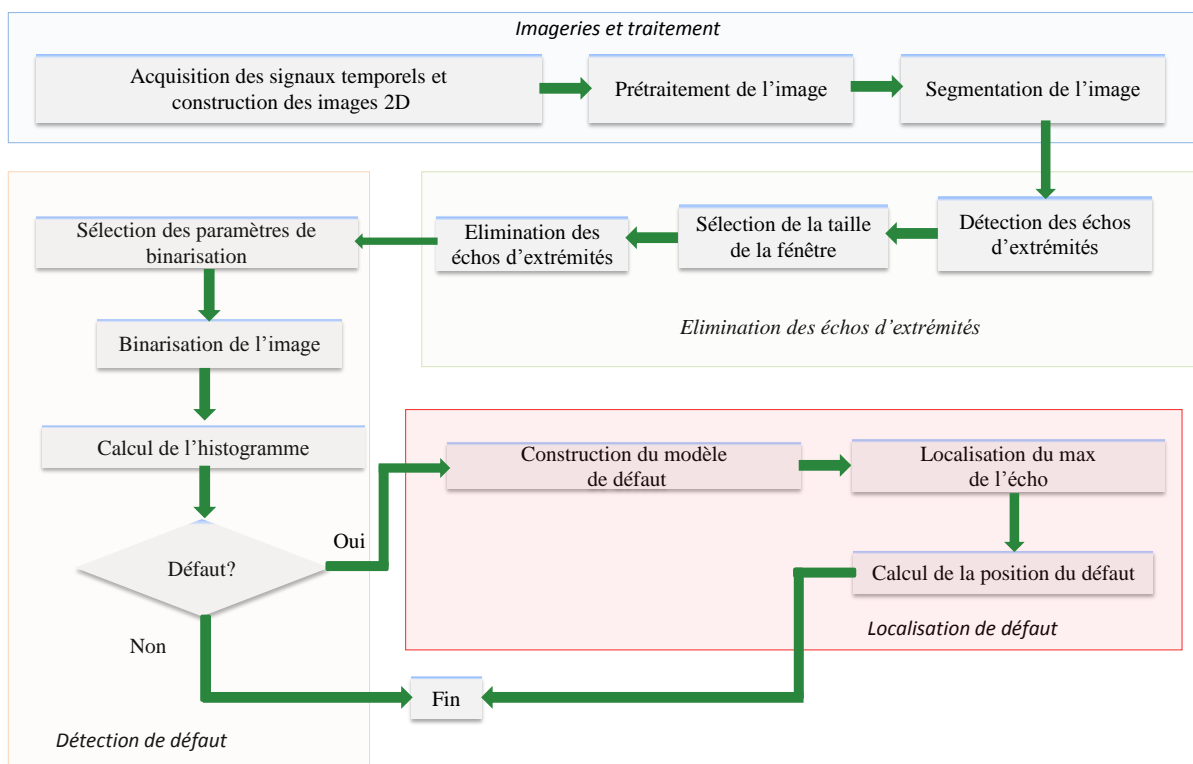


FIGURE 4.19: Algorithme de détection de défaut par traitement d'image

Il faut toutefois noter que le signal enregistré avec un taux d'échantillonnage de 10 Méchantillons/s avec 10000 échantillons pour chaque angle d'incidence est redondant. Lorsque l'onde se propage sur une longue distance dans la cuve de l'expérience, l'atténuation acoustique et les interférences peuvent affecter l'image acoustique même si le coefficient d'atténuation du matériau est faible. Pour cette raison, les échos des ondes lointaines peuvent introduire d'énormes

erreurs dans les applications.

### 4.5.1 Procédure de traitement d'image des signaux acoustiques

L'image traitée est composée des signaux temporels obtenus pour des angles d'incidence variant continuellement de  $0^\circ$  à  $180^\circ$ . Ces images sont utilisées pour la détection de défauts par traitement de signal et traitement d'image. Les images de test sont ensuite normalisées et améliorées à cause de l'amplitude faible des signaux temporels qui les constituent. Selon le critère de Rayleigh, la résolution optimale de l'image acoustique est de  $\lambda/2$  avec  $\lambda$  la longueur d'onde. Les technologies de traitement d'image peuvent ensuite être utilisées pour l'amélioration des images acoustiques. L'amélioration de l'image permettra d'élargir la gamme dynamique du signal initial, même si elle n'augmente pas le contenu de l'information. Le fond de l'image est composé de petites valeurs qui peuvent être considérées comme du bruit, ce bruit sera éliminé avant un traitement ultérieur. La figure 4.20(A) montre les échos temporels obtenus sous différents angles d'incidence. La construction de l'image acoustique 2D, l'étiquetage des échos d'extrémités et de l'écho de défaut sont présentés par la figure 4.20(B). Afin d'avoir une visualisation sans ambiguïté, les figures 4.20(B) et (C) sont binarisées. Comme on peut le voir sur la 4.20(A), les échos de défauts possibles, telles que des rainures sont relativement petits lorsque les angles d'incidence sont compris entre  $[10^\circ - 15^\circ]$  et  $[166^\circ - 180^\circ]$ . D'autre part, lorsque les angles d'incidence sont proches de  $90^\circ$ , par exemple dans l'intervalle  $[71^\circ - 110^\circ]$ , les échos de défauts possibles sont marqués mais mélangés avec les échos provenant des extrémités de la plaque. Par conséquent, les meilleures gammes incidence d'angle de la détection des défauts sont entre  $[16^\circ - 70^\circ]$  et  $[111^\circ - 165^\circ]$ .

L'image 2D est segmentée dans les gammes incidence angulaire  $[16^\circ - 70^\circ]$  et  $[111^\circ - 165^\circ]$  comme indiqué par la figure 4.20(B).

Une fenêtre glissante est utilisée sur les signaux temporels pour les angles d'incidence  $16^\circ$  et  $165^\circ$  pour localiser les positions de départ des échos de l'extrémité proche notés  $x_1$  et  $x_2$ . La plus petite valeur entre  $x_1$  et  $x_2$  est choisie pour la segmentation. En raison de la symétrie du



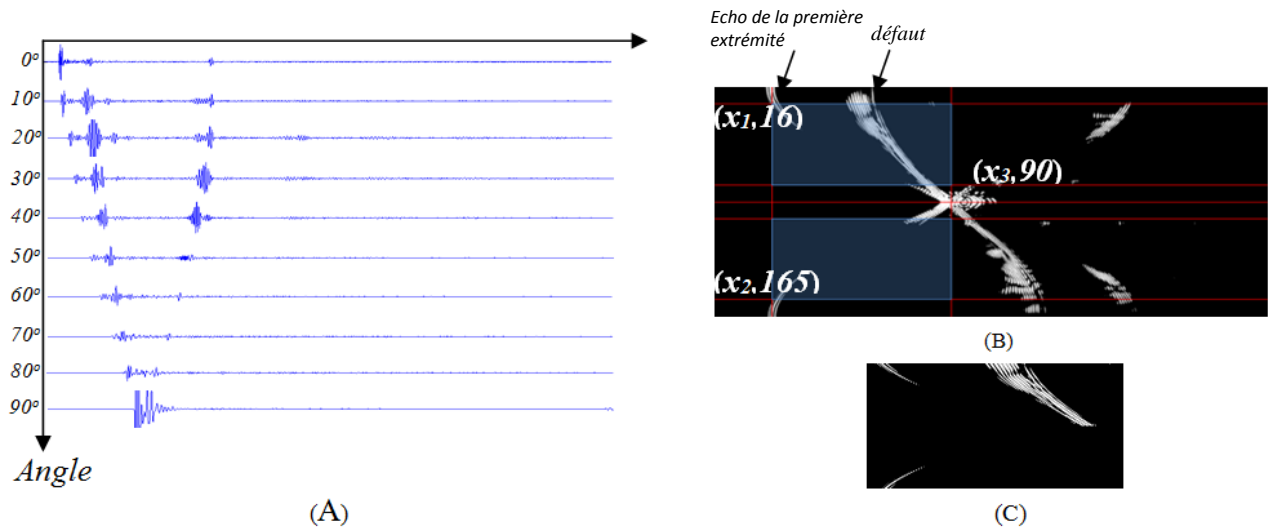


FIGURE 4.20: Signaux de diffusion acoustique en image, (A) les échos temporels en fonction des angles d'incidence, (B) schéma de segmentation de l'image, (C) image de test obtenu.

problème, le maximum de l'écho sous  $90^\circ$  est aussi le centre du signal de sorte que ce centre soit de coordonnées  $(x_3, 90)$ .

À noter que les coordonnées de la segmentation entre  $0^\circ$  et  $90^\circ$  sont  $(\min(x_1, x_2), 16)$   $(\min(x_1, x_2), 70)$ ,  $(x_3, 16)$  et  $(x_3, 70)$ . De même, les coordonnées de la segmentation entre  $91^\circ$  et  $180^\circ$  sont  $(\min(x_1, x_2), 111)$ ,  $(\min(x_1, x_2), 165)$ ,  $(x_3, 111)$  et  $(x_3, 165)$ . Ainsi, nous pouvons obtenir l'image acoustique 2D à tester selon ces coordonnées comme illustré sur la figure 4.20(C).

## 4.5.2 Détection des fissures

Comme le montre la figure 4.20(C), il y a deux types de signaux dans l'image de test : les échos d'extrémités et des échos éventuels de défaut. Les signaux de rétrodiffusion des extrémités peuvent être automatiquement supprimés. La méthode de détection consiste donc à segmenter l'image 2D acoustique ; puis de localiser et éliminer les échos d'extrémités ; la détection robuste et efficace des défauts peut être ensuite effectuée. Une fenêtre glissante est utilisée sur les signaux temporels sous chaque angle d'incidence afin de situer les positions de début des échos d'extrémité. L'équation 4.24 est utilisée pour sélectionner la taille optimale de la fenêtre

d'analyse pour la suppression des échos d'extrémités.

$$W_f = \frac{\sum_{i=1}^m \sum_{j=1}^n |G_{i,j} - E_{i,j}|}{\sum_{i=1}^m \sum_{j=1}^n |T_{i,j}|} \quad (4.24)$$

où  $G$  est la matrice binaire de l'image de test avec les échos d'extrémité et de défaut,  $E$  est l'image binaire de test dans lequel les échos de l'extrémité proche sont éliminés avec une taille de fenêtre donnée,  $T$  est le modèle binaire de l'écho d'extrémité,  $(m, n)$  est la taille de l'image de test.  $W_f$  indique le pourcentage d'échos d'extrémité qui sont éliminés. Plusieurs tailles de fenêtre sont testées sur des images de test provenant des plaques avec des défauts sous différentes positions. Lorsque la taille de la fenêtre est plus petite que la largeur de l'écho d'extrémité, celui ci ne peut pas être éliminé complètement. Avec l'augmentation de la taille de la fenêtre, le pourcentage d'élimination augmente donc  $W_f$  augmente. Lorsque l'écho d'extrémité est complètement supprimé,  $W_f$  atteint une valeur égale à 1 ce qui signifie que la taille de la fenêtre est optimale. La sélection de la taille de la fenêtre en utilisant  $W_f$  est discutée.

La figure 4.21 montre l'amplitude et l'histogramme d'une image de test. On peut remarquer que l'amplitude des échos de défaut est plus grande que celle de l'image de fond (arrière-plan).




FIGURE 4.21: Amplitude (A) et histogramme (B) d'une image de test

En raison de la faible densité des signaux dans l'image de test, il est nécessaire de réaliser une binarisation afin de réduire la complexité de calcul et d'améliorer la précision de la détection. Pour cela un seuil de binarisation est utilisé. Le facteur de binarisation  $T_h$  est défini par l'équation 4.25 afin de trouver le paramètre de seuil optimal en testant une série de paramètres de binarisation.

$$T_h = \frac{\sum_{i=1}^m \sum_{j=1}^n D_{i,j}}{\sum_{i=1}^m \sum_{j=1}^n (RD_{i,j} + BG_{i,j})} \quad (4.25)$$

où  $D$  est l'image binarisée avec un paramètre donné dans lequel l'écho de l'extrémité la plus proche est éliminé,  $RD$  est l'écho de défaut résiduel de  $D$ ,  $BG$  est l'image de fond à un seuil donné. Ainsi, pour chaque paramètre de seuil testé,  $T_h$  est proportionnel au nombre de pixels de l'écho de défaut et est inversement proportionnel au bruit de fond. Lorsque  $T_h$  atteint le maximum du paramètre de seuil, alors on peut déduire qu'elle est optimale.

