

Université Saâd DAHLAB. Blida1

Faculté de Technologie

THESE DE DOCTORAT

en Electronique

METHODES DE TRAITEMENT ET D'ANALYSE DE TEXTURE DES
IMAGES ULTRASONORES B-SCAN DU TYPE TOFD DANS LA
DETECTION ET L'IDENTIFICATION DES DEFAUTS

par

Ahmed KECHIDA

Devant le jury composé de :

Mr. A. AISSAT	Professeur, U. de Blida	Président
M ^{elle} N. BENBLIDIA	Professeur, U. de Blida	Examinatrice
M ^{me} L. HAMAMI	Professeur, ENP. d'Alger	Examinatrice
Mr. M. ZERGOUG	Directeur de recherche, C.RT.I Alger	Examineur
Mr. R. DRAI	Directeur de recherche, C.RT.I Alger	Directeur de thèse
Mr. A. GUESSOUM	Professeur, U. de Blida.	Co-Directeur de thèse

Blida, Février 2016

خلاصة :

تناقش هذه الأطروحة دراسة وتنفيذ طرق معالجة و تجزئة صور الموجات فوق الصوتية اعتمادا على تقنية زمن الطيران البلوري (TOFD) للكشف عن العيوب. هذه التقنية لها ميزة كبيرة في تحديد موقع وتحجيم العيوب، وخاصة الشقوق. المشكلة الرئيسية لهذه الأخيرة هي تفسير هذه الصور من قبل الخبراء المقتشين. في هذه الأطروحة المناهج المدروسة تستند على بنية معلومات العيوب واضحة جزئيا من قبل الخبير. يتم استخراج بارامترات البنية و كتابتها بطريقتين، وهما التحليل المتعدد الأزمنة مبني على أساس تحويل الموجات و ربطها مع التحليل الإحصائي للبنية وبنوك مرشحات غابور. مجموعة خاصة المتجاهات تحسن من خلال استعمال تحليل المكون الرئيسي (PCA). تصنيف كل بكسل بعيب أو لا يعطى عن طريق خوارزمية تجميع ضبابي متوسط (FCMI). ثم، لتحسين حساب الوقت نفذنا نهج التعلم باستعمال دعم متجهات الآلات (SVM). النتائج التي تم الحصول عليها على الصور من نوع TOFD الصناعية تشهد على متانة وأداء هذه الأساليب

Résumé :

Ce travail de thèse concerne l'étude et l'implémentation des méthodes de segmentation pour la détection des défauts dans des images ultrasonores de type Time of Flight Diffraction (TOFD). Cette technique présente un grand avantage sur la localisation et le dimensionnement des défauts et particulièrement les fissures. Le problème majeur de cette dernière est l'interprétation de ces images par les inspecteurs experts. Dans cette thèse, les approches étudiées sont basées sur les informations de la texture des défauts partiellement visibles par l'opérateur. Les paramètres de textures sont extraits par deux méthodes, à savoir l'analyse de multirésolution basée sur la transformée en ondelettes associée à l'analyse statistique de la texture et les banques de filtres de Gabor. L'ensemble des vecteurs d'attributs sont optimisés par l'analyse en composantes principales (ACP). La classification de chaque pixel comme défaut ou non défaut est donnée par l'algorithme de 'Fuzzy C-Mean Itirative' FCMI. Ensuite, pour l'optimisation de temps de calcul nous avons implémenté une approche d'apprentissage supervisé avec les « Séparateur à Vaste Marge » (SVM). Les résultats obtenus sur des images TOFD industrielles attestent de la robustesse et la performance de ces méthodes.

Abstract :

This thesis work deals with the study and the implementation of segmentation methods for flaws detection in ultrasound image type Time of Flight Diffraction (TOFD). This technique allows the location and sizing of flaws, especially cracks. The main problem of this latter is the inspectors' visual interpretation. In this thesis, the considered approaches are based on the texture information of flaws which are partially visible by an operator. Texture features are extracted by two methods, namely the multiresolution analysis such as wavelet transform associated with statistical texture analysis and Gabor filter banks. The most relevant features are optimized by Principal Components Analysis (PCA) and used as input data on a Fuzzy C-Mean Iterative classifier. We use two classes: 'defects' or 'no defects'. Then, to optimize the computation time we have to implement a supervised learning approach with Support Vector Machines (SVM). Finally, the results obtained in industrial TOFD images attest to the robustness and performance of this work.

REMERCIEMENTS

Je profite de cette opportunité pour remercier en premier lieu Dieu, le tout puissant, de m'avoir donné autant de courage, de patience et de volonté pour atteindre ce but.

La direction de cette thèse a été assurée par Monsieur R. DRAI, Directeur de recherche et chef de Division de Traitement du Signal et de l'Imagerie du Centre de Recherche en Technologies Industrielles CRTI, ex-CSC (Chéraga). Je ne saurais trop lui témoigner toute ma reconnaissance pour la confiance et l'extrême disponibilité qu'il m'a accordées et lui adresser mes plus vifs remerciements pour son soutien sans faille. Qu'il soit assuré de ma profonde gratitude.

Je tiens à remercier Monsieur A. GUESSOUM, Professeur à Université Saâd DAHLAB de Blida, pour l'intérêt qu'il a porté à ce travail et lui exprime ma reconnaissance pour avoir bien voulu être le co-directeur de cette thèse.

Je remercie vivement Monsieur A. AISSAT, Professeur à l'Université Saâd DAHLAB de Blida, pour l'honneur qu'il a bien voulu me faire en acceptant de présider le jury de cette thèse.

Qu'il me soit permis de remercier :

Mademoiselle N. BENBLIDIA, Professeur à l'Université Saâd DAHLAB de Blida, Madame L. HAMAMI, Professeur à l'ENP et Monsieur M. ZERGOUG, Directeur de recherche au CRTI qui m'honorent de leur présence dans ce jury.

Ma gratitude à Monsieur A. BADIDI BOUDA, Directeur de recherche au CRTI, pour ses encouragements, son aide et ses conseils précieux et désintéressés.

Mes remerciements vont aussi à tous mes collègues de la Division de Traitement du Signal et de l'Imagerie «DTSI» pour leur aide et leur soutien constant. Je suis particulièrement reconnaissant envers M. KHELIL, A. BENAMMAR et F. CHIBANE pour leur loyauté, leur aide efficace et surtout pour m'avoir supporté tout au long de la rédaction de cette thèse.

Je n'oublierais pas de remercier particulièrement mon épouse pour sa présence, son soutien, ses encouragements permanents et pour ses conseils dans la rédaction des différentes publications et communications.

Enfin, mes remerciements s'adressent à mes proches, mes amis, et tous ceux qui m'ont soutenu et aidé pour mener à terme ce travail.

TABLE DES MATIERES

RESUME.....	01
REMERCIEMENTS.....	03
TABLE DES MATIERES.....	04
Liste des illustrations, graphiques et tableaux.....	06
Liste des symboles et des abréviations.....	08
INTRODUCTION	09

CHAPITRE 1 : CONTROLE ET IMAGERIE PAR LA TECHNIQUE TIME OF FLIGHT DIFFRACTION(TOFD)

1.1. Introduction.....	12
1.2. Description de la technique TOFD.....	12
1.3. Evolutions de la technique TOFD.....	18
1.4. Développement des techniques expérimentales de la TOFD.....	20
1.5. Bases théoriques de la technique TOFD.....	21
1.6. Expérimentations et acquisitions des images TOFD	25
1.7. Problématique étudiée et état de l'art.....	30
1.8. Conclusion.....	33

CHAPITRE 2 : TEXTURE ET ANALYSE D'IMAGES

2.1. Introduction.....	34
2.2. Notion de texture.....	35
2.2.1. Attributs visuels de la texture.....	35
2.2.2. Texture et niveaux de gris.....	36
2.2.3. Invariance par translation.....	37
2.3. Classification des textures.....	38
2.3.1. Textures structurelles.....	38
2.3.2. Textures aléatoires.....	38
2.4. Analyse texturale.....	39
2.4.1. Méthodes statistiques.....	40
2.4.1.1. Méthodes d'ordre 1.....	40
2.4.1.2. Matrice de cooccurrences.....	41
2.4.1.3 Matrice de longueurs de plage.....	48
2.4.2. Méthodes fondées sur un modèle.....	51
2.4.3. Autres méthodes	52
2.4.3.1. Méthodes structurelles.....	52
2.4.3.2. Modèles fractals.....	52
2.4.3.3. Méthodes basées sur les décompositions atomiques.....	52
2.5. Conclusion	53

CHAPITRE 3 : ANALYSE ET SEGMENTATION DES IMAGES TOFD

3.1. Introduction.....	54
3.2. Analyse en multirésolution basée sur la transformée en ondelettes.....	55
3.2.1. La transformée en ondelettes.....	55
3.2.2. Analyse multirésolution pour la décomposition des images..	59
3.3. Procédure de segmentation.....	63
3.4. Résultats et discussions.....	72
3.5. Conclusion.....	79

CHAPITRE 4 : SEGMENTATION SUPERVISEE DE TEXTURE BASEE SUR LES BANQUES DE FILTRES DE GABOR

4.1. Introduction	80
4.2. Méthode SVM	81
4.2.1. Linéarité et non linéarité.....	81
4.2.2. Principe des SVMs.....	82
4.2.2.1. Principe des données linéairement séparables.....	84
4.2.2.2. Principe des données non linéairement séparables....	88
4.3. Extraction des paramètres de Gabor.....	94
4.4. Résultats et discussions	97
4.5. Conclusion.....	104
CONCLUSION	105
REFERENCES	107

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure 1.1	Mise en œuvre de la technique TOFD	16
Figure 1.2	Représentation du signal A-scan de la technique	17
Figure 1.3	Exemple d'image B-SCAN ultrasonore de type TOFD	18
Figure 1.4	Mode de propagation des ondes ultrasonores	21
Figure 1.5	La base de la technique TOFD avec deux sondes	24
Figure 1.6	Chaîne d'acquisition ultrasonore	25
Figure 1.7	Mise en œuvre de la technique TOFD en immersion	26
Figure 1.8	Image TOFD par immersion	26
Figure 1.9	Chaîne d'acquisition d'image TOFD par contact	27
Figure 1.10	Image TOFD correspond au 1 ^{er} joint d'épaisseur 10mm	27
Figure 1.11	Image TOFD correspond au 2 ^{ème} joint d'épaisseur 25mm	28
Figure 1.12	Images TOFD issues de contrôle réel à l'échelle industriel	29
Figure 1.13	Zoom sur un défaut dans une image B-SCAN ultrasonore de type TOFD	30
Figure 2.1	L'œil ne distingue qu'une texture	35
Figure 2.2	Les niveaux de gris discriminent les régions	36
Figure 2.3	La texture discrimine les régions	36
Figure 2.4	La fenêtre de visualisation est satisfaisante	37
Figure 2.5	La fenêtre de visualisation n'est pas satisfaisante	37
Figure 2.6	Deux textures structurelles	38
Figure 2.7	Texture aléatoire	39
Figure 2.8	Recensement des transitions	42
Figure 2.9	Matrice de cooccurrence	42
Figure 2.10	Recensement des segments	49
Figure 2.11	Matrice des longueurs de plage	50
Figure 3.1	Fonction d'échelle et l'ondelette de Haar	57
Figure 3.2	Fonction d'échelle et l'ondelette de Daubechies 2	57
Figure 3.3	Fonction d'échelle et l'ondelette de Daubechies 20	57
Figure 3.4	Algorithme de décomposition d'un signal unidimensionnel en paquets d'ondelettes	58
Figure 3.5	Processus de reconstruction du signal	59
Figure 3.6	Décomposition en ondelettes d'une image par produit de convolution 1-D le long des lignes et des colonnes	61
Figure 3.7	Décomposition multirésolution par paquet d'ondelettes	62
Figure 3.8	Décomposition multirésolution adaptée d'une image	62
Figure 3.9	Exemple de décomposition d'une image TOFD par ondelettes	63
Figure 3.10	Segmentation idéale d'une image composée de 4 textures	64
Figure 3.11	Paramètres d'ondelettes pour chaque pixel dans l'image à segmenter (première approche)	66
Figure 3.12	Reconstruction d'une image à partir des ondelettes	68
Figure 3.13	Vecteur d'attributs de chaque pixel	68
Figure 3.14	Résultats de segmentation de la première image TOFD réalisée au niveau du laboratoire	73

Figure 3.15	Résultats de segmentation de la deuxième image TOFD réalisée au niveau du laboratoire	74
Figure 3.16	Résultats de segmentation de la deuxième approche sur des images composées de deux textures de la base Brodatz	76
Figure 3.17	(a) Image TOFD industrielle, (b) Image segmentée par la 1 ^{ère} approche, (c) Image segmentée par la 2 ^{ème} approche	77
Figure 3.18	(a) Image TOFD industrielle, (b) Image segmentée par la 1 ^{ère} approche, (c) Image segmentée par la 2 ^{ème} approche	78
Figure 4.1	Exemple de données linéairement séparables	82
Figure 4.2	Exemple de données non linéairement séparables	82
Figure 4.3	Exemple de redescription de l'espace	82
Figure 4.4	Illustration des notions de base des SVMs	83
Figure 4.5	Les hyperplans	85
Figure 4.6	Une transformation rend les données linéairement séparables	89
Figure 4.7	Cas de données non séparables	91
Figure 4.8	Compromis entre marge maximale et bruit	91
Figure 4.9	Vecteur d'attributs pour chaque pixel de l'image	96
Figure 4.10	Exemple de la banque de filtres de Gabor utilisée	97
Figure 4.11	(a) Image TOFD industrielle, (b) Image segmentée avec les paramètres de Gabor, (c) Image segmentée avec les paramètres d'ondelettes	98
Figure 4.12	(a) Image TOFD industrielle, (b) Image segmentée avec les paramètres de Gabor, (c) Image segmentée avec les paramètres d'ondelettes	99
Figure 4.13	Organigramme de la phase d'apprentissage	101
Figure 4.14	Organigramme de la phase test	102
Figure 4.15	(a) Image TOFD industrielle, (b) Image segmentée avec 40 points d'apprentissage, (c) Image segmentée avec 100 points d'apprentissage	103

LISTE DES SYMBOLES ET DES ABREVIATIONS

ACP	: Analyse en composantes principales
AR	: Autorégressif
ARMA	: Autorégressive moving average
CND	: Contrôle non destructif
CWT	: Continuous wavelet transform
DT-CWT	: Discrete time continuous wavelet transform
DWT	: Discrete wavelet transform
FCMI	: Fuzzy C-Means Iterative
FMQ	: Filtres miroirs en quadrature
KKT	: Les conditions de Karush-Kuhn-Tucker
LDP	: Matrice des longueurs des plages
MA	: Moving average
NDG	: Niveau de gris
PA	: Phased array
PISC	: Program of inspection of steel components
P-Wave	: Onde longitudinale
PWR	: Pressurised water reactor
RBF	: Radial basis function
SAFT	: Synthetic aperture focusing technique
SAR	: Simultaneous autoregressive
SFFT	: Short fast Fourier transform
SH-Wave	: Onde transversale
SNR	: Rapport signal sur bruit
SVM	: Séparateur à vaste marge
TF	: Temps fréquence
TOFD	: Time of flight diffraction
D	: Défaut
T_x	: Emetteur
R_x	: Récepteur
2S	: La distance qui sépare les deux sondes
H	: Epaisseur de la plaque
$\ \quad \ $: Symbole représentant la norme
*	: Opérateur de convolution temporelle
\otimes	: Opération de convolution à deux dimensions
$\langle \quad , \quad \rangle$: Produit scalaire

INTRODUCTION

L'avancée sans cesse croissante de l'utilisation des ultrasons dans le domaine du contrôle non destructif des matériaux ouvre la voie régulièrement à des applications qui étaient inaccessibles auparavant. Lors d'un contrôle non destructif par n'importe quelle technique, les industriels attendent de l'inspecteur CND une réponse claire aux deux questions : La pièce, l'assemblage ou l'installation peut-elle encore fonctionner sans risque et pour combien de temps ?

La réponse à ce genre de question est en soit une science qui traite de la durée de vie estimée d'une installation. Elle fait appel à la synergie de plusieurs spécialités telles que la métallurgie, la mécanique et même l'électronique. Un des soucis auxquels doit répondre l'inspecteur expert est d'abord la détection des défauts et particulièrement les plus nocifs. Ensuite, l'inspecteur doit caractériser ces derniers, d'un point de vue position, orientation, dimension et type des défauts détectés.

Actuellement, plusieurs travaux de recherche sont menés dans le but d'améliorer la probabilité de détection des défauts qu'ils soient nocifs ou pas. En effet, les ondes ultrasonores à des fréquences adaptées aux dimensions des défauts recherchés sont employées pour distinguer les zones saines des zones douteuses [1].

L'analyse ultrasonore des matériaux est basée sur un principe simple de la physique : le mouvement de n'importe quelle onde sera affecté par le milieu dans lequel elle se propage. Ainsi, le changement d'un ou de plusieurs des quatre paramètres (facilement mesurables) : temps de transit, atténuation, diffusion et diffraction, associés au passage d'une onde à travers le matériau peut souvent être corrélé avec le changement des propriétés physiques tel que la présence de défauts [2].

Avec le développement fulgurant de l'électronique durant ces deux dernières décades, le contrôle non destructif des matériaux par ultrasons a fait une avancée remarquable en fiabilité, à tel point que, les acquisitions de données ultrasonores sont réalisées de manière automatique. Les analyses et

interprétations sont effectuées, d'abord en temps réel puis a posteriori, sur des cartographies appelées images ultrasonores. La constitution des images TOFD (Time of Flight Diffraction), sont ainsi réalisées, et les inspecteurs sont appelés à les interpréter. Cette tâche consiste d'abord à détecter les défauts et ensuite les évaluer en dimensions et orientations. Néanmoins, elle reste dépendante de la compétence et de l'expérience des inspecteurs experts.

Dans cette thèse, nous proposons une aide basée sur le traitement automatique des données, permettant de détecter aisément les défauts présents dans les images TOFD. Les approches proposées reposent sur la segmentation de ce type d'images à partir d'une analyse texturale. En effet, nous considérons que la texture des zones de défauts est différente de celle du fond de l'image.

Dans le premier chapitre, nous présentons la technique d'imagerie B-Scan, relativement récente (TOFD). Nous commencerons par la description de l'évolution de cette technique dans le temps, suivie par la mise en œuvre de cette technique, sans oublier les bases théoriques et l'étude bibliographique des travaux récents portant sur cette technique.

Le deuxième chapitre est consacré à la base théorique et l'importance de la notion de texture ainsi que les paramètres pertinents qui la caractérisent. Nous présenterons les méthodes d'analyses des textures les plus courantes. Nous verrons que parmi ces méthodes: les quatorze paramètres d'Haralick issues des matrices de cooccurrence ou bien cinq paramètres des longueurs de plage peuvent donner une bonne description de la texture. Nous discuterons leurs avantages et leurs inconvénients.