Après binarisation, l'image de test se compose de l'écho de défaut ou des échos de bruit uniquement. Afin d'identifier s'il existe un défaut, nous considérons chaque ligne et chaque colonne de l'image pour tracer deux courbes. S'il n'y a pas de défaut dans l'image de test, une faible valeur de la somme est obtenue et il n'y a pas de changement brusque. D'autre part, s'il y a un changement brusque dans les deux sommes des courbes de ligne et de colonne, alors un défaut existe. Les points de changement brusque des deux courbes représentent la position des défauts. Ainsi, un rectangle de l'écho de défaut peut être obtenu.

### 4.5.3 Localisation des défauts

Dans les applications de détection de défaut, il est toujours important de localiser la position exacte des défauts. Dans cette recherche, deux méthodes différentes de localisation de défaut sont proposées sur la base des relations géométriques de réflexion acoustique. Le temps de vol des ondes acoustiques qui se propagent à des distances différentes peut être utilisé pour mesurer la distance entre la position du transducteur et la cible sur la plaque. Après l'élimination de

l'écho de l'extrémité la plus proche, le maximum de chaque ligne de l'image représente une réflexion de l'onde sur le défaut s'il existe. Afin de localiser avec précision les défauts, il est nécessaire de trouver le maximum du signal d'écho de défaut pour chaque angle d'incidence. La figure 4.22 montre le résultat de localisation de maximums des échos de défaut, ce qui correspond à la position de défaut.

Avec les coordonnées des maxima il est facile de calculer le temps de vol aller-retour de l'onde acoustique entre le transducteur et le défaut. Pour une onde acoustique donnée, on peut calculer la distance entre le transducteur et le défaut. On peut également calculer la distance entre le transducteur et d'extrémité proche à la fois avec les coordonnées du maximum de l'écho de défaut. La figure 4.23 illustre le principe de localisation du défaut.




FIGURE 4.22: Maximum de l'écho de défaut pour chaque incidence angulaire

Pour une onde acoustique donnée,  $T_F$  et  $TE_1$  sont données par les équations 4.26 et 4.27. La distance verticale entre le transducteur et la plaque est donnée par l'équation 4.28. Ainsi les distances entre le transducteur et le défaut sont obtenu par les équations 4.29 et 4.31

$$T_F = \frac{t_1 S_e}{2} \quad (4.26)$$

$$TE_1 = \frac{t_2 S_e}{2} \quad (4.27)$$

$$TC = TO \sin(\theta) \quad (4.28)$$



l'écho de l'extrémité proche et celui de l'extrémité éloignée est proportionnelle à la largeur de la plaque. De même pour chaque angle d'incidence, la distance entre l'écho d'extrémité proche et l'écho de défaut est proportionnelle à la distance entre l'extrémité proche et le défaut dans la plaque testée. Selon les caractéristiques de l'image de diffusion Acoustique, les maximum d'énergie apparaissent au milieu de la plaque lorsque l'angle d'incidence est de  $90^\circ$ . Le point central peut donc être calculée par le maximum d'énergie de l'image. Cette caractéristique nous donne un autre moyen de localiser la position du défaut puisque, les coordonnées de l'écho de défaut peuvent être obtenues à partir des coordonnées du point central et des coordonnées de l'écho de l'extrémité proche. La position exacte du défaut peut être calculée par l'équation 4.31

$$D_{ED} = \frac{d_{ED}}{d_{EC}} D_{EC} \quad (4.31)$$

$D_{ED}$  est la distance entre l'extrémité proche et celui de défaut dans la plaque.  $D_{EC}$  est la distance entre l'extrémité la plus proche et la ligne centrale obtenue dans la plaque.  $d_{ED}$  est la distance entre l'extrémité proche et le défaut dans l'image de test.  $d_{EC}$  est la distance entre l'extrémité proche et la ligne centrale dans l'image de test.

#### 4.5.4 Résultats et discussion

La figure 4.24 montre les résultats expérimentaux de la méthode proposée. La figure 4.24(A) montre l'image acoustique dans le cas de la plaque saine. La figure 4.24(B) montre l'image de test dans le cas d'une plaque avec rainure, la figure 4.24(C) montre le résultat de la segmentation de l'image 4.24(B). La figure 4.24(D) montre le résultat de l'élimination de l'écho de l'extrémité la plus proche. La figure 4.24(E) montre le résultat de la binarisation de l'image 4.24(D). La figure 4.24(F) montre la localisation du maximum de l'écho de défaut.

Comme illustré sur la figure 4.24(A), les deux échos d'extrémité de la plaque de test sont symétriques. Comparé aux échos de l'extrémité proche, les échos de l'extrémité éloignée et de défaut sont atténués et interfèrent. Par conséquent, la segmentation d'image est essentielle

pour une meilleure détection des défauts et une meilleure précision de localisation . La figure 4.24(C) montre un résultat d'image 2D acoustique contenant un écho de défaut.




FIGURE 4.24: Résultats expérimentaux de la méthode proposée. (A) image de test sans défaut, (B) image de test avec une fissure verticale, (C) résultat de la segmentation de (B), (D) élimination des échos d'extrémités de (C), (E) résultat de la binarisation d'image de (D), (F) localisation du maximum de l'écho de défaut.

Pour éliminer l'écho de l'extrémité proche, il est nécessaire de choisir une fenêtre de taille optimale. La taille de la fenêtre pour les images de test est calculée en utilisant l'équation 4.24 et tracées comme le montre la figure 4.25. Cette figure illustre  $W_f$  lorsque la taille de la fenêtre augmente. Pour les plaques avec différentes positions de défaut, il existe une légère différence lorsque la taille de la fenêtre se rapproche de 75 ; les valeurs de  $W_f$  se rapproche de 1 pour toutes les images de test. Lorsque la taille de la fenêtre est large, par exemple 80, les échos de l'extrémité proche ne peuvent pas être éliminées complètement. D'autre part, si la taille de la fenêtre est trop grande, la méthode peut éventuellement éliminer l'écho de défaut en particulier lorsque le défaut est proche de l'extrémité la plus proche. Cela peut affecter les maxima de l'écho de localisation et induire ainsi des erreurs de détection et de localisation. En conséquence, nous avons choisi une fenêtre de taille égale à 80.

La figure 4.24 (D) représente le résultat de l'élimination de l'écho de l'extrémité proche de l'échantillon de test en utilisant la taille optimale de la fenêtre. Les échos de l'extrémité proche sont complètement éliminés tandis que les échos de défaut ne sont pas affectés, même pour




FIGURE 4.25: Variation de  $W_f$  en fonction de la taille de la fenêtre




FIGURE 4.26: Sélection de la taille optimale de fenêtre pour l'élimination des échos d'extrémités

l'échantillon pour lequel le défaut est extrêmement proche de l'extrémité comme on peut le voir sur la figure 4.27. L'élimination de l'écho de l'extrémité proche affecte le taux de détection de défaut. D'autre autre part, le paramètre de binarisation est le facteur clé pour une détection et une localisation robuste et précise.

Le seuil de binarisation pour les images de test est calculé en utilisant l'équation 4.25 et tracé sur la figure 4.28. Plus le seuil de binarisation est élevé, plus les pixels de l'écho de défaut






FIGURE 4.27: Échantillon avec une fissure proche de l'extrémité. (A) image de test, (B) résultat de la segmentation, (C) élimination des échos d'extrémités, (D) binarisation de l'image, (E) localisation du maximum de l'écho de défaut

sont élevés et moins des pixels de fond sont élevés. Lorsque le seuil de binarisation est faible, l'écho de défaut peut être complètement préservé cependant, les bruits de fond ne peuvent pas être éliminés de façon qu'il existe une séparation claire entre le fond et le cas sans-défaut. Au contraire, lorsque le seuil est élevé, le bruit de fond peut être éliminée et la plupart des pixels de l'écho de défaut sont conservés en raison de leurs fortes amplitudes. En outre, seuls les maximas des échos de défaut sont utilisés dans la phase de localisation. Par conséquent, lorsque le seuil est légèrement plus grand que le seuil optimal, par exemple 0,1, le taux de détection et de localisation ne sont pas affectés. Dans ce travail, pour obtenir une séparation complète du fond et des défauts nous choisissons le seuil de binarisation = 0,1. La figure Figure 4.28(B) montre les résultats de binarisation en utilisant différents seuils (de haut en bas) : 0,02 ; 0,1 et 0,15.

Des expériences sur des plaques avec des défauts situés à des positions différentes sont effectuées avec la méthode proposée. La plaque sans défaut est également testée pour la comparaison. Avec la segmentation flexible et la méthode d'élimination des échos de l'extrémité proche, il est facile de détecter un défaut dans une plaque de test et le taux de détection de défaut de la fissure atteint 100%. Le tableau 4.4 montre les résultats expérimentaux de la

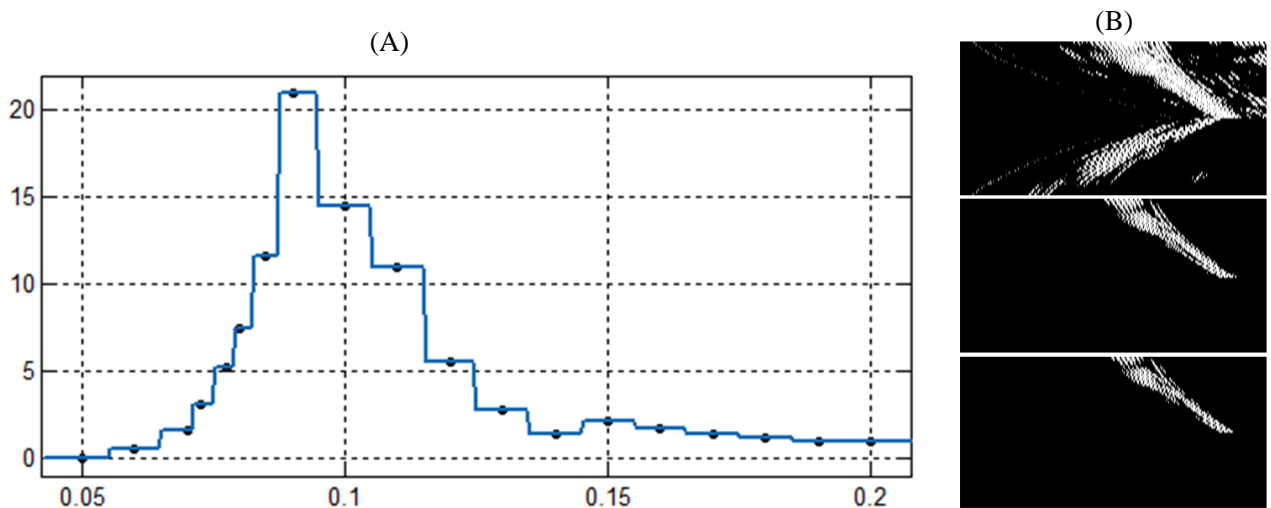


FIGURE 4.28: choix du seuil de la binarisation de l'image. (A) seuil en fonction du facteur de binarisation, (B) résultat de la binarisation en utilisant différents seuils du haut en bas respectivement pour 0.02,0.1 et 0.15

localisation de défaut. La précision de localisation moyenne atteint 96%.

Échantillons	Position réelle du défaut	Détection de défaut	Localisation
Échantillon 1	35.0mm	37.0mm	94.41%
Échantillon 2	52.0mm	53.6mm	96.95%
Échantillon 3	71.0mm	69.2mm	97.11%

TABLE 4.4: Résultats expérimentaux de la localisation du défaut pour différents échantillons

## 4.6 Conclusion

Dans ce chapitre, la détection et la localisation des défauts ont été proposées selon deux méthodes différentes basées sur la génération de résidus. La première méthode, par traitement direct des signaux, est plus facile à mettre en place mais présente l'inconvénient de devoir estimer manuellement les seuils de détection utilisés pour détecter les extrémités des plaques et les défauts. La seconde méthode utilise des réseaux de neurones dans les procédures de détection et de diagnostic, et automatise la sélection des seuils mis en œuvre pour détecter les extrémités des plaques. Les performances obtenues avec plusieurs plaques illustrent l'efficacité

de la méthode dans une large gamme angulaire. L'avantage de notre méthode est sa capacité à surveiller à distance les structures immergées. Il faut noter que la méthode dépend seulement de deux paramètres à savoir la taille de la fenêtre temporelle utilisée pour extraire les paramètres et le seuil fixé par l'utilisateur.

L'estimation des paramètres (distance, angle) influence les performances de la méthode proposée et cela peut être observé sur les figures 4.10, 4.11. On remarque des valeurs aberrantes de l'estimation des paramètres (angle et distance) sur la plage d'incidence angulaire [70-80]. Et cela se répercute sur les courbes de performance de la détection données par la figure 4.18. L'erreur moyenne et maximale d'estimation d'angle et de distance sont données par le tableau 4.1. Les tableaux 4.2 et 4.3 donnent l'influence des paramètres (taille  $w$  et seuil  $\eta_F$ ) sur les performances de la méthode.

Par ailleurs, nous avons abordé le problème de la détection et de la localisation de défaut dans les plaques immergées en utilisant des méthodes de traitement d'images acoustiques. Les signaux acoustiques temporels sont superposés pour construire une image 2D qui fait l'objet d'une analyse. Il faut noter que certains signaux obtenus sous certains angles d'incidence sont défavorables dans la procédure de détection et de localisation de défauts. Pour cette raison, l'image acoustique 2D a été prétraitée et segmentée pour améliorer la précision de détection et réduire la complexité de calcul. Les paramètres optimaux ont été sélectionnés pour l'élimination de l'effet de l'écho de la première extrémité. Enfin, une méthode de détection et de localisation robuste et simple a été introduite pour détecter et localiser des défauts dans les images 2D. Les résultats expérimentaux montrent que le taux de détection atteint 100% pour les défauts de fissure et la précision de localisation atteint 96% en moyenne.

## CHAPITRE 5

# DÉTECTION ET DIAGNOSTIC DES DÉFAUTS SANS MODÈLE DE RÉFÉRENCE

### 5.1 Introduction

Les opérations de détection et de diagnostic peuvent être considérées comme un problème de classification de données dans lequel des signaux de caractéristiques similaires (propriétés physiques, géométriques, statistiques, ..., etc) sont regroupés dans la même classe. Dans l'architecture de réseau que nous avons utilisée, la détection permet de séparer les données de la classe saine (classe étiquetée 0) des données de la classe défectueuse pouvant être constituée de plusieurs sous classes défectueuses (classes étiquetées 1,2,3). Dans un second temps, le diagnostic est réalisé afin de séparer les données des différentes sous classes (trou, fine fissure, large fissure). Pour cela, deux réseaux de neurones gaussiens avec la même architecture sont utilisés. Les principales étapes sont : l'acquisition des signaux à partir des plaques de référence et des plaques de test, le prétraitement des signaux avec des outils d'analyse décrits dans le chapitre 2 (détection des extrémités, de la plage utile, extraction des enveloppes, ..., etc), l'extraction des caractéristiques pertinentes par Analyse en Composantes Principales (ACP) et ensuite la détection et le diagnostic de défauts. Le schéma global traduisant ces étapes est donné par la

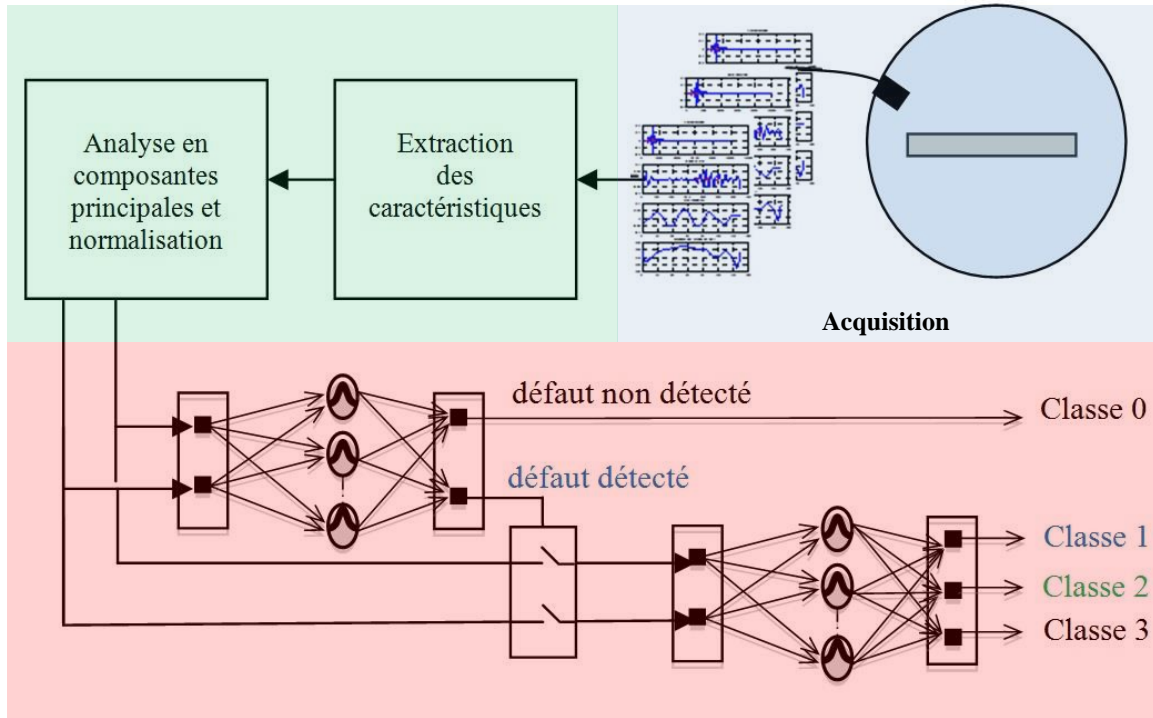


FIGURE 5.1: Schéma général de la détection et du diagnostic de défaut sans modèle de référence dans les plaques métalliques immergées

figure 5.1.

## 5.2 Prétraitement des signaux

Cette section est consacrée à la mise en forme des signaux. Tout d'abord, l'extraction du segment utile est réalisée par la méthode de classification des signaux provenant des extrémités de la plaque. Ensuite, les caractéristiques statistiques sont extraites des segments utiles. Par la suite, ces caractéristiques sont organisées puis analysées.

Dans cette démarche, l'extraction des caractéristiques peut être réalisée dans le domaine temporel (moyenne quadratique, amplitude de crête à crête, variance, kurtosis, etc.), dans le domaine fréquentiel (densité spectrale, coefficients de la transformée de Fourier rapide (FFT), etc), ou dans le domaine temps-fréquence (transformée de Fourier à court terme, transformée en ondelettes). En particulier, dans le domaine temporel plusieurs systèmes d'analyse des

séries temporelles pour la détection des défauts de plaques ont réalisé [Rizzo et al., 2006] et [Trendafilova and Manoach, 2008].

Dans notre étude, pour un signal temporel donné, les caractéristiques suivantes sont extraites : la moyenne du motif, la variance qui mesure la dispersion des mesures autour de la moyenne, l'aplatissement aussi appelé skewness qui permet de caractériser l'apparition de pics dans un signal, le kurtosis qui mesure l'asymétrie du motif, l'énergie du motif, la somme quadratique des variations du motif et l'amplitude maximale du motif. Pour un signal donné obtenu sous un angle donné et représenté par son segment utile, l'ensemble des caractéristiques constitue un vecteur. L'ensemble de ces vecteurs forme la base de données initiales  $E$ . L'utilisation de l'ACP permet de construire la base réduite  $E_R$  à partir de  $E$ .

Avec différentes plages de variation, ces paramètres nécessitent une normalisation, et pour cela, l'équation 3.10 du chapitre 2 est utilisée. Chaque échantillon de la base réduite  $E_R$  est normalisée, composante par composante, entre 0 et 1, par rapport aux valeurs minimales et maximales que peut prendre la composante sur l'ensemble  $E_R$ .

### 5.3 Analyse en composantes principales

Comme expliqué dans le chapitre 2, il est nécessaire de déterminer les combinaisons de paramètres les plus significatives pour effectuer une meilleure séparation des données provenant des signaux en plusieurs classes selon les types de défauts. Dans notre étude, l'ACP est utilisée pour déterminer les deux composantes principales les plus déterminantes. Le choix de retenir deux composantes est motivé par les différents essais réalisés mais aussi par un souci de simplicité pour présenter facilement les résultats dans l'espace de projection. Après l'utilisation de l'ACP, les deux composantes principales sont représentées par des vecteurs lignes  $c_1$  et  $c_2$  et constituent le projecteur  $C = [c_1^T c_2^T]^T$ .

À l'issue de l'analyse en composantes principales, une base d'apprentissage réduite  $E_R$  est obtenue à partir de la base d'apprentissage complète  $E$  selon l'équation 5.1.

$$E_R = C.E \quad (5.1)$$

## 5.4 Classification par réseau de neurones gaussiens

Une fois les données mises en forme, la procédure de classification peut être appliquée. Pour cela, la première étape consiste en l'apprentissage du réseau de neurones gaussiens avec la base d'apprentissage  $E_{RN}$ .

### 5.4.1 Algorithme d'apprentissage du réseau de neurones à noyau gaussien

Chaque gaussienne  $j$  de la couche cachée est associée à une seule classe et son activation pour un échantillon  $x$  est définie par l'équation 5.2. où  $d_j$  et  $c_j$  sont respectivement la dispersion et la position du centre (vecteur de dimension  $p = 2$ ) de la gaussienne. L'utilisation de fonctions d'activation gaussiennes est motivée par la répartition des données réduites normalisées dans la région  $[0 : 1] \times [0 : 1]$ . En dimension  $p = 2$ , les séparatrices des gaussiennes divisent l'espace de projection selon des arcs de cercles ou des droites selon les paramètres de ces gaussiennes.

$$G_j(x) = \frac{1}{d_j \sqrt{2\pi}} \cdot e^{\left( -\frac{(x-c_j)^T(x-c_j)}{2d_j^2} \right)} \quad (5.2)$$

Dans ce qui suit nous noterons  $N_A$  le nombre d'échantillons dans  $E_{RN}$ . L'apprentissage est une étape très importante dans la construction d'un réseau de neurones, elle permet d'ajuster les paramètres du réseau jusqu'à convergence de la sortie à l'aide des échantillons d'apprentissage. Dans le réseau de neurones gaussiens proposé, la position des centres des gaussiennes, la dispersion des gaussiennes et le nombre de gaussiennes associées à chacune des classes sont successivement adaptés. Pendant la phase d'apprentissage, le réseau calcule sa sortie en fonction des vecteurs présentés. Un algorithme d'apprentissage supervisé est utilisé pour entraîner

le réseau avec les données de la base d'apprentissage réduites et normalisées  $E_{RN}$ . L'ensemble d'apprentissage peut donc être divisé en  $N_C$  sous ensembles disjoints qui regroupent les échantillons issus de chacune des classes :  $E_{RN} = E_{RN}^1 \cup \dots \cup E_{RN}^{N_C}$ . L'algorithme comporte une phase d'initialisation et des phases d'adaptation pour déplacer les centres des fonctions gaussiennes, pour ajuster leurs dispersions et finalement pour ajouter des gaussiennes représentatives de certaines classes lorsque cela est nécessaire. Un nombre maximal d'itérations  $K_{max}$  est considéré.