Dans le troisième chapitre, nous discuterons l'analyse et la segmentation des images TOFD. Nous présentons une approche de segmentation d'images TOFD basées sur la caractérisation texturale d'un défaut ainsi que les paramètres de texture en utilisant la transformée en ondelettes. La décomposition en ondelettes est une représentation spatio-fréquentielle d'une image. Elle représente les composantes de fréquences d'une image à l'endroit où elles se trouvent. Pour le choix du canal de décomposition, nous utiliserons un critère de sélection basé sur l'analyse statistique des textures des sous images. Les paramètres d'ondelettes seront optimisés par l'Analyse en Composantes Principales (ACP) et

utilisés comme vecteur d'attributs pour chaque pixel de l'image TOFD. Finalement, la segmentation de l'image est donnée par la classification de chaque pixel de l'image par l'algorithme FCMI (Fuzzy C-Means Itirative) comme « défaut » ou « non-défaut ». L'approche proposée sera testée sur des images réalisées au niveau du laboratoire et à l'échelle industrielle.

Le quatrième chapitre est consacré à l'aspect expérimental de nos travaux et principalement à la segmentation supervisée de texture basée sur les banques de filtres de Gabor. Des méthodes générales sont développées en reconnaissance de formes pour extraire automatiquement des informations des données sensibles afin de caractériser les classes de formes (apprentissage) et d'assigner automatiquement ces données à ces classes (reconnaissance). L'apprentissage ou modélisation est une étape clé dans la chaîne de reconnaissance de formes, elle consiste à acquérir la connaissance et de l'organiser en classes ou en modèles de références. Cette étape nous conduit à la reconnaissance proprement dite des défauts. L'intérêt de ce chapitre, est d'implémenter une méthode de segmentation de l'image TOFD par classification de chaque pixel avec un apprentissage supervisé tel que les SVMs (Séparateur à Vaste Marge). Notre objectif est cette fois ci une méthode de segmentation rapide et efficace.

Les paramètres de Gabor seront tout aussi optimisés comme pour les paramètres d'ondelettes par l'Analyse en Composantes Principales (ACP). Ces paramètres seront utilisés comme vecteur d'attributs pour chaque pixel de l'image TOFD. L'approche proposée sera testée sur des images réalisées au niveau du laboratoire et à l'échelle industrielle. Les résultats de cette approche sont comparés à ceux de l'approche du troisième chapitre afin de montrer l'efficacité et la rapidité de cette dernière.

Nos résultats expérimentaux seront analysés et discutés dans la conclusion générale. Nous terminons cette thèse par l'énoncé de quelques perspectives.

CHAPITRE 1

CONTROLE ET IMAGERIE PAR LA TECHNIQUE TIME OF FLIGHT DIFFRACTION (TOFD)

1.1. Introduction

Le contrôle non destructif par ultrasons se développe graduellement et régulièrement dans la maintenance industrielle à tel point qu'il est devenu incontournable. Actuellement, les acquisitions de données ultrasonores sont réalisées de manière automatique. Les analyses et interprétations sont effectuées, a posteriori, sur des cartographies appelées images ultrasonores. Le but de ce chapitre est de présenter une technique d'imagerie B-Scan relativement récente qui est Time of Flight Diffraction (TOFD). Nous commencerons par l'évolution de cette technique dans le temps suivie par la mise en œuvre et de quelques bases théoriques de cette dernière. Avant de présenter les expérimentations réalisées et la problématique du sujet, nous exposons une étude bibliographique des travaux récents portant sur la technique TOFD.

1.2. Description de la technique TOFD

Apparue dans les années quarante avec l'invention des sonars sous-marins, les ultrasons se sont imposés dans le diagnostic dans le domaine médical. L'évolution substantielle dans le domaine de l'électronique et de l'informatique a permis aux ultrasons d'être très fiables dans l'analyse des signaux et surtout des images 2D et 3D. Les applications sont multiples et variées aussi bien militaires (détection et identification d'engins sous-marins ou volants par leurs signatures acoustiques) et civiles (détection de défauts).

Néanmoins, le problème majeur en contrôle non destructif est le pouvoir de détection des défauts. En effet, certains défauts plans et particulièrement les fissures sous toutes leurs formes [1] ont la particularité de se propager et s'agrandir sous l'effet de contraintes mécaniques et/ou thermiques. Ceci est le cas, dans la quasi-totalité des installations industrielles. Ce problème est crucial dans le transport des hydrocarbures (gazoducs et pipelines).

En contrôle non destructif par ultrasons la sensibilité de détection des défauts plans est élevée comparativement aux autres techniques de CND particulièrement pour les fissures.

L'autre avantage des ultrasons est que c'est la seule technique de CND qui peut investiguer à des profondeurs pouvant aller jusqu'à quelques mètres [1]. A titre d'exemple la radiographie est limitée à 100 mm d'acier, la magnétoscopie à quelques mm et les courants de Foucault à moins d'un millimètre.

Lors d'un contrôle non destructif, l'inspecteur doit faire des investigations afin de répondre à 04 questions :

1. Y a-t-il des défauts ? : Sensibilité de détection
2. Où ? : Localisation
3. De quelle taille ? : Dimensionnement
4. Quoi ? : Identification

Sur la base de ces informations, l'inspecteur en CND prend une décision d'acceptation, de réparation ou de rejet en conformité avec les normes en vigueur pour le type d'installation inspectée [2].

Il est important de rappeler que la réponse à la question une est de loin l'information la plus pertinente. Les accidents industriels surviennent quasiment toujours à une mauvaise détection.

Il existe plusieurs techniques de CND par ultrasons dans l'industrie.

- Le contrôle par contact avec une sonde en émission réception ou mode écho. Cette technique d'inspection se base sur l'amplitude et la forme d'un signal renvoyé par un défaut situé dans une installation ou une pièce vers la sonde qui transforme l'onde acoustique en signal et qui est visualisé sur un écran d'oscilloscope. Cette technique est très utilisée dans l'inspection des soudures. L'analyse du signal ou écho (temps de vol, amplitude et autres paramètres) permet de donner des informations sur le défaut. Cette technique, bien que fiable, nécessite un balayage ou sondage du palpeur sur la totalité de la surface de la pièce à examiner. Le développement de l'électronique a permis l'utilisation d'une autre génération d'appareils PA (Phased array) qui assure lui-même un balayage

électronique du faisceau acoustique dans la pièce [3]. Ceci permet un rendement élevé et un gain de temps dans le dimensionnement et même l'identification des défauts.

- Le contrôle par ondes guidées pour contrôle des parois des tubes sur des distances pouvant aller jusqu'à 100 mètres [4]. Cette technique offre l'énorme avantage de procéder au contrôle des tubes enterrés ou aériens sans enlever leur enrobage, qui leur est nécessaire pour se protéger de la corrosion, ainsi que du rendement élevé.

Bien que l'introduction de cette technique soit établie dans le contrôle des pipelines, elle a l'inconvénient d'un manque de fiabilité dans la détection de certaines fissures de petites tailles. Or, les fissures sont des défauts nocifs quelque soient leurs orientations ou leurs dimensions.

Une fois détecté, tout défaut doit être localisé et dimensionné afin de prendre une décision quant à son acceptation, sa réparation ou son rejet. Si sa localisation est exigée pour un suivi ultérieur et périodique à titre préventif, son dimensionnement à lui seul peut décider de son rejet ou pas.

Il est donc primordial de dimensionner un défaut immédiatement après sa détection. Un défaut peut atteindre sa taille critique et il devient urgent de parer à ces situations fréquentes qui précèdent les accidents.

Par conséquent, en contrôle non destructif deux paramètres sont primordiaux : le pouvoir ou la sensibilité de détection des défauts et l'estimation de leurs dimensions.

Dans le cas des fissures, l'évaluation de leurs tailles est nécessaire afin de prévenir les ruptures de matériaux qui surviennent après la taille critique d'une fissure. Rappelons que ce type de défauts est dynamique et sa longueur croît sous l'effet d'une contrainte mécanique ou d'une contrainte thermique.

La contrainte maximale théorique que peut supporter un solide dépend de la force de liaison des électrons d'un atome. Dans la pratique, la résistance à la rupture est déterminée par ces forces de liaison ainsi que par la taille des fissures, soit en surface ou en interne.

Quand un matériau est sous contrainte, l'énergie est stockée dans la matière de manière élastique. Si le matériau contient une fissure, elle s'agrandit sous l'effet de la charge appliquée donnée. Alors la fissure s'ouvrira légèrement et les deux faces s'écarteront. Le matériau derrière les faces de la fissure est donc détendu et l'énergie de déformation stockée est libérée. Cependant, ce processus crée une nouvelle surface de fissure – un processus qui nécessite une certaine quantité d'énergie. En équilibrant ces deux énergies, une relation peut être formulée pour évaluer la taille critique théorique de la fissure [5] :

$$a_c = \frac{2WE}{\pi\sigma^2} \quad (1.1)$$

Où a_c est la taille critique en mètres, W est le travail d'une fracture du solide en J/m^2 , E est un module d'élasticité dépendant du mode de contrainte, et σ est la contrainte appliquée (en N/m^2).

Une valeur typique de W serait de $6 J/m^2$ pour le verre, un matériau cassant avec une très petite fissure, et une valeur de W pour un matériau ductile tel que l'acier ou l'aluminium peuvent se situer entre 10^4 et $10^6 J/m^2$. Les dimensions critiques de la fissure correspondant à des charges de 100 MPa, pour les plaques infiniment larges et épaisses, seraient d'environ $27\mu m$ pour le verre et $1,3mm$ pour l'acier. Pour les structures de tailles réalistes, ces tailles critiques sont encore réduites. Le défaut critique est une fissure orientée perpendiculairement aux principales contraintes appliquées.

La mesure précise de ce paramètre de défauts est donc d'une grande importance pour assurer l'intégrité d'une structure.