L'algorithme est initialisé avec un nombre de neurones égal au nombre de classes :  $N_G = N_C$ . L'algorithme étant supervisé, les centres  $c_j$  des gaussiennes sont initialisés pour coïncider avec les barycentres des nuages de points  $E_{RN}^j$  représentatifs de chacune des classes. Les dispersions  $d_j$  sont initialisées de façon arbitraire avec l'écart type de chacun des nuages de point  $E_{RN}^j$ . À chaque itération, la performance du réseau est mesurée en évaluant les taux d'erreur de classification. On note  $E(j, k)$  la proportion d'échantillons de  $E_{RN}^j$ , qui active une gaussienne représentative de la classe  $k$ . L'erreur moyenne de classification est donnée par l'équation 5.3.

$$E_m = \frac{1}{N_C(N_C - 1)} \left( \sum_{\substack{j=1, \\ k=1 \\ k \neq j}}^{N_C} E(j, k) \right) \quad (5.3)$$

### 5.4.2 Adaptation de la position des centres des gaussiennes

L'adaptation des centres des fonctions gaussiennes consiste à répartir les gaussiennes associées à chacune des classes en fonction des échantillons d'apprentissage. On note  $g(x)$  la gaussienne la plus représentative de  $x$  et  $N_A^j(k)$  le nombre d'échantillons de  $E_{RN}^j$  qui appartiennent au domaine d'activation de la fonction gaussienne  $G_k$ . Pour chaque classe  $j$  et chaque échantillon  $x \in E_{RN}^j$ ,  $g(x)$  est déterminé selon l'équation 5.4 avec  $k = 1, \dots, N_G^k$ . Le centre de la fonction gaussienne est déplacé selon l'équation 5.5.  $\alpha$  est un paramètre de gain choisi par l'utilisateur. Pour chaque échantillon, l'algorithme d'adaptation des centres permet de dé-



terminer le neurone le plus proche, considéré comme le plus représentatif de l'échantillon. La procédure est itérée jusqu'à atteindre une position stable des gaussiennes ou un nombre maximal d'itérations  $K_{max}$ . L'adaptation des centres des fonctions gaussiennes est nécessaire pour (1) repositionner correctement le centre lorsqu'une nouvelle gaussienne est ajoutée dans une classe (2) pour « suivre » un nuage de points qui se déplace dans l'espace de représentation (l'évolution d'un défaut par exemple). L'ajout de gaussiennes est conditionné par un taux  $\rho$  tenant compte de la mauvaise classification. Dans ce cas, le barycentre du nuage de points représentant le défaut se déplace et les gaussiennes associées à la classe considérée doivent aussi pouvoir se déplacer.

$$g(x) = arg(max_k \{G_k(x)\}, k = 1, \dots, N_G^k) \quad (5.4)$$

$$\Delta c_g(x) = \frac{\alpha(c_g(x) - x)}{N_A^j(g(x))} \quad (5.5)$$

### 5.4.3 Adaptation de la dispersion des gaussiennes

L'adaptation de la dispersion des gaussiennes se fait par essai – erreur. En effet la dispersion est un paramètre qui influence fortement la forme des régions d'activation des différentes gaussiennes en déplaçant les séparatrices. Lorsqu'une dispersion est modifiée pour améliorer localement la séparation entre deux gaussiennes, l'ensemble des régions d'activation est affecté (cette difficulté augmente avec le nombre de classes). Il est donc difficile de trouver une règle d'adaptation systématique des dispersions. Pour cette raison, nous évaluons la performance du réseau en calculant le taux moyen  $E_m$  d'erreur de classification (équation 5.3) en augmentant ou en diminuant la dispersion de chacune des gaussiennes et en retenant l'adaptation qui améliore la performance moyenne. La dispersion retenue sera celle qui minimisera  $E_m$ . Elle est obtenue par l'équation 5.6 dans laquelle  $\gamma$  représente la correction de la dispersion.  $\beta$  est un paramètre de gain proche de 0 choisi par l'utilisateur. Lorsque les nuages de points correspondants à chacune des classes ne sont pas disjoints, l'adaptation des dispersions permet

d'optimiser les performances dans les régions communes à plusieurs classes.

$$\gamma = \arg(\min_{\{1, 1+\beta, 1-\beta\}} \{E_m(d_j), E_m(d_j(1+\beta)), E_m(d_j(1-\beta))\}, j = 1, \dots, N_C) \quad (5.6)$$

$$d_j \leq \gamma \cdot d_j \quad (5.7)$$

#### 5.4.4 Adaptation du nombre de gaussiennes associées à chaque classe

Lorsque le taux d'erreur de classification  $E(j, k)$  entre la classe  $j$  et la région d'activation des gaussiennes associées à la classe  $k$  est significatif (c'est-à-dire supérieur à un seuil  $\rho$  fixé par l'utilisateur), un neurone supplémentaire est ajouté dans la classe  $j$ . Le centre de la nouvelle fonction gaussienne est initialisé pour coïncider avec le barycentre du nuage des échantillons de  $E_{RN}^j$  classés dans la classe  $k$ . La dispersion est initialisée de façon arbitraire avec l'écart type du nuage de ces échantillons. La procédure d'ajout est itérée tant que la performance moyenne du réseau est améliorée. Dans le cas où les classes ne correspondent pas à des régions connexes, l'ajout de gaussiennes supplémentaires permet une meilleure séparation des classes. L'algorithme présenté par la figure 5.2 donne les différentes étapes de l'apprentissage du réseau de neurones gaussiens.

#### 5.4.5 Classification d'un échantillon

Après apprentissage les paramètres du réseau sont mémorisés et le réseau peut classer de nouveaux échantillons. Pour chaque échantillon  $x$  de la base de validation, la probabilité  $P_k(x)$  d'appartenance à la classe  $k$  est obtenue avec l'équation 5.8.

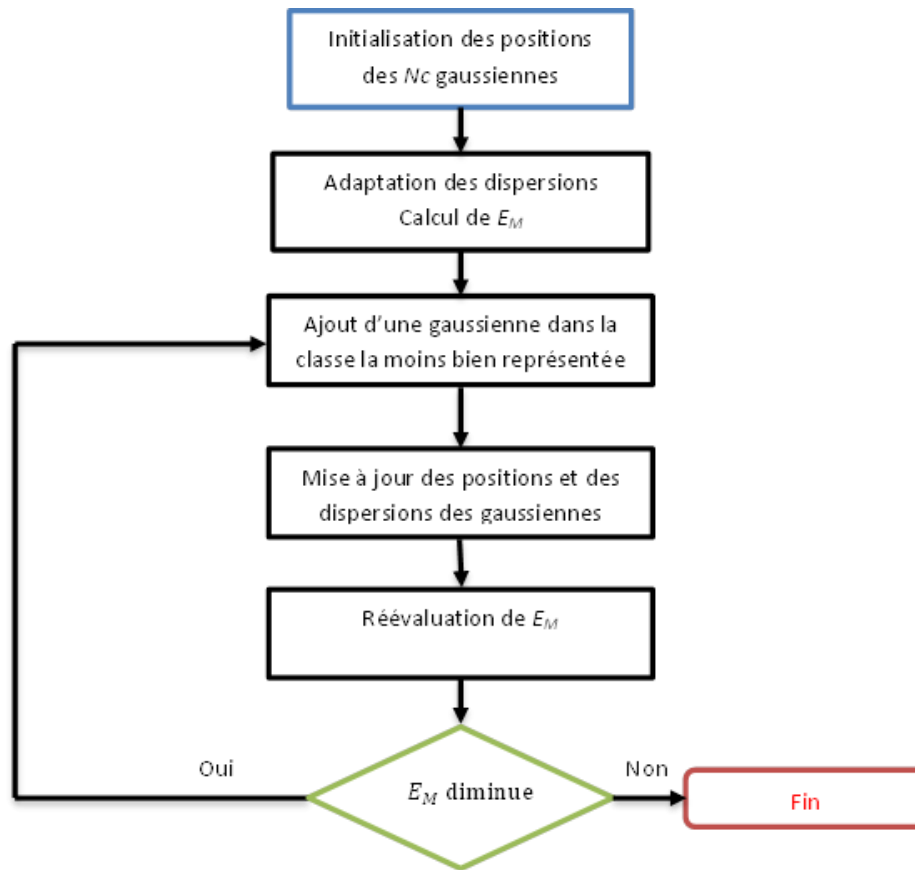


FIGURE 5.2: Algorithme d'apprentissage du réseau de neurones à noyau gaussien

$$P_k(x) = \frac{G_j(x)}{\sum_{i=1}^{N_C} G_k(x)}, j = 1, \dots, N_C \quad (5.8)$$

L'échantillon  $x$  est finalement classé selon le maximum des probabilités d'appartenance aux différentes classes (équation 5.9).

$$classe(x) = \arg(\max(P_k(x)), k = 1, \dots, N_C) \quad (5.9)$$

Pour un vecteur issu de la base de validation, une probabilité d'appartenance à chacune des classes obtenue lors de l'apprentissage est évaluée (équation 5.8). La classe du vecteur est obtenue en obtenue par le maximum de toutes les probabilités d'appartenance aux différentes

classes (équation 5.8). Les résultats de la détection ou du diagnostic sont représentés dans un tableau croisé appelé matrice de confusion. Dans ce tableau la première colonne représente les échantillons de plaques (exemple : fissure, trou, . . . , etc.) et la première ligne la classe d'appartenance de l'échantillon. La diagonale représente le taux de bonne classification pour chaque échantillon.

## 5.5 Détection et diagnostic des défauts dans les plaques immergées par réseaux de neurones gaussiens

### 5.5.1 Protocole d'expérimentation et constitution de la base d'apprentissage

Quatre plaques de référence ont été utilisées pour constituer l'ensemble d'apprentissage. Ces plaques ont les mêmes dimensions ( $L = 60$  mm, épaisseur  $e = 1,5$  mm) et les mêmes propriétés physiques mais se distinguent par la présence et la nature des défauts qu'elles présentent. Les échantillons issus des différentes plaques sont distingués par différents symboles :

- Plaque  $P_0$  sans défaut : astérisque
- Plaque  $P_1$  avec une fissure débouchante : astérisque
- Plaque  $P_2$  avec une fissure fine : cercle
- Plaque  $P_3$  avec un trou : triangle

Sur les 3 plaques défectueuses, les défauts ont été artificiellement positionnés à  $\delta = 2/3$  de l'extrémité  $E_1$ . Les intervalles utiles et les motifs de défauts (une fenêtre centrée autour de la position du défaut) sont extraits selon le modèle et la méthode précédemment présentés : 42 motifs sont extraits de chacune des 4 plaques. Pour chaque échantillon, les 7 paramètres présentés dans le chapitre 2 sont calculés. L'ensemble d'apprentissage  $E$  obtenu est donc constitué de 168 échantillons et chaque échantillon est un vecteur composé des 7 paramètres. À l'issue

de l'analyse en composantes principales et de la normalisation, une base d'apprentissage normalisée réduite  $E_{NR}$  est obtenue. Cette base comporte 168 échantillons de taille 2. Les deux combinaisons linéaires retenues pour extraire les composantes principales sont représentées par des vecteurs lignes  $c1$  et  $c2$  et constituent le projecteur  $C = [c1^T \ c2^T]^T$ .

La figure 5.3 donne la dispersion obtenue dans le plan variance-skewness pour les quatre classes sans utiliser l'ACP (figure 5.3(A)) et en utilisant l'ACP (figure 5.3(B)). Nous pouvons déduire alors l'utilité de l'ACP dans la procédure de classification pour la détection et le diagnostic de défaut.

Cette analyse montre que l'énergie du motif et son maximum en valeur absolue sont particulièrement discriminants. On peut constater immédiatement l'intérêt d'inclure l'analyse en composantes principales dans le prétraitement : les échantillons issus de plaques différentes sont non séparables si la projection est mal choisie. De plus, les ordres de grandeur des paramètres sont différents selon les échantillons et les composantes.

Après apprentissage, les performances du réseau sont évaluées sur un nouvel ensemble constitué des plaques de l'ensemble (1) du chapitre 3 et de deux autres plaques similaires comportant respectivement une fine fissure et un trou. Au total, 4 plaques sont utilisées dont une plaque saine. L'ensemble de validation  $E_T$  est composé de 172 échantillons. L'intérêt de séparer la détection et le diagnostic est de limiter la taille des réseaux utilisés.

## 5.5.2 Résultat de la détection

La détection est réalisée à l'aide d'un réseau gaussien qui réalise la classification selon  $N_C = 2$  classes. L'apprentissage résulte donc de l'agrégation de tous les motifs de défauts dans une classe unique (classe 1) :

- Les motifs sans défaut (classe 0) : croix
- Les motifs défectueux (classe 1) : étoiles

L'algorithme est initialisé avec 2 gaussiennes centrées sur les barycentres des 2 classes (figure 5.4 (A)). Pendant l'apprentissage, une troisième gaussienne, associée à la classe 1, est




FIGURE 5.3: Projection de l'ensemble  $E$  dans le plan (variance, skewness), (A) sans utilisé l'analyse en composantes principales, (B) en utilisant l'analyse en composantes principales

automatiquement créée.




FIGURE 5.4: Détection des défauts : a) initialisation du réseau ; b) après apprentissage

Son centre et sa dispersion sont adaptés pour mieux représenter les échantillons de défauts (figure 5.4(B)). Les résultats de détection sur l'ensemble d'apprentissage et sur l'ensemble de test sont présentés dans le tableau 5.1. Les performances du réseau de détection sont détaillées dans les cellules sur la diagonale du tableau. Le taux moyen de bonne classification est 87 % et 80 % respectivement en phases d'apprentissage et de test. Le taux de fausses alarmes correspond à la proportion de motifs sains reconnus à tort dans la classe 1. Symétriquement, le taux de non détections correspond à la proportion de motifs avec défauts reconnus à tort dans la classe 0. On peut constater que le réseau privilégie la réduction du taux de non détections (de l'ordre de 7 %) plutôt que celle du taux de fausses alarmes (de l'ordre de 25 %). Des coefficients de pondération peuvent être utilisés avec l'équation 5.3 afin de modifier ces performances. Une courbe opérationnelle de réception permet de déterminer les pondérations les mieux adaptées à notre problème.

	Classe 0	Classe 1
Motifs sans défaut	Apprentissage : 81 %	Apprentissage : 19 %
	Test : 67 %	Test : 33 %
Motifs avec défaut	Apprentissage : 7 %	Apprentissage : 93 %
	Test : 8 %	Test : 92 %

TABLE 5.1: Résultats de détection des défauts pour les données d'apprentissage et de validation (Test)

### 5.5.3 Résultat du diagnostic

Le diagnostic est également réalisé à l'aide d'un réseau gaussien qui réalise la classification des motifs pour lesquels un défaut a été détecté selon  $N_C = 3$  classes :

- Motifs avec une fissure débouchante (classe 1) : étoile en bas de la figure
- Motifs avec une fissure fine (classe 2) : cercle (motif ovale au milieu de la figure)
- Motifs avec un trou (classe 3) : triangle (en haut de la figure)

Seuls les motifs, pour lesquels un défaut a été détecté, sont diagnostiqués. Le même algorithme est utilisé pour l'apprentissage du réseau de diagnostic. Ce réseau est initialisé avec 3



gaussiennes centrées sur le barycentre des 3 classes. Après apprentissage, le réseau conserve la même taille. Les positions et les dispersions des gaussiennes sont adaptées selon les échantillons de défauts (figure 5.5). Les résultats de diagnostic sur l'ensemble d'apprentissage et sur l'ensemble de test sont présentés dans le tableau 5.2. Pour chaque groupe de motifs, ce tableau 5.2 détaille les performances du réseau de classification (dans les cellules sur la diagonale du tableau) et les taux d'erreur de classification pour chacune des classes. Les performances obtenues pour la fissure débouchante et le trou sont élevées (de l'ordre respectivement de 87 % et 90 %). Mais nous constatons une dégradation significative des performances en ce qui concerne la fissure (taux de classification de l'ordre de 67 %). Nous expliquons cette dégradation car la fissure correspond à une rayure de la plaque alors que la fissure débouchante et le trou sont des dégradations beaucoup plus marquées : notamment ces deux défauts sont débouchants.




FIGURE 5.5: Diagnostic des défauts : domaine d'activation des gaussiennes après apprentissage

	Classe 1	Classe 2	Classe 3
Motifs avec une fissure débouchante	Appr : 88 %	Appr : 10 %	Appr : 2 %
	Test : 86 %	Test : 12 %	Test : 2 %
Motifs avec une fissure	Appr : 17 %	Appr. : 71 %	Appr : 12 %
	Test : 21 %	Test : 65 %	Test : 14 %
Motifs avec un trou	Appr : 5 %	Appr. : 5 %	Appr. : 90 %
	Test : 7 %	Test : 2 %	Test : 91 %

TABLE 5.2: Résultats de diagnostic des défauts pour les données d'apprentissage (Appr.) et de validation (Test)

Au delà des performances obtenues, l'approche proposée reste conditionnée par le choix de plusieurs paramètres déterminants (tableau 5.3).

Paramètre	Valeur	Observation
$k$	3	Détermine la première extrémité de la plaque
$\tau$	0.2	Proportion de la plage utile servant à extraire les motifs
$p$	2	Nombre de composantes extraites
$\alpha$	0.6	coefficient d'adaptation de la position des centres
$\beta$	0.1	coefficient d'adaptation de la dispersion des centres
$\rho$	0.1	Taux de MC déclenchant le rajout d'une nouvelle gaussienne

TABLE 5.3: Paramètres de la méthode proposée

## 5.6 Classification par extraction de la transformée en ondelette continue

Dans cette section, la détection de défaut basée sur l'utilisation de la transformée en ondelette a été élaborée. Pour cela, l'équation 3.8 a été utilisée. Les paramètres  $a$  et  $b$  sont respectivement l'échelle et le paramètre de translation de l'ondelette mère,  $b$  est défini plus petit que la longueur de la plage utile  $[t_{E_1} : t_{E_2}]$ .

La convolution de l'ondelette mère avec la plage utile (figure 5.6 (a)) représentative du signal est réalisée à différentes échelles. Parmi les différents types d'ondelettes (Meyer, Morlet, chapeau mexicain, Haar, ..., etc, notre choix s'est porté sur l'ondelette de Morlet (Figure 5.6 (b)).

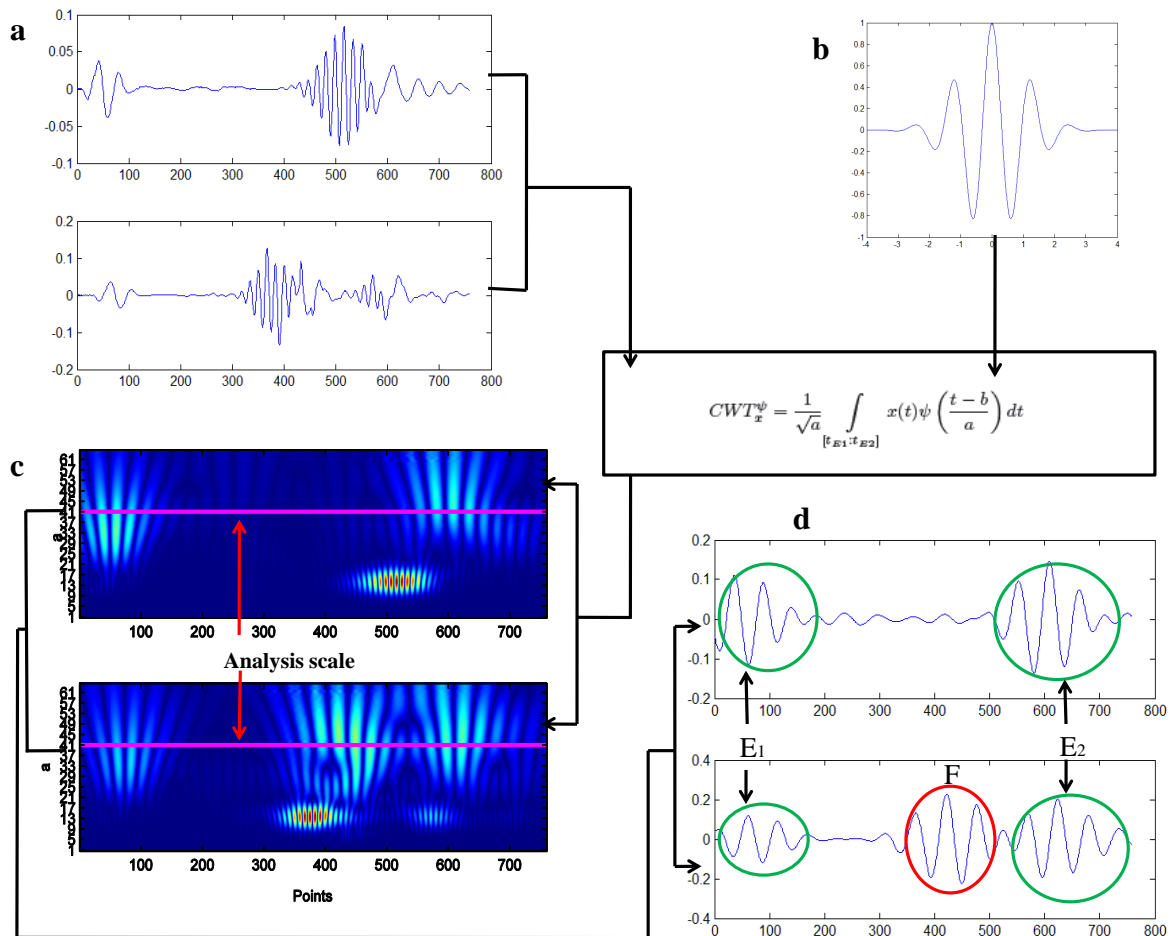


FIGURE 5.6: Procédure de calcul des coefficients d'ondelette pour un défaut vertical sous incidence de  $50^\circ$

Ce choix est motivé par sa similarité avec le signal émis. Un ensemble de coefficients est obtenu pour un même segment utile mais à différentes échelles. La figure 5.6 (c) présente l'amplitude des coefficients d'ondelette en fonction des paramètres  $a$  et  $b$  respectivement pour le signal de référence (haut) et de test (bas). Pour chaque valeur de  $a$  et  $b$ , correspond une amplitude de couleur comprise entre le rouge et le bleu. La couleur bleu correspond aux coefficients d'ondelette de faible valeur absolue et le rouge correspond aux coefficients de forte valeur absolue. Dans cette procédure (Figure 5.6(c)), la meilleure échelle est choisie selon le calcul de la valeur maximale de l'amplitude [Park et al., 2009]. Cette échelle est utilisée pour l'extraction des caractéristiques des signaux dans la plage utile (Figure 5.6(d)).

Pour valider cette méthode, deux échantillons de plaques  $P_1$  et  $P_3$  (table : 5.4) ont été

utilisées. La plaque  $P_2$  est testée conformément à la plaque de référence  $P_1$  et la plaque  $P_4$  est testée conformément à la plaque  $P_3$ .

Pour la plaque  $P_2$ , le défaut est de type vertical et situé à 20 mm de la deuxième extrémité. La plaque  $P_4$  comporte un défaut de type oblique. La notion de défaut vertical ou oblique dépend de la direction du faisceau ultrasonore émis par le transducteur.




FIGURE 5.7:  $P_2$  : (gauche),  $P_4$  :( droite)

Les résultats obtenus sont donnés par les tableaux et matrices définis dans les prochaines sections.

Plaques	paramètres	Classes
$P_1$		<i>Saine</i>
$P_2$	$L = 60 \text{ mm}$	<i>CR</i>
$P_3$		<i>Saine</i>
$P_4$	$L = 194 \text{ mm}$	<i>CR<sub>OBL</sub></i>

TABLE 5.4: Paramètres des plaques utilisées

### 5.6.1 Défaut vertical

Nous nous intéressons dans cette section à la classification des défauts de la plaque  $P_1$  et  $P_2$ . Pour ces plaques, la plage des angles interdits est comprise entre  $[88^\circ - 91^\circ]$ . Par conséquent la procédure de détection de défaut est restreinte à l'intervalle  $[0^\circ - 88^\circ]$   $[92^\circ - 180^\circ]$ . Finalement, la plage d'incidence angulaire est limitée à l'intervalle  $[0^\circ - 88^\circ]$  en tenant compte de la symétrie des plaques. Sans utiliser la transformée en ondelette continue, la répartition des échantillons Saine-fissure (verticale) est donnée sur la figure 5.8.

On distingue deux nuages de points et les performances obtenues à l'issue de la détection de défaut sont données par le tableau 5.5. En moyenne, le taux de classification est de 89%. Le taux de fausses alarmes s'élève à 17% et le taux de non détections est de l'ordre de 5%.




FIGURE 5.8: Répartition des échantillons sains et avec fissure verticale sans la transformée en ondelette

En utilisant la transformée en ondelette dans la procédure de détection, les résultats obtenus

	Saine	défaut vertical
$P_1$	83 %	17%
$P_2$	5 %	95 %

TABLE 5.5: Matrice confusion : saine et défaut vertical sans transformée en ondelette

sont donnés sur la figure 5.9 et la matrice de confusion 5.6. On remarque que les deux classes sont encore mieux séparées, par conséquent les performances de la détection sont meilleures par comparaison à la procédure de détection sans la transformée en ondelette. En moyenne, le taux de classification est de 96%. Les taux de fausses alarmes et de non détections sont respectivement de 5% et 2%. On peut conclure que l'utilisation de la transformée en ondelette augmente les performance de détection des défauts de type vertical.