La technique classique par contact qui utilise le mode écho assure de manière fiable la détection et la localisation des défauts, mais manque de précision dans le dimensionnement des défauts. Pour contourner cette difficulté toutes les normes et standards de CND ont convenu de critères d'acceptation de défauts dont la longueur estimée est comparée à des multiples ou des fractions de l'épaisseur des échantillons ou soit de l'épaisseur du cordon de soudure ou de sa longueur pour les assemblages soudés [1].

Ceci ne résout pas le problème des coûts d'inspection CND mais permet par excès de prudence d'éviter les ruptures et donc les accidents.

Une des techniques qui a fait ses preuves et répond à ces deux critères (détection et dimensionnement) est la technique TOFD.

Cette technique a une grande précision pour mesurer la taille critique des fissures dans la paroi. Dans plusieurs cas, cette précision est bien meilleure que ± 1 mm, et peut être obtenue dans une grande variété d'épaisseurs du matériau à partir de laquelle sont réalisés les composants sous pression. Elle est de plus en plus utilisée dans différents secteurs de l'industrie, comme l'aérospatiale et l'industrie nucléaire en particulier.

Son principe physique est simple. Une sonde émettrice irradie un défaut ou une discontinuité dans un matériau. L'énergie acoustique après propagation dans le matériau arrive à la discontinuité. Une partie de cette énergie est réfléchiée par la surface du défaut en obéissant à la loi de Snell Descartes [2]. Une autre partie est transmise dans le matériau. Durant cette interaction entre les ondes acoustiques et la matière, les extrémités du défaut diffractent ces ondes et les réfléchissent dans toutes les directions sur 360° .

Ces extrémités se comportent à leur tour comme des sources ponctuelles d'ondes acoustiques. C'est la réflexion spéculaire.

Un palpeur récepteur est positionné de manière adéquate afin de recevoir ces réflexions spéculaires ainsi que les ondes émises directement par le palpeur émetteur. L'analyse de tous les signaux reçus permet de détecter, dimensionner et positionner le défaut (figure 1.1).

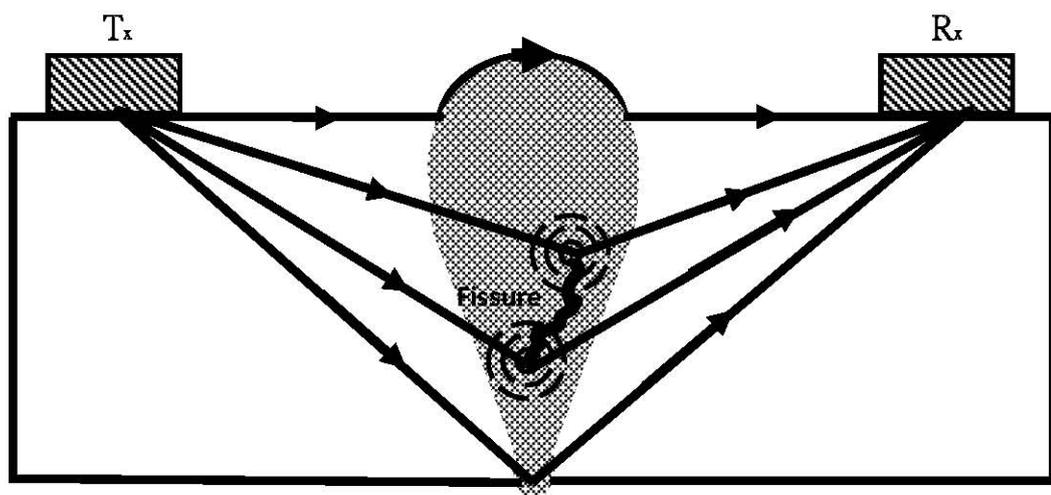


Figure 1.1: Mise en œuvre de la technique TOFD

On voit à travers cette figure que nous avons 04 trajets importants :

- 1 Le premier est le trajet dit latéral. Il suit le contour de la pièce à partir de l'émetteur jusqu'au récepteur. Il est en général le plus court.
- 2 Le deuxième est le trajet qui passe par l'extrémité du défaut la plus proche des sondes (haut du défaut).
- 3 Le troisième est le trajet qui passe par l'autre extrémité du défaut (bas du défaut).
- 4 Le quatrième est le trajet qui se réfléchit sur la face arrière de la pièce.

Cette configuration se traduit sur l'écran de l'appareil par la représentation A-Scan suivante :

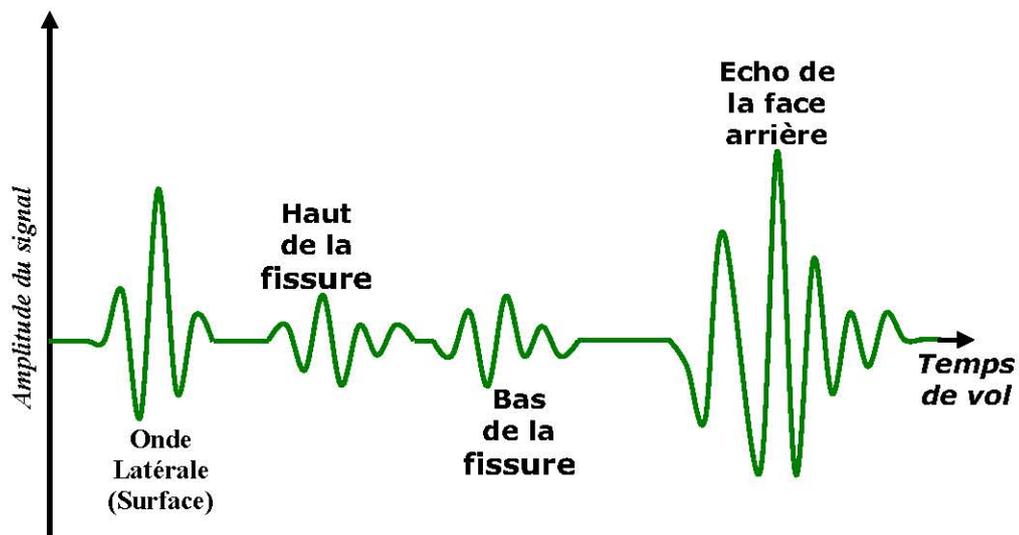


Figure 1.2: Représentation du signal A-scan de la technique

Connaissant les vitesses de propagation de l'onde dans le matériau et les différents temps de vol (ou de transit) mesurés sur l'oscilloscope, il devient aisé de déterminer les positions des défauts et d'estimer sa taille avec une précision acceptable.

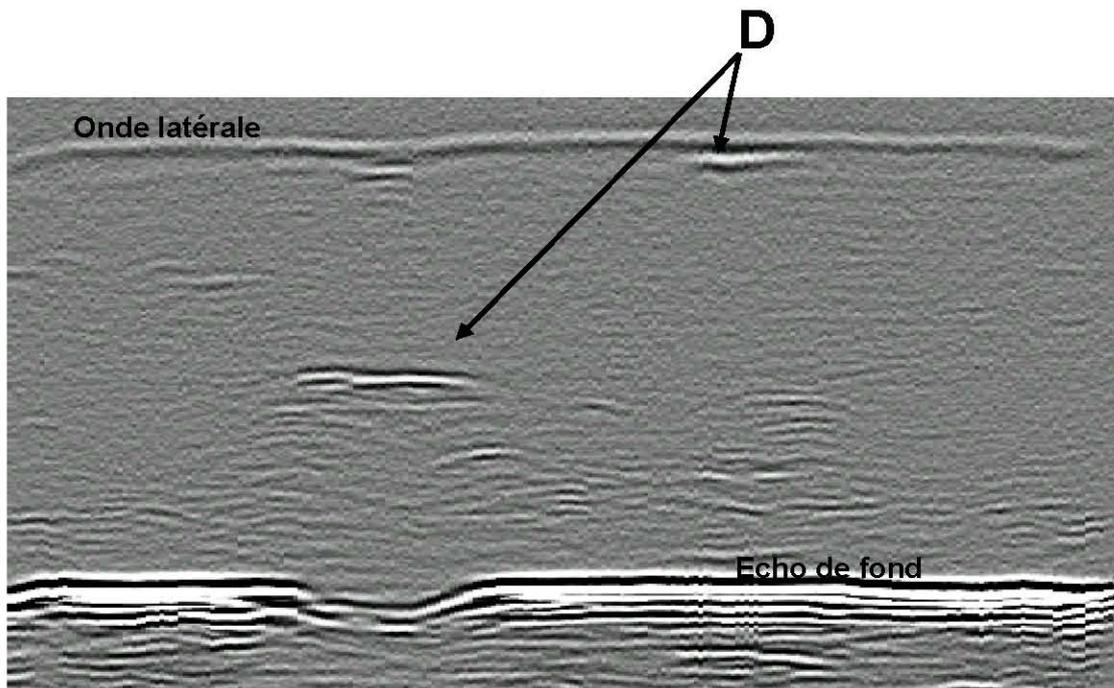


Figure 1.3: Exemple d'image B-SCAN ultrasonore de type TOFD

1.3. Evolutions de la technique TOFD

La technique TOFD a été introduite pour détecter les défauts et surtout pour les dimensionner avec précision.

Les premiers pas sont apparus suite aux travaux de Doyle et Scala en 1978 [6] qui ont réussi à déterminer la profondeur d'une fissure suite à un travail antérieur en 1972 [7]. Une description détaillée de la technique est développée dans les articles de SILK [8-13]; de SILK et LIDINGTON [14]; et de SILK, LIDINGTON et HAMMOND [15].