FIGURE 5.9: Répartition des échantillons sains et avec défaut vertical en utilisant la transformée en ondelette

	Saine	défaut vertical
$P_1$	95 %	5%
$P_2$	2 %	98 %

TABLE 5.6: Matrice de confusion en utilisant de la transformée en ondelette

### 5.6.2 Défaut Oblique

Sans utiliser la transformée en ondelette, la répartition des échantillons issus de plaques saines et avec défaut oblique est donnée par la figure 5.10. Il est impossible de distinguer les classes car un seul nuage de points est observé. Les performances obtenues à l'issue de la détection de défauts sont données par le tableau 5.7. En moyenne, le taux de classification est de 57%. Le taux de fausses alarmes et de non détections sont respectivement 55% et 30%. La détection directe sans l'utilisation de la transformée ne résout pas ce problème.




FIGURE 5.10: Répartition des échantillons issus de la plaque saine et avec défaut oblique sans utiliser la transformée en ondelette

	Saine	défaut oblique
$P_3$	45 %	55%
$P_4$	30 %	70 %

TABLE 5.7: Matrice de confusion : saine et défaut oblique sans la transformée en ondelette

En utilisant la transformée en ondelette dans la procédure de détection, les résultats obtenus sont donnés par la figure 5.11 et la matrice de confusion 5.8. On distingue deux nuages de points distincts et par conséquent les deux classes sont bien séparées.




FIGURE 5.11: Répartition des échantillons de plaque saine et avec défaut oblique en utilisant la transformée en ondelette

	Saine	défaut oblique
$P_3$	98 %	2%
$P_4$	0 %	100 %

TABLE 5.8: Matrice de confusion : saine et défaut oblique avec utilisant la transformée en ondelette



En moyenne, le taux de classification est de 99%. Le taux de fausses alarmes est de 2% et le taux de non détections est de 0% et 2%. On peut conclure que l'utilisation de la transformée en ondelette résout le problème de la détection de défaut oblique. Afin de valider cette étude, d'autres types d'ondelette mères ont été utilisés. En moyenne, les résultats obtenus sont : 97%, 93% et 84% respectivement pour les ondelettes de *Meyer*, *chapeau Mexican* et *Bior*. L'ondelette de *Morlet* est celle qui a donnée les meilleures performances en raison de sa forte ressemblance avec le signal émis. Notons toutefois qu'au delà des performances obtenues, l'approche proposée reste conditionnée par le choix de plusieurs paramètres déterminants (tableau 5.9) avec MC : Mauvaise Classification. Notons aussi que l'utilisation de la transformée en ondelette est d'une importance capitale dans la détection de défaut oblique et le choix de l'ondelette mère est une étape cruciale dans l'utilisation de cet outil.

Paramètres	valeur	Observation
$k$	3	Détermine la première extrémité de la plaque
$\tau$	0.2	Proportion de la plage utile servant à extraire les motifs
$p$	2	Nombre de composantes extraites
$\alpha$	0.6	Adaptation de la position des centres
$\beta$	0.1	Adaptation de la dispersion des centres
$\rho$	0.1	Taux de MC déclenchant le rajout d'une nouvelle gaussienne

TABLE 5.9: Paramètres de la méthode proposée

## 5.7 Détection et diagnostic par mesures moyennées

### 5.7.1 Principe de la méthode

Deux réseaux de neurones gaussiens sont utilisés en cascade comme le montre le schéma global 5.1 de la procédure de détection et de diagnostic de défaut. Pour chaque type de défaut, les bases d'apprentissage et de test sont construites en utilisant les signaux issus des échantillons de plaques. Dans un premier temps, la procédure de traitement de signaux est appliquée aux signaux bruts. Ensuite, le réseau de neurones gaussiens de détection de défaut avec deux entrées est utilisé. Le but de cette étape est de séparer les motifs de défauts des motifs sains.

Quand plusieurs défauts existent, un second réseau de neurones gaussiens de diagnostic est utilisé avec  $n$  entrées ( $n$  étant le nombre de classes avec défaut). Le but de cette étape est la séparation de différentes classes de défaut. Le schéma global est quasi similaire à celui utilisé précédemment (figure 5.1). Par comparaison avec d'autres méthodes qui utilisent une image complète de la plaque avec tous les angles d'incidence, la méthode proposée est basée sur un faible nombre de mesures et plus facile à mettre en œuvre pour des analyses in-situ. Afin d'augmenter les performances de la détection et du diagnostic, plusieurs mesures de la même plaque sont considérées sous des angles d'incidence différents. Soit  $n_{mes}$  le nombre de mesures utilisées pour la prise de décision. Dans ce cas, la probabilité  $c_q$  (équation 5.8) que la plaque considérée appartient à la classe  $q$  est une moyenne sur l'ensemble des mesures  $x_1, \dots, x_{n_{mes},k}$  considérées [Sidibe et al., 2015]. Le reste de la méthode reste inchangé.

### 5.7.2 Résultats obtenus

Les structures étudiées sont les plaques rectangulaires ou des croix inoxydables. Trois groupes de structures sont utilisés et la largeur  $L$  dépend du groupe. Le groupe (1) constitué de quatre plaques est celui utilisé dans le chapitre 3. La plaque labellisée (*REF1*) est celle de référence, c'est à dire sans aucun défaut géométrique. Les autres plaques ont différentes classes de défaut énumérées comme suit : le défaut de type trou (*TR*), fine fissure (*FF*) et large fissure (*LF*). Ces plaques ont la même largeur  $L = 60\text{mm}$  et les défauts sont situés à une distance de 20 mm de l'extrémité gauche de la plaque. Ce groupe est utilisé pour évaluer la performance de la méthode dans le problème de diagnostic (à savoir l'identification de la classe de défaut).

Le groupe (2) également utilisé dans le chapitre 3. Il contient quatre plaques de même largeur  $L = 194\text{mm}$ . La première plaque est celle de référence (*REF2*) sans aucun défaut géométrique. Les autres plaques ont le même type de défaut : une large fissure (*GF*) située à différentes positions dans la plaque (respectivement 17 mm, 52 mm et 71 mm de l'extrémité gauche de la plaque). Ce groupe est utilisé pour évaluer la performance de la méthode sur

les problèmes de détection. Le groupe (3) contient deux structures en croix fabriquées par l'assemblage de 4 plaques. La dimension de ces croix est de 100mm. La première croix est saine et sur la seconde est réalisé un trou. Ce groupe est utilisé pour illustrer les défauts dans des structures géométriques plus complexes.

Les tableaux 5.10, 5.12, 5.13 et 5.11 donnent les performances de la méthode proposée pour chaque groupe de structures. Ces performances ont été obtenues en utilisant  $n_{mes} = 5$  (nombre de mesures sous différents angles d'incidence). Le nombre d'essais est de 1000 pour chaque groupe de structures. Notez également que la segmentation a été simplifiée afin de se concentrer sur les segments qui sont centrés sur les échos de bords et des défauts. Pour chaque groupe, les structures testées sont représentés dans différentes lignes, et les classes sont représentées dans les différentes colonnes.

Par exemple, le groupe (1) est constitué des plaques  $P_1$  à  $P_4$  dont les échantillons peuvent être classés comme sains ou défectueux. Ensuite, le diagnostic est réalisé pour séparer les différentes classes défectueuses. Dans les tableaux de résultat, les lignes représentent les échantillons et les colonnes sont les classes d'appartenance.

Dans la procédure de détection de défaut en utilisant le groupe (1), le taux de fausses alarmes est de 6%.

Ce taux représente le pourcentage de mesures issues de la plaque saine ( $P_1$ ) classés comme défectueuses ( $P_{2,3,4}$ ). Le taux de non-détection est de 30% qui traduit la classification des mesures provenant des plaques  $P_2$ ,  $P_3$  et  $P_4$  comme saines.

Le tableau 5.10 résume ces performances. Ce mauvais résultat s'explique par la mauvaise détection du trou, qui se comporte comme diffuseur notamment à cause de sa faible dimension (diamètre d'environ 1 mm). Lorsque le trou n'est pas pris en compte dans la procédure de détection, le taux de détection est supérieur à 95%.

Les performances pour la détection des défauts des groupes (2) et (3) sont données par les tableaux 5.12 et 5.13. Considérons maintenant le diagnostic effectué sur les mesures issues de plaques  $P_2$ ,  $P_3$  et  $P_4$  classés comme défectueuse (tableau 5.11). Les taux de classification sont

	Saine	défectueuse
$P_1$	94%	6%
$P_{2,3,4}$	30%	70%

TABLE 5.10: Matrice de confusion de la détection du groupe 1

	$TR$	$FF$	$LF$
$P_2$	97%	3%	0%
$P_3$	6%	88%	6%
$P_4$	0%	13%	87%

TABLE 5.11: Matrice de confusion du diagnostic du groupe 1

respectivement 97%, 89% et 87% pour le trou, la fine fissure et large fissure.

	Saine	Avec défaut
$P_5$	99%	1%
$P_{6,7,8}$	16%	84%

TABLE 5.12: Matrice de confusion de la détection pour le groupe 2

	Saine	Avec défaut
$P_5$	78%	22%
$P_{6,7,8}$	19%	81%

TABLE 5.13: Matrice de confusion de détection du groupe 3

L'approche proposée est conditionnée par les paramètres détaillés dans le tableau 5.14.

Paramètres	Valeurs	Définition
$p$	2	Nombre de composante principale
$\alpha$	0.6	Paramètre d'adaptation du centre de gaussienne
$\beta$	0.1	Paramètre d'adaptation de la dispersion de gaussienne
$w$	50 points	Taille du segment extrait du groupe I
	100 points	Taille du segment extrait du groupe II
	150 points	Taille du segment extrait du groupe III

TABLE 5.14: Caractéristiques des différents groupes d'échantillons

Afin d'évaluer la qualité des résultats précédents, la figure 5.12 illustre les performances de détection pour les trois groupes d'échantillons de plaques utilisées par rapport aux nombre de

mesures  $n_{mes}$ . Notons que les performances du groupes (1) n'excèdent pas 0,83 à cause de la non détection de quelque défauts.




FIGURE 5.12: Influence du nombre de mesures

Nous pouvons conclure que la méthode proposée est efficace d'une part pour les structures simples et d'autre part sur les structures plus complexes et elle est applicable pour une large plage d'incidence angulaire. Son avantage se situe dans sa capacité d'analyse d'informations multivariées sous différents angles d'incidence. Il faut toutefois souligner que la détection de la fissure oblique nécessite l'utilisation de la transformée en ondelette afin d'augmenter la qualité des signaux acquis.

## 5.8 Conclusion

Dans ce chapitre, nous avons proposé une méthode de diagnostic des structures immergées en combinant des outils du traitement du signal et de l'intelligence artificielle. L'approche s'est avérée efficace dans la détection et le diagnostic des défauts géométriques simples sur des structures élémentaires. Comparée aux méthodes usuelles de diagnostic de systèmes dans lesquelles des capteurs sont positionnés sur des éléments faisant l'objet du contrôle, notre approche permet de réaliser un diagnostic rapide des défauts mécaniques sans le moindre contact. Notre approche permettra donc de réduire considérablement le coût des inspections en remplaçant la mise hors immersion de l'hydrolienne par un dispositif fonctionnant en environnement marin. Par comparaison aux travaux qui utilisent des techniques de diagnostic passif à base d'acoustique ultrasonore [Chen et al., 2000], notre méthode est moins performante. Il faut cependant signaler que la classification réalisée avec la plupart de ces méthodes consiste à distinguer des objets de nature très différente (différents type de bateaux ou de mammifères marins) ce qui constitue un problème de classification moins difficile. Enfin les résultats présentés s'affranchissent de la connaissance de l'angle de la mesure, ce qui est aussi une avancée significative. D'autre part, la transformée en ondelette a été associée à la procédure de détection et a permis la détection de défauts de nature oblique pour laquelle les signaux acquis sont complexes à exploiter. Le choix de l'ondelette d'analyse reste une étape cruciale dans cette approche.



Les résultats obtenus dans ce mémoire de thèse constituent une contribution à l'aide à la décision pour la détection de défauts dans les structures en immersion dont l'accès est difficile. L'étude réalisée nous a permis de montrer que la détection et le diagnostic des défauts dans les plaques métalliques immergées à l'aide des ondes de Lamb est possible. L'utilisation des réseaux de neurones conduit à des résultats satisfaisants. D'un point de vue pratique, nous avons mis en place deux méthodes de détection et de diagnostic de défaut :

**À base de modèle de référence** qui s'appuie sur la génération de résidus et se compose en deux sous méthodes :

La première associe des seuils pour l'extraction du segment utile des signaux enregistrés. Elle présente l'avantage d'être simple à mettre en place et présente ses limites quand il s'agit de l'automatisation des tâches pour lesquelles elle est dédiée. La seconde est basée sur une alternative pour la détection systématique du segment utile par utilisation d'un réseau de neurones gaussiens pour la détection des échos d'extrémités dans les signaux de mesure. A cela s'ajoute la détection et la localisation de défaut par traitement d'images qui a également conduit à des résultats très encourageants.

**Sans modèle de référence** qui est basée exclusivement sur l'utilisation de réseau de neu-



rones gaussiens. L'avantage d'utiliser cette méthode réside dans sa capacité de généralisation du problème de détection et de diagnostic. Elle constitue une alternative de résolution aux problèmes de détection et de diagnostic dans les systèmes lorsque la mise en place d'un modèle théorique est compliquée voir impossible. Le choix du type de réseau, en l'occurrence le réseau de neurones gaussiens, a été discuté. Le choix des échantillons des plaques a été réalisé en fonction des objectifs recherchés (détection pour différentes positions de défauts, diagnostic pour différents types de défauts). La détection associant la transformée en ondelette et la méthode portant sur la décision en moyennant un certains nombre de mesures ont été également abordées.

En perspective, ces travaux peuvent être généralisés pour la surveillance des structures plus complexes en immersion (hydroliennes) pour lesquelles les méthodes classiques sont soit trop coûteuses soit nécessitent une durée importante pour les tâches de détection et de diagnostic de défaut.

Plusieurs améliorations seront étudiées dans la suite de nos travaux. La génération automatique de nouvelles classes et l'élimination systématique de mesures aberrantes seront étudiées pour l'application considérée. Pour ce faire, un indice de confiance sera évalué et associé aux décisions des réseaux de classification. Notons aussi que l'effort pour s'affranchir d'un repérage précis de l'orientation et des dimensions des objets analysés devra être poursuivi. Des structures plus complexes, d'orientations inconnues avec de multiples défauts seront étudiées. Cette généralisation nous permettra de nous rapprocher des conditions réelles de surveillance des sites hydroliens par acoustique ultrasonore pour lesquels les acquisitions seront réalisées à bord de navires en mouvement.

Une comparaison des résultats avec d'autres méthodes de segmentation sera mise en œuvre et détaillée. Une amélioration basée sur la décomposition en ondelettes, la décomposition en Mode Empirique EMD et d'autres transformations temps-fréquence sera également considérées.

## BIBLIOGRAPHIE

- [Adjallah, 1993] Adjallah, K. (1993). *Contribution au diagnostic des systèmes par observateur d'état*.
- [Baillard et al., 2008] Baillard, A., Chiumia, J., Décultot, D., Maze, G., Klauson, A., and Met-saveer, J. (2008). Surface wave conversion analysis on a lengthwise soldered circular cylindrical shell. *The Journal of the Acoustical Society of America*, 124(4) :pages 2061–2067.
- [Barakat et al., 2011] Barakat, M., Druaux, F., Lefebvre, D., Khalil, M., and Mustapha, O. (2011). Self adaptive growing neural network classifier for faults detection and diagnosis. *Neurocomputing*, 74(18) :pages 3865–3876.
- [Bentoumi, 2004] Bentoumi, M. (2004). *Tools for detection and classification :Application to the diagnosis of rail surface defect*. Thèse, Université Henri Poincaré - Nancy I.
- [Berer et al., 2012] Berer, T., Grun, H., Bauer-Marschallinger, J., Burgholzer, P., Passler, K., Nuster, R., and Paltauf, G. (2012). Dual mode photoacoustic/acoustic microscopy with optical generation and detection. In *Ultrasonics Symposium (IUS), 2012 IEEE International Dresden Germany*, pages 1–4.
- [Chen et al., 2000] Chen, C. H., Lee, J. D., and Lee, M. (2000). Classification of underwater signals using neural networks. *Tamkang Journal of Science and Engineering*, 3 :pages 31–48.
- [Chenu et al., 1995] Chenu, C., Royer, D., and Fink, M. (1995). Defect detection by surface

- acoustic waves generated by a multiple beam laser. In *Ultrasonics Symposium, 1995. Proceedings., 1995 IEEE, Seattle, WA*, volume 1, pages 821–824.
- [Chin-Hsing et al., 1998] Chin-Hsing, C., Jiann-Der, L., and Ming-Chi, L. (1998). Classification of underwater signals using wavelet transforms and neural networks. *Mathematical and Computer Modelling*, 27(2) :47 – 60.
- [Cité et al., 2012] Cité, N., Chati, F., Décultot, D., Léon, F., and Maze, G. (2012). Acoustic scattering from a finite plate : Generation of guided lamb waves  $s_0$ ,  $a_0$  and  $a$ . *The Journal of the Acoustical Society of America*, 131(6) :pages 4233–4242.
- [De and Chatterjee, 2002] De, A. and Chatterjee, N. (2002). Recognition of impulse fault patterns in transformers using kohonen’s self-organizing feature map. *Power Delivery, IEEE Transactions on*, 17(2) :pages 489–494.
- [Deraemaeker and Preumont, 2006] Deraemaeker, A. and Preumont, A. (2006). Vibration based damage detection using large array sensors and spatial filters. *Mechanical Systems and Signal Processing*, 20(7) :1615 – 1630.
- [Décultot et al., 1993] Décultot, D., Lecroq, F., Maze, G., and Ripoche, J. (1993). Acoustic scattering from a cylindrical shell bounded by hemispherical endcaps. resonance interpretation with surface waves propagating in cylindrical and spherical shells. *The Journal of the Acoustical Society of America*, 94(5) :pages 2916–2923.
- [Engin et al., 2014] Engin, G., Aksoyer, B., Avdagic, M., Bozanlı, D., Hanay, U., Maden, D., and Ertek, G. (2014). Rule-based expert systems for supporting university students. *Procedia Computer Science*, 31(0) :22 – 31. 2nd International Conference on Information Technology and Quantitative Management, 2014.
- [Evans et al., 1969] Evans, F., Wilcox, J., of Aeronautics, A. I., and Astronautics (1969). *Experimental Strapdown Redundant Sensor Inertial Navigation System*. American Institute of Aeronautics and Astronautics.
- [Feldman, 2011] Feldman, M. (2011). Hilbert transform in vibration analysis. *Mechanical Systems and Signal Processing*, 25(3) :pages 735–802.

- [Fiorito et al., 1979] Fiorito, R., Madigosky, W., and Åœberall, H. (1979). Resonance theory of acoustic waves interacting with an elastic plate. *The Journal of the Acoustical Society of America*, 66(6) :pages 1857–1866.
- [Frank and Köppen-Seliger, 1997] Frank, P. M. and Köppen-Seliger, B. (1997). Fuzzy logic and neural network applications to fault diagnosis. *International Journal of Approximate Reasoning*, 16(1) :pages 67–88.
- [Harb and Yuan, 2015] Harb, M. and Yuan, F. (2015). A rapid, fully non-contact, hybrid system for generating lamb wave dispersion curves. *Ultrasonics*, 61(0) :62 – 70.
- [Harkat et al., 2006] Harkat, M., Gotz, M., and Ragot, J. (2006). An improved PCA scheme for sensor FDI : application to an air quality monitoring net work. *Journal of Process Control*, 16 :pages 625–634.
- [Hong-xu et al., 2010] Hong-xu, H., Yi-yu, Z., Wen-li, J., and Zhi-tao, H. (2010). A new time-delay echo jamming style to sar. In *Signal Processing Systems (ICSPS), 2nd International Conference on, Dalian China, 5-7 July 2010*, volume 3, pages 14–17.
- [Hu et al., 2013] Hu, J., Wen, C., and Li, P. (2013). Data-driven aided parity space-based approach to fast rate residual generation in non-uniformly sampled systems. In *Control and Automation (ICCA), 2013 10th IEEE International Conference on, Hangzhou China, 12-14 June 2013*, pages 57–62.
- [Isermann, 1993] Isermann, R. (1993). Fault diagnosis of machines via parameter estimation and knowledge processing—tutorial paper. *Automatica*, 29(4) :pages 815–835.
- [Isermann, 2005] Isermann, R. (2005). Model-based fault-detection and diagnosis – status and applications. *Annual Reviews in Control*, 29(1) :pages 71–85.
- [Izadi et al., 2008] Izadi, I., Shah, S., and Chen, T. (2008). Parity space fault detection based on irregularly sampled data. In *American Control Conference*, pages 2798–2803.
- [Kimmich et al., 2005] Kimmich, F., Schwarte, A., and Isermann, R. (2005). Fault detection for modern diesel engines using signal- and process model-based methods. *Control Engineering Practice*, 13(2) :pages 189–203.

- [Lamb, 1917] Lamb, H. (1917). On waves in an elastic plate. *Proceedings of the Royal Society of London. Series A*, 93(648) :pages 114–128.
- [Lee et al., 2012] Lee, B., Jeon, N., and Lee, H. (2012). Model-based fault detection and isolation algorithm of current sensor for ipmsm. In *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, Montreal, QC, 25-28 Oct. 2012*, pages 5376–5381.
- [Li et al., 2014] Li, F., Peng, H., and Meng, G. (2014). Quantitative damage image construction in plate structures using a circular {PZT} array and lamb waves. *Sensors and Actuators A : Physical*, 214(0) :66 – 73.
- [Li et al., 2009a] Li, L., Peng, Z., and Zhao, M. (2009a). In-situ monitoring of active crack in steel structure using acoustic emission technique. In *Measuring Technology and Mechatronics AUTOMATION, 2009. ICMTMA '09. International Conference on, Zhangjiajie China, 11-12 April 2009*, volume 1, pages 229–232.
- [Li et al., 2009b] Li, Y., Liang, G., Zha, G., and Fu, J. (2009b). The application of ldpc code in underwater acoustic wireless communications. In *Wireless Communications, Networking and Mobile Computing, 2009. WiCom '09. 5th International Conference on, Beijing China, 24-26 Sept. 2009*, pages 1–3.
- [Liu and Hong, 2015] Liu, W. and Hong, J.-W. (2015). Modeling of three-dimensional lamb wave propagation excited by laser pulses. *Ultrasonics*, 55(0) :113 – 122.
- [Lowe et al., 1998] Lowe, M., Alleyne, D., and Cawley, P. (1998). Defect detection in pipes using guided waves. *Ultrasonics*, 36(1 - 5) :pages 147–154.
- [Lowe et al., 2002] Lowe, M. J. S., Cawley, P., Kao, J.-Y., and Diligent, O. (2002). The low frequency reflection characteristics of the fundamental antisymmetric lamb wave a<sub>0</sub> from a rectangular notch in a plate. *The Journal of the Acoustical Society of America*, 112(6) :pages 2612–2622.
- [Luenberger, 1971] Luenberger, D. (1971). An introduction to observers. *Automatic Control, IEEE Transactions on*, 16(6) :pages 596–602.