Ces techniques sont basées sur la réflexion spéculaire vers le transducteur récepteur de l'onde incidente. Pour que le dimensionnement soit parfait l'orientation du défaut doit être perpendiculaire au faisceau incident. Dans la réalité c'est loin d'être le cas. Cette difficulté a été mise en évidence par Haines, Langston, Green & Wilson en 1982 [16]. Ce travail a servi de base aux normes de contrôle pour contourner ce problème. En effet, les normes exigent de procéder à des irradiations par ultrasons sous plusieurs angles d'incidences et l'intervalle d'incertitude se trouve réduit de manière significative. Ceci a été confirmé expérimentalement par le test round-robin du programme européen PISC (Inspection of Steel Components) à partir de 1979 [1], dont le principe est de

procéder au contrôle d'une pièce par plusieurs laboratoires et de comparer les résultats entre les laboratoires d'abord et les dimensions réelles ensuite.

L'un des avantages de la technique TOFD est que les ultrasons se diffractent sur les bords du défaut indépendamment de son orientation par rapport au faisceau acoustique. Dans tous les cas, nous avons des informations sur la configuration de ce défaut. Les travaux de K.G. Hall de British Rail Engineering [1] montrent clairement que les ondes diffractées paraissent rayonner à partir du bord du défaut. Des résultats similaires peuvent être prédits à partir des travaux de modélisation théorique utilisant des solutions par les différences finies pour les équations d'ondes élastiques [17].

La base de la technique TOFD a été inventée au Centre National NDT, Harwell, par le Dr. Maurice Silk. Bien que Miller [18] paraît avoir été le premier qui a publié des preuves sur la détection des signaux diffractés de l'extrémité de la fissure. Il n'a pas été établi que c'était la source de ces signaux et il a alors manqué l'occasion d'inventer la technique TOFD.

Cette dernière a été développée, principalement par Silk et ses collaborateurs chercheurs du Laboratoire de Harwell, au début des années 1970, à partir d'une curiosité de laboratoire lors d'une inspection de feuilles ou tubes de 1 mm d'épaisseur puis d'un blindage de réacteur nucléaire de type PWR (Pressurised water reactor) sur des épaisseurs supérieures à 250 mm.

Afin d'optimiser la puissance du signal de diffraction, les sondes sont disposées comme représenté dans la partie supérieure de la figure 1.1. Un signal typique se compose d'un premier écho à partir d'un déplacement de l'onde par la voie la plus directe, appelé l'onde latérale, suivi éventuellement par plusieurs échos provenant d'ondes diffractées par les extrémités des défauts et enfin une réflexion de la face arrière de la pièce à contrôler.

Pour éviter toute erreur de détection (condition nécessaire mais non suffisante), il faut s'assurer que :

- les signaux diffractés par les extrémités du ou des défaut(s) se situent toujours dans un intervalle délimité par le trajet direct le long de la face de contact avec les sondes et le trajet correspondant à la réflexion sur l'autre face.

- Les signaux reçus par la sonde réceptrice aient l'amplitude maximale correspondant au trajet le plus court. Ceci peut être obtenu en déplaçant les sondes (émettrice et réceptrice simultanément) latéralement.

Il est à noter que les bords supérieurs et inférieurs d'un même défaut donnent des signaux d'amplitudes similaires, et en opposition de phase [1]. Ceci facilite la détection et l'identification d'un défaut et permet de distinguer son haut et son bas.

1.4. Développement des techniques expérimentales de la TOFD

La technique a d'abord été appliquée pour suivre la croissance des fissures débouchant en surface.

Le dispositif consiste à placer deux sondes pointées l'une vers l'autre avec des sabots inclinés permettant d'irradier le bas de la fissure.

L'ensemble est monté sur un support qui maintient une séparation et une orientation constantes des sondes tout en permettant à l'ensemble un balayage manuel ou mécanique le long de l'échantillon défectueux. L'écho provenant du trajet le plus court en surface est constant et peut être mesuré avec précision.

L'accroissement de la fissure peut être rapidement mis en évidence si le trajet séparant les signaux diffractés varie.

L'affichage ou représentation B-scan est une représentation différente. Elle traduit un signal sur l'écran par un pixel (niveau de gris). Pour une configuration type avec une face avant, une face arrière et un défaut entre elles, nous aurons 04 points ou 04 niveaux de gris situés sur l'écran. La distance qui sépare les niveaux de gris correspond à l'épaisseur de l'échantillon. Il devient alors aisé de situer le défaut et surtout le dimensionner.

Physiquement, la représentation B-scan n'est rien d'autre qu'une coupe de l'échantillon parallèlement au faisceau ultrasonore à l'endroit où sont placées les sondes.

Un balayage latéral des sondes permet d'obtenir cette représentation à l'endroit désiré ou sur la totalité de l'échantillon (figure 1.3).

1.5. Bases théoriques de la technique TOFD

Dans cette partie, nous nous intéresserons à deux modes de vibrations des ultrasons. Le premier est le cas où les particules de la matière vibrent dans une direction parallèle à la direction de propagation. Ce sont les ondes longitudinales ou de compression (P-wave). Le deuxième est le cas où les particules de la matière vibrent dans une direction perpendiculaire à la direction de propagation. Ce sont les ondes transversales ou de cisaillement (SV ou SH-wave) (figure 1.4).

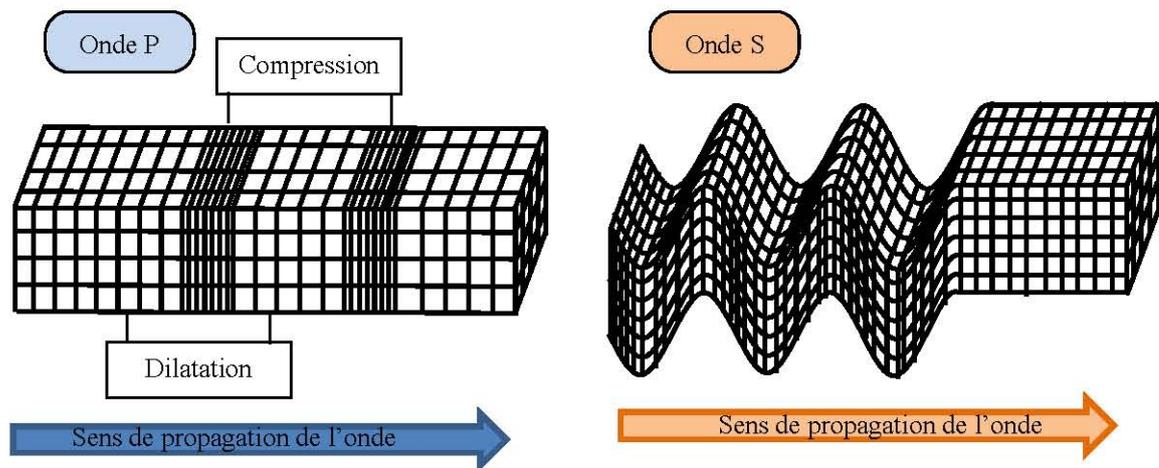


Figure 1.4 Mode de propagation des ondes ultrasonores

Outre leurs directions de vibration, ces deux modes se distinguent par des vitesses de propagation et des atténuations différentes et qui dépendent du matériau dans lequel ces ondes se propagent. La majorité des études de la technique TOFD utilisent les ondes longitudinales à cause de leur faible atténuation et de la simplicité de leur utilisation.

Les vitesses de propagation des ondes longitudinales C_p et transversales C_s sont données par les relations suivantes :

$$C_p = \sqrt{\frac{\lambda + 2\mu}{\rho}} \quad (1.2)$$

$$C_s = \sqrt{\frac{\mu}{\rho}} \quad (1.3)$$

$$E = \frac{\mu(3\lambda + 2\mu)}{\lambda + \mu} \quad (1.4)$$

Où λ et μ sont les constantes de Lamé. E est le module d'élasticité ou module de Young. ρ est la masse volumique du matériau.

$$\nu = \frac{\lambda}{2(\lambda + \mu)} \quad (1.5)$$

$$K = \lambda + \frac{2\mu}{3} \quad (1.6)$$

μ est le coefficient de Poisson. K est le module de cisaillement.

Afin de simplifier le calcul de la profondeur à partir de laquelle les signaux diffractés proviennent, nous supposons que le front d'onde sera considéré comme provenant d'un point source et convergeant vers un point de détection. Bien que ceci soit une approximation, elle est suffisamment précise si deux conditions sont réunies. La première est que la source de diffraction soit dans le champ lointain des sondes émettrices et réceptrices défini comme :

$$N_0 = \frac{D^2}{4\Lambda} \quad (1.7)$$

Où D est le diamètre effectif de l'élément vibrant et Λ la longueur d'onde.

La deuxième condition est que la source de diffraction reste raisonnablement contenue dans l'axe du faisceau de l'émetteur et du récepteur.

Si ces deux conditions sont réunies, nous serons en mesure de déterminer les intervalles de temps entre les signaux qui suivent les différents trajets pour de petites portions de la période.

Pour calculer la taille et la profondeur des fissures à partir d'une inspection en surface, seul le théorème de Pythagore suffit.

Supposons que la fissure est orientée dans un plan perpendiculaire à la surface d'inspection et la ligne qui joint l'émetteur et le récepteur le long de cette surface. Supposons aussi que la fissure est à mi-chemin de l'émetteur et du récepteur. Cette dernière supposition est obtenue par le déplacement des deux sondes jusqu'à ce que le trajet ultrasonore qui les sépare soit minimum (figure 1.5).

Si l'extrémité la plus proche de la fissure a une profondeur d et que sa longueur est a , alors nous aurons :

$$t_L = \frac{2S}{c} \quad (1.8)$$

$$t_1 = \frac{2\sqrt{S^2 + d^2}}{c} \quad (1.9)$$

$$t_2 = \frac{2\sqrt{S^2 + (d+a)^2}}{c} \quad (1.10)$$

$$t_{bw} = \frac{2\sqrt{S^2 + H^2}}{c} \quad (1.11)$$

Où t_L , t_1 , t_2 , et t_{bw} sont indiqués dans la figure 1.5 et H est l'épaisseur de la plaque. Les temps t_1 et t_2 sont les temps d'arrivés des échos diffractés par les bords de la fissure. Le temps le plus court t_L correspond à l'onde latérale et t_{bw} est le temps d'arrivé de l'écho de la face arrière. C est considéré comme étant soit C_p ou C_s , la vitesse de propagation du mode longitudinal ou transversale, respectivement.

En manipulant les équations ci-dessus, nous trouvons la profondeur de la partie supérieure de la fissure par rapport à la surface de contrôle :

$$d = \frac{1}{2}\sqrt{C^2 t_1^2 - 4S^2} \quad (1.12)$$

La taille de la fissure est donnée par :

$$a = \frac{1}{2}\sqrt{C^2 t_2^2 - 4S^2} - d \quad (1.13)$$

La distance qui sépare les deux sondes se calcule par :

$$2S = C_L t_L \quad (1.14)$$

Où C_L est la vitesse de l'onde latérale. Sur une pièce plate, cette vitesse est identique avec les vitesses C_p ou C_s , les vitesses de propagation respectives du mode longitudinal ou transversale.

Un exemple est donné pour une fissure de profil irrégulier et de longueur comprise entre 8 et 15 mm. La précision de la mesure de profondeur est discutée et détaillée par Lidington, Silk, Montgomery and Hammond [19]. Cette étude montre que l'incertitude de ces mesures n'excède pas 3 dixièmes de millimètre.

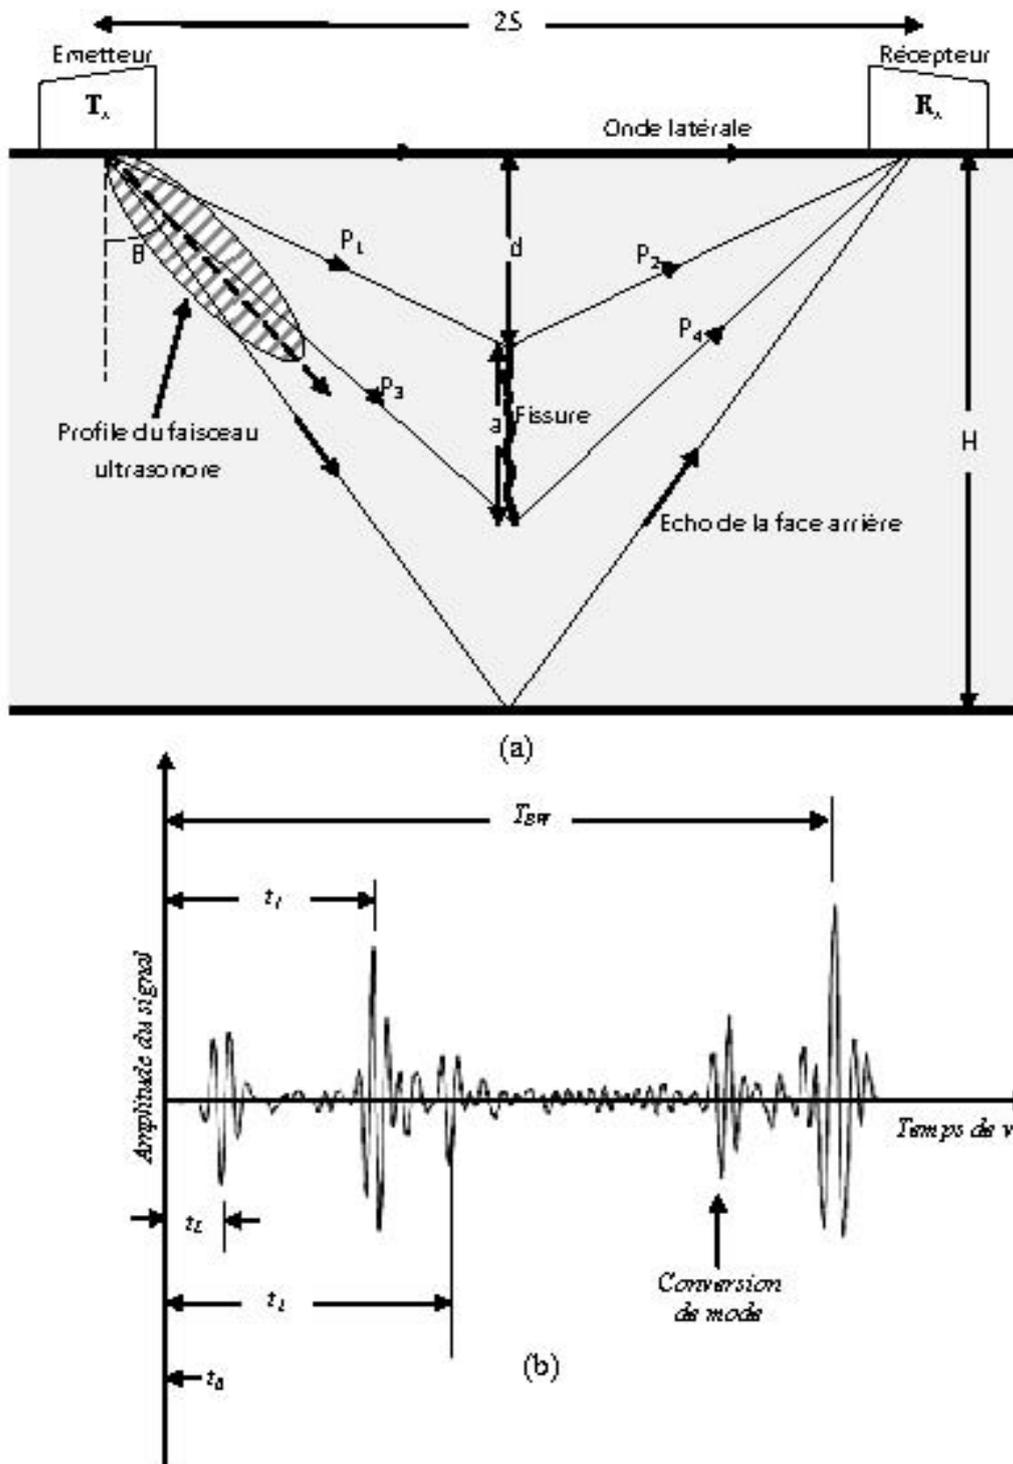


Figure 1.5 : (a) La base de la technique TOFD avec deux sondes. Les bords de la fissure sont déterminés à partir des différences de temps entre l'onde latérale et les impulsions qui suivent les chemins $P_1 + P_2$ ou $P_3 + P_4$. Ces chemins correspondent à t_1 et t_2 respectivement dans la figure (b)

1.6. Expérimentations et acquisitions des images TOFD

Dans notre expérimentation, nous avons reconstitué des images TOFD par immersion en utilisant une chaîne d'acquisition ultrasonore illustrée par la figure 1.6. Deux sondes à immersion non focalisées sont utilisées et leur déplacement suivant le plan Y est effectué par un moteur pas à pas commandé automatiquement par un micro – ordinateur à travers l'interface RS-232 (voir la figure 1.7). Un oscilloscope programmable commandé par PC à travers l'interface IEEE 488, permet un échantillonnage sur un nombre de points et une fenêtre temporelle réglable. Les signaux recueillis sont acheminés vers le PC afin d'être traités, quantifiés et stockés sous forme d'image B-scan.

Les résultats des acquisitions après quantification de chaque pixel en niveau de gris sont donnés par les images de la figure 1.8.

L'image 1.8.a montre le résultat du contrôle d'un bloc en aluminium avec deux trous dans la face arrière. Nous avons utilisé une fenêtre temporelle autour des deux défauts.

Pour l'image 1.8.b c'est le contrôle d'un bloc en acier avec trois trous de différentes dimensions dans la face arrière. La fenêtre temporelle est choisie de tel sorte à éliminer les échos de la face avant.