- [Luppé et al., 1990] Luppé, F., Chatelets, B. G., and Maze, G. (1990). Diffraction of lamb waves at the end section of a plate. *The Journal of the Acoustical Society of America*, 87(4) :pages 1807–1809.
- [Léon et al., 1992] Léon, F., Lecroq, F., Décultot, D., and Maze, G. (1992). Scattering of an obliquely incident acoustic wave by an infinite hollow cylindrical shell. *The Journal of the Acoustical Society of America*, 91(3) :pages 1388–1397.
- [MacGregor and Kourti, 1995] MacGregor, J. and Kourti, T. (1995). Statistical process control of multivariate processes. *Control Engineering Practice*, 3(3) :pages 403 – 414.
- [Maki and Loparo, 1997] Maki, Y. and Loparo, K. (1997). A neural-network approach to fault detection and diagnosis in industrial processes. *Control Systems Technology, IEEE Transactions on*, 5(6) :pages 529–541.
- [Martin, 1999] Martin, J. (1999). Knowledge-based supervision and diagnosis of complex process. In *Intelligent Control/Intelligent Systems and Semiotics, 1999. Proceedings of the 1999 IEEE International Symposium on, Cambridge, MA, 15 Sep 1999-17 Sep 1999*, pages 225–230.
- [Massoumnia, 1986] Massoumnia, M. (1986). A geometric approach to the synthesis of failure detection filters. *Automatic Control, IEEE Transactions on*, 31(9) :pages 839–846.
- [Maze et al., 1985] Maze, G., Izbicki, J. L., and Ripoche, J. (1985). Resonances of plates and cylinders : Guided waves. *The Journal of the Acoustical Society of America*, 77(4) :pages 1352–1357.
- [Maze et al., 2014] Maze, G., Leon, F., Farid, C., Decultot, D., Sidibe, Y., Druaux, F., and Lefebvre, D. (2014). Detection of a straight groove in a metal plate by acoustic scattering in water with applications to marine current turbines. *NDTE International*, pages 47 – 53.
- [McCulloch and Pitts, 1943] McCulloch, W. S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, (5) :pages 115–133.
- [McFadden, 1986] McFadden, P. (1986). Journal of vibration, acoustics, stress and reliability in design. *Journal of Vibration, Acoustics, Stress and Reliability in Design*, 108 :pages 165–170.

- [Minsky and Papert, 1969] Minsky, M. and Papert, S. (1969). Review of 'perceptrons : An introduction to computational geometry'. *Information Theory, IEEE Transactions on*, 15(6) :pages 738–739.
- [Nagatsu and Katsura, 2013] Nagatsu, Y. and Katsura, S. (2013). Macro-micro bilateral control using kalman filter based state observer for noise reduction and decoupling of modal space. In *Industrial Electronics Society, IECON 2013 - 39th Annual Conference of the IEEE, Autriche, 10-13 Nov. 2013*, pages 4192–4197.
- [Nerrand et al., 1993] Nerrand, O., Roussel-Ragot, P., Personnaz, L., Dreyfus, G., and Marcos, S. (1993). Neural networks and nonlinear adaptive filtering : Unifying concepts and new algorithms. *Neural Computation*, 5(2) :pages 165–199.
- [Nerrand et al., 1994] Nerrand, O., Roussel-Ragot, P., Urbani, D., Personnaz, L., and Dreyfus, G. (1994). Training recurrent neural networks : why and how? an illustration in dynamical process modeling. *Neural Networks, IEEE Transactions on*, 5(2) :pages 178–184.
- [Newsam and Wegener, 1994] Newsam, G. and Wegener, M. (1994). Generating non-gaussian random fields for sea surface simulations. In *Acoustics, Speech, and Signal Processing, 1994. ICASSP-94., 1994 IEEE International Conference on*, volume 6, pages 195–198.
- [Nomikos and MacGregor, 1994] Nomikos, P. and MacGregor, J. F. (1994). Monitoring batch processes using multiway principal component analysis. *AIChE Journal*, 40(8) :pages 1361–1375.
- [Ochôa et al., 2015] Ochôa, P., Infante, V., Silva, J. M., and Groves, R. M. (2015). Detection of multiple low-energy impact damage in composite plates using lamb wave techniques. *Composites Part B : Engineering*.
- [Pai et al., 2015] Pai, P. F., Deng, H., and Sundaresan, M. J. (2015). Time-frequency characterization of lamb waves for material evaluation and damage inspection of plates. *Mechanical Systems and Signal Processing*, 62–63(0) :183 – 206.
- [Park et al., 2009] Park, H. W., Kim, S. B., and Sohn, H. (2009). Understanding a time reversal process in lamb wave propagation. *Wave Motion*, 46(7) :pages 451–467.

- [Pavlakovic et al., 1997] Pavlakovic, B., Lowe, M., Alleyne, D., and Cawley, P. (1997). Disperse : A general purpose program for creating dispersion curves. In Thompson, D. and Chimenti, D., editors, *Review of Progress in Quantitative Nondestructive Evaluation*, volume 16 of *Review of Progress in Quantitative Nondestructive Evaluation*, pages 185–192. Springer US.
- [Rizzo et al., 2006] Rizzo, P., Francesco-Lanza-di, S., and Ji, H. (2006). Feature extraction for defect detection in strands by guided ultrasonic waves. *Structural Health Monitoring*, 5 :pages 297–308.
- [Senyurek, 2015] Senyurek, V. (2015). Detection of cuts and impact damage at the aircraft wing slat by using lamb wave method. *Measurement*, 67(0) :10 – 23.
- [Shuyu, 2002] Shuyu, L. (2002). Study on the radiation acoustic field of rectangular radiation in flexural vibration. *Journal of Sound and Vibration*, 254(3) :pages 469–479.
- [Sidibe et al., 2013a] Sidibe, Y., Druaux, F., Lefbvre, D., Maze, G., and Leon, F. (2013a). Outils d’aide à la décision pour le diagnostic des structures immergées. *JESA*, 47(4-8) :pages 339–360.
- [Sidibe et al., 2013b] Sidibe, Y., Druaux, F., Lefebvre, D., Leon, F., and Maze, G. (2013b). Active fault diagnosis for immersed structure. In *Control, Decision and Information Technologies (CoDIT), 2013 International Conference on, Hammamet, Tunisia, 6-8 May 2013*, pages 71–75.
- [Sidibe et al., 2015] Sidibe, Y., Druaux, F., Lefebvre, D., Leon, F., and Maze, G. (2015). A non contact method for the detection and diagnosis of surface damage in immersed structures. *Advances in Acoustics and Vibration*, 2015.
- [Sidibe et al., 2013c] Sidibe, Y., Lefebvre, D., Druaux, F., Maze, G., and Leon, F. (2013c). Detection, diagnostic et localisation des défauts dans les structures immergees. In *Journées doctorales journée nationale Modélisation, Automatic, Control, 11-12 juillet 2013*, Strasbourg, France.



- [Sidibe et al., 2013d] Sidibe, Y., Lefebvre, D., Druaux, F., Maze, G., and Leon, F. (2013d). Localisation de défaut dans un signal ultrasonore. In *Qualita, 19-22 Mars 2013*, Compiègne, France.
- [Singh et al., 2003] Singh, S., Pruthi, H. S., and Agarwal, V. (2003). Efficient modal control strategies for active control of vibrations. *Journal of Sound and Vibration*, 262(3) :pages563 – 575.
- [Sodsri and Choomchuay, 2013] Sodsri, C. and Choomchuay, S. (2013). Hdi detection by using an ae technique. In *Communications and Information Technologies (ISCIT), 2013 13th International Symposium on, Surat Thani, 4-6 Sept. 2013*, pages 585–588.
- [Tellili et al., 2004] Tellili, A., Abdelkrim, M., and Benrejeb, M. (2004). Model-based fault diagnosis of two-time scales singularly perturbed systems. In *Control, Communications and Signal Processing, 2004. First International Symposium on, Hammamet, Tunisia, 21-24 March 2004*, pages 819–822.
- [Tharrault et al., 2008] Tharrault, Y., Mourot, G., and Ragot, J. (2008). Fault detection and isolation with robust principal component analysis. In *Control and Automation, 2008 16th Mediterranean Conference on, Ajaccio, 25-27 June 2008*, pages 59–64.
- [Torabi et al., 2012] Torabi, A., Joo, E. M., Xiang, L., Siong, L. B., Lianyin, Z., Linn, S., Peen, G. O., and Teck, C. C. (2012). Application of classical clustering methods for online tool condition monitoring in high speed milling processes. In *Industrial Electronics and Applications (ICIEA), 2012 7th IEEE Conference on, Singapore, 18-20 July 2012*, pages 1249–1254.
- [Trendafilova and Manoach, 2008] Trendafilova, I. and Manoach, E. (2008). Vibration-based damage detection in plates by using time series analysis. *Mechanical Systems and Signal Processing*, 22(5) :pages 1092 – 1106.
- [Willsky and Jones, 1976] Willsky, A. and Jones, H. (1976). A generalized likelihood ratio approach to the detection and estimation of jumps in linear systems. *Automatic Control, IEEE Transactions on*, 21(1) :pages 108–112.

- [Xiaoyan et al., 2011] Xiaoyan, X., Junyi, L., Feng, W., and Tailong, Q. (2011). Damage diagnosis of structures based on vibration mode. In *Intelligent Systems and Applications (ISA), 2011 3rd International Workshop on, Wuhan China, 28-29 May 2011*, pages 1–4.
- [Xingeng and Cunfu, 1997] Xingeng, Z. and Cunfu, H. (1997). Experimental set-up of laser ultrasonic techniques and applications. *Tsinghua Science and Technology*, 2(2) :pages 578–582.
- [Xu and Chen, 2007] Xu, X. and Chen, R. (2007). Recurrent neural network based on-line fault diagnosis approach for power electronic devices. In *Natural Computation, 2007. ICNC 2007. Third International Conference on*, volume 2, pages 700–704.
- [Xun and Yan, 2008] Xun, J. and Yan, S. (2008). A revised hilbert–huang transformation based on the neural networks and its application in vibration signal analysis of a deployable structure. *Mechanical Systems and Signal Processing*, 22(7) :pages 1705–1723.
- [Ye et al., 2004] Ye, H., Wang, G., and Ding, S. (2004). A new parity space approach for fault detection based on stationary wavelet transform. *Automatic Control, IEEE Transactions on*, 49(2) :pages 281–287.
- [Yibo and Xiaopeng, 2006] Yibo, C. and Xiaopeng, X. (2006). Wear particles classification based on wavelet transform and back-propagation neural network. In *Computational Engineering in Systems Applications, IMACS Multiconference on, Beijing, 4-6 Oct. 2006*, volume 2, pages 2010–2014.
- [Yu et al., 2007] Yu, D., Yang, Y., and Cheng, J. (2007). Application of time–frequency entropy method based on hilbert–huang transform to gear fault diagnosis. *Measurement*, 40(9–10) :pages 823–830.





## **Aide à la décision pour la détection et l'analyse des défauts de surface dans les structures immergées**

Résumé : Cette thèse concerne le développement de méthodes de détection et de diagnostic des défauts de surface dans les structures immergées. Les structures étudiées sont formées de plaques métalliques. Les méthodes proposées sont basées sur une analyse de mesures acoustiques ultrasonores issues d'échographie sous-marine. Cette analyse combine des outils usuels du traitement du signal et des méthodes de classification à base de réseaux de neurones gaussiens. Des variantes avec et sans modèle de référence sont proposées. Les techniques usuelles d'évaluation par contact montrent leurs limites pour le diagnostic des structures telles que les hydroliennes. Le présent travail de recherche consiste à utiliser un seul et unique transducteur sans contact sous différents angles contrairement à d'autres techniques qui nécessitent un grand nombre de capteurs et une connaissance précise de leur positionnement. Notre étude utilise les ondes de Lamb car elles sont très sensibles aux anomalies structurelles. Les principales étapes et outils utilisés sont les suivants :

- Utilisation d'un dispositif de génération et d'acquisition d'ondes de Lamb.
- Étude de la propagation d'ondes de Lamb dans les structures en immersion, en particulier dans les plaques métalliques immergées dans l'eau.
- Caractérisation des signaux pour différents types de défauts.
- Estimation de l'angle d'acquisition et de la distance du transducteur par rapport au centre de la plaque.

## **Decision support tools for the detection and analysis of surface defects in submerged structures**

Abstract : This study concerns the damages detection and diagnosis for immersed structure. The structures are metallic plates. The proposed method focuses on the analysis of ultrasonic acoustic measurements obtained by submarine echography. It combines signal processing tools and Gaussian neural networks for classification purpose. Methods with and without reference models are proposed. The usual detection technics with contact are not applicable for the considered systems like stream turbines. This research consist to use a single and a single transducer under different incidence angles opposed to others technics using numerous sensors and their accurate location. The present research use Lamb wave according to their sensibility to the structural damages. The different stages are the following :

- Experimental setup for Lamb wave generation and acquisition.
- Study of the Lamb wave processing on immersed structures, in particular in metallic plate immersed in water.
- Signal characterization for different types of damages.
- Estimation of the angle and lift-off distance.