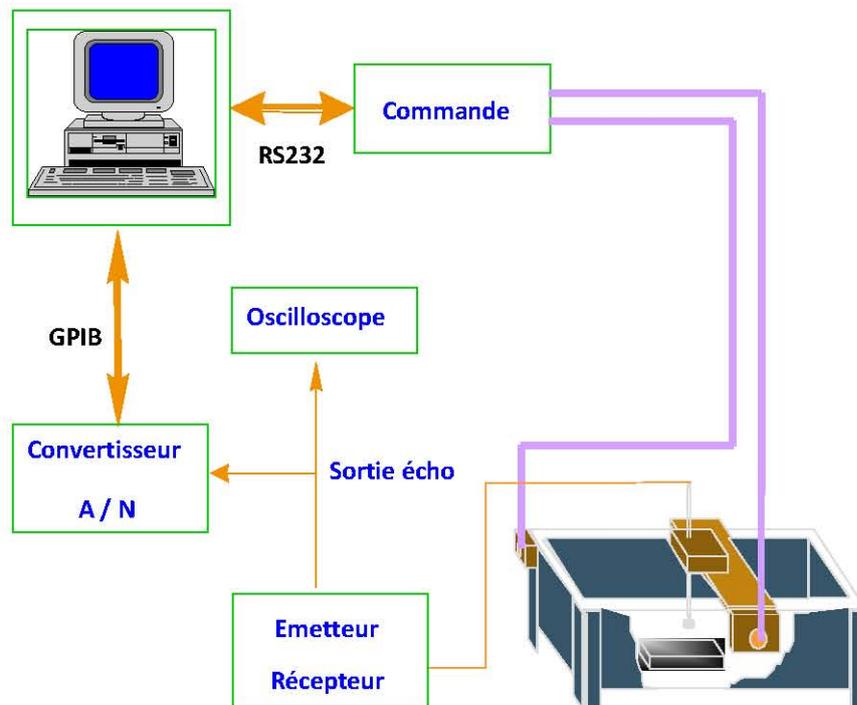


Figure 1.6 : Chaîne d'acquisition ultrasonore

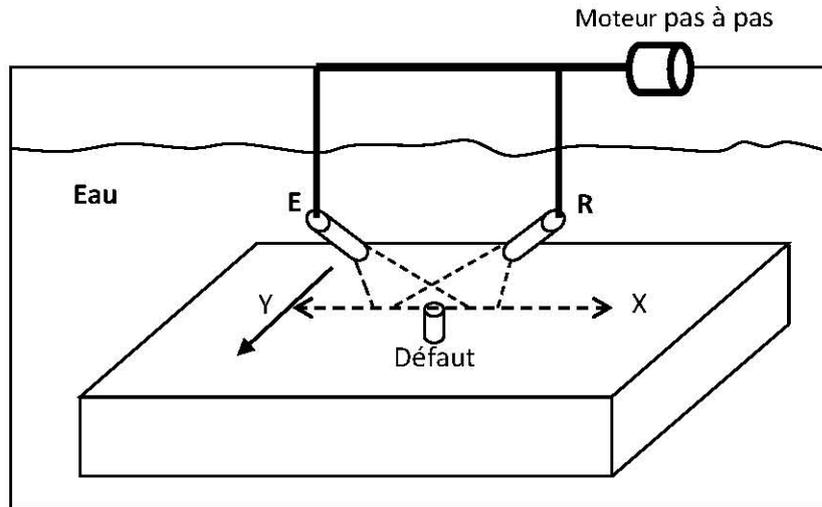
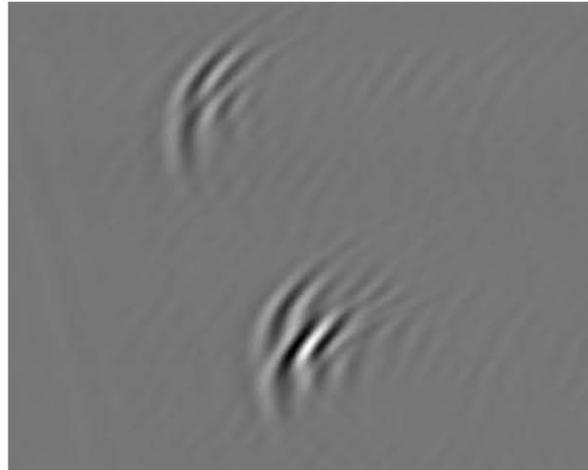
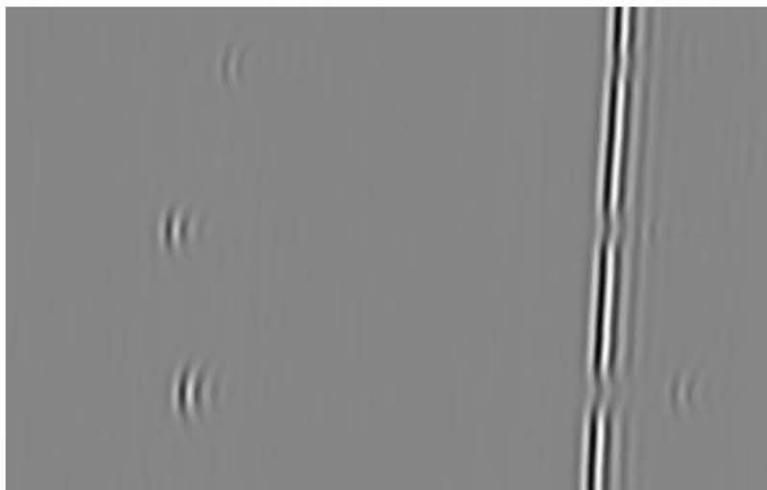


Figure 1.7 : Mise en œuvre de la technique TOFD en immersion



(a)



(b)

Figure 1.8 : Images TOFD par immersion

Pour l'acquisition des images TOFD par contact, nous avons utilisé un Omniscan Olympus (MX1) et un scanner HSMT-Flex avec le TRPP 5810 comme émetteur-préamplificateur (figure 1.9). Nous avons contrôlé deux joints soudés bout à bout avec des épaisseurs différentes (10mm et 25mm). Pour la première épaisseur, nous avons utilisé des sondes de fréquence 2.25 Mhz et 5 Mhz pour la deuxième. Des sabots TOFD de 70° et 45°. Les résultats sont illustrés dans les figures 1.10 et 1.11. Au-dessus de chaque image TOFD un signal A-Scan correspondant au défaut présent dans chaque joint est donné.



Figure 1.9 : Chaîne d'acquisition d'image TOFD par contact

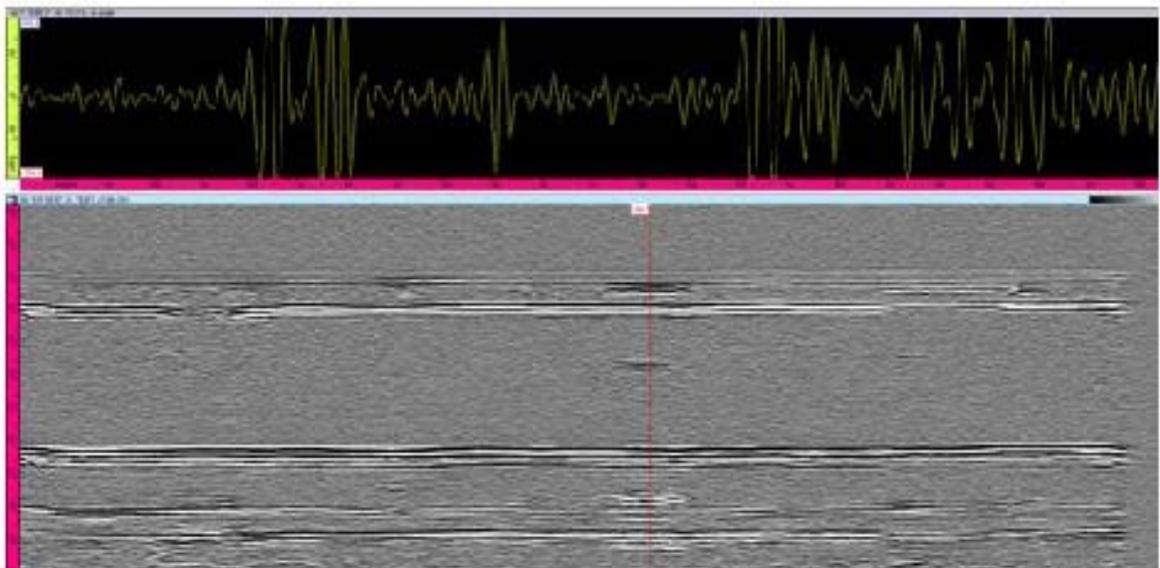


Figure 1.10 : Image TOFD correspondant au 1^{er} joint d'épaisseur 10mm

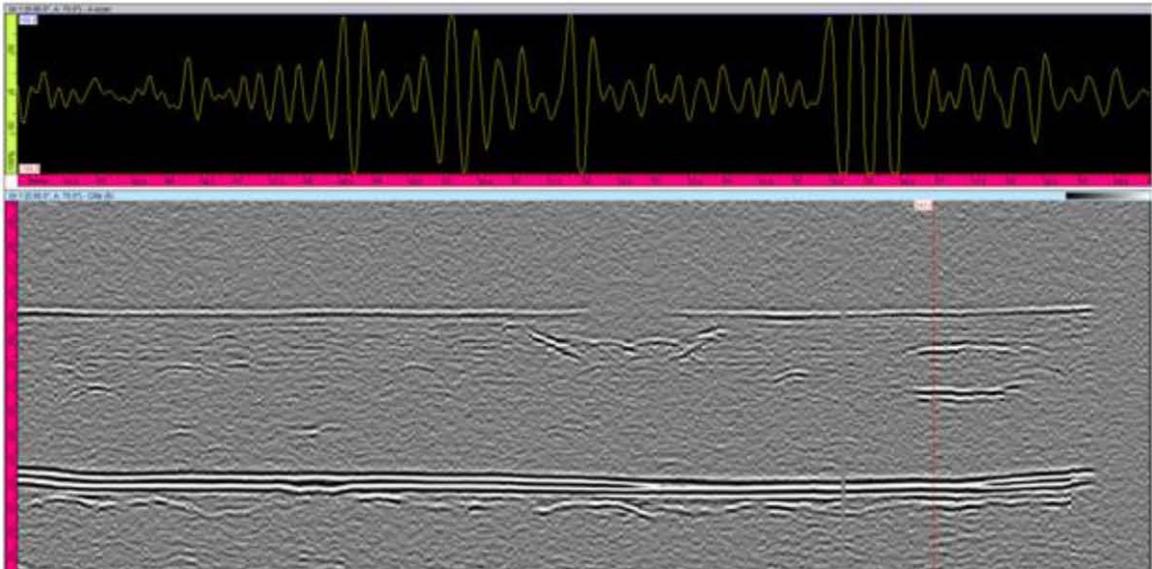


Figure 1.11 : Image TOFD correspondant au 2^{ème} joint d'épaisseur 25mm

Remarque : l'utilisation de l'Omniscan nous a donné des images de faible résolution verticale à savoir 130 pixels entre l'onde latérale et la face arrière. Ce résultat rend l'implémentation d'algorithme d'analyse d'images impossible.

Afin de valider les approches qui vont être implémentées dans ce travail, nous avons testé les deux approches développées sur deux images réalisées à l'échelle industrielle. Ces images représentent le résultat d'un contrôle non destructif automatique par ultrasons réalisées sur des soudures avec des défauts réels connus et elles font l'objet d'interprétation par des inspecteurs niveau II.

La première image (figure 1.12.a) est une B-Scan de taille 245 × 300 pixels qui illustre le résultat de l'inspection d'un joint soudé bout à bout d'un bloc en acier avec trois défauts réels.

Défaut D1 : Fissure débouchante.

Défaut D2 : Inclusion de laitier.

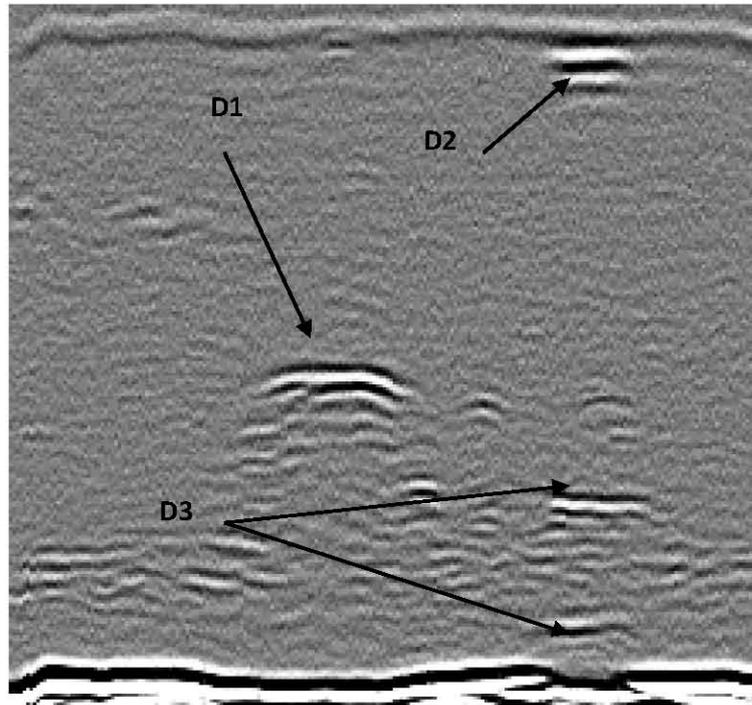
Défaut D3 : manque de fusion.

La deuxième image est une B-scan avec une taille de 500 x 300 pixels (Figure 1.12.b). Le test résulte trois défauts réels :

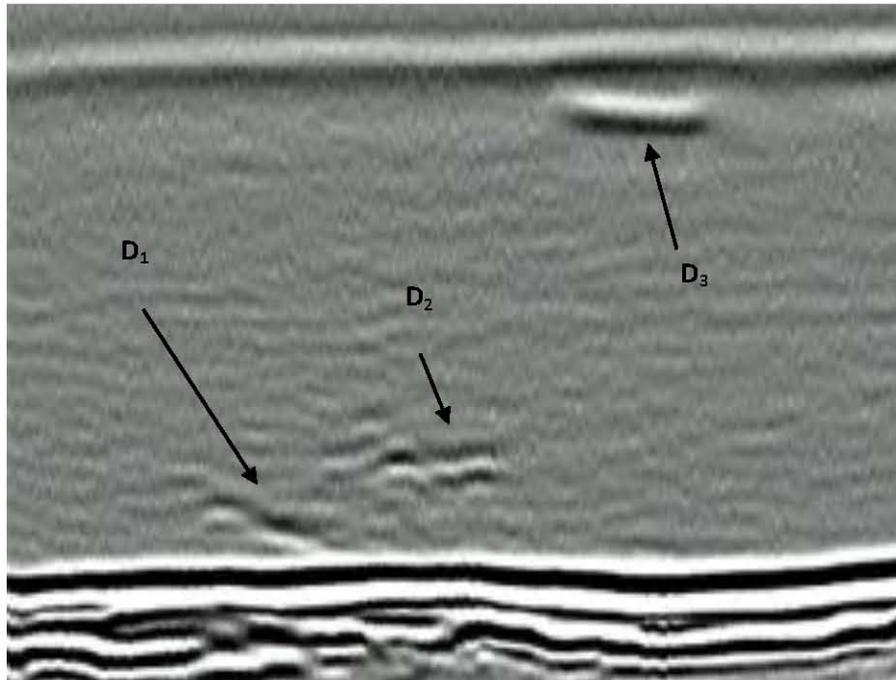
Défaut D1 : manque de fusion.

Défaut D2 : fissure débouchante.

Défaut D3 : Manque de fusion.



(a)



(b)

Figure 1. 12 : Images TOFD issues de contrôle réel à l'échelle industriel

1.7. Problématique étudiée et état de l'art

A l'exception de certains pays développés, l'utilisation des images TOFD dans le contrôle industriel n'a pas connu un grand succès dans son utilisation industrielle. Même si la technique est normalisée, l'interprétation de ces images reste dépendante de la compétence et de l'expérience des inspecteurs experts. Lors d'un contrôle d'un pipeline en construction, grâce à la robotisation de la chaîne d'imagerie, l'acquisition des signaux A-Scan et la constitution des images TOFD sont réalisées d'une manière rapide. L'inconvénient majeur réside dans le nombre très élevé d'images à interpréter. Cette tâche consiste d'abord à détecter les défauts et ensuite les évaluer en dimensions et en orientations.

Si on examine ces images de près, nous constatons deux zones comme le montre la figure 1.13. La texture de la zone où se situe le défaut est bien différente de la zone saine. Une première remarque s'impose, une recherche sommaire de texture permet la détection des zones présentant des défauts visibles ou partiellement visibles par un opérateur. Ce travail vise donc à étudier et développer des outils d'analyse d'images permettant de détecter et de localiser des défauts présents dans un matériau métallique. Les approches que nous proposons seront basées sur la segmentation des images TOFD pour la détection des défauts en utilisant l'information texturale d'un défaut. L'analyse de textures pour la segmentation d'images sera détaillée dans le chapitre 2.

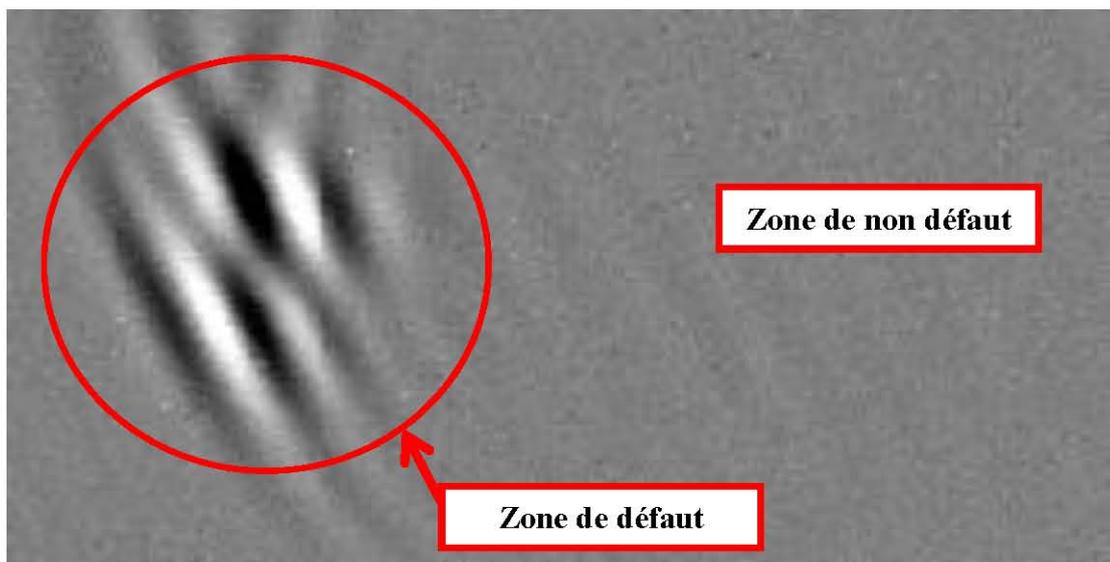


Figure 1.13 : Zoom sur un défaut dans une image B-Scan ultrasonore de type TOFD

Beaucoup de chercheurs dans le domaine de l'évaluation non destructive par ultrasons des matériaux utilisent d'une part, la technique SAFT (Synthetic Aperture Focusing Technique) pour améliorer la résolution latérale et le rapport SNR des images ultrasonores [20]. D'autre part, ils utilisent la méthode TOFD pour déterminer l'ampleur du défaut à travers sa caractérisation en hauteur qui est utilisée comme un paramètre critique dans la mécanique de la rupture [21]. Néanmoins, chaque technique a des inconvénients :

- TOFD :

Cette méthode a un problème de résolution dans la mesure du temps d'arrivée des ondes diffractées par les bords du défaut, notamment les défauts proches de la face avant et de la face arrière de la pièce.

- SAFT :

En utilisant cette technique, on suppose que les signaux d'échos du défaut ont la même forme et la même fréquence. Cela est incompatible avec le profil réel d'un faisceau ultrasonore émis par un transducteur, dont les fréquences les plus basses ont tendance à diverger à des angles relativement importants, tandis que les hautes fréquences sont beaucoup plus focalisées.

La performance du transducteur est fortement influencée par la fréquence centrale, l'angle de réfraction et de la taille de l'élément piézoélectrique de la sonde. Ces paramètres importants peuvent aussi affecter directement la sensibilité et la véracité de la détection. Lorsque la fréquence centrale de la sonde devient plus faible, donc une longueur d'onde plus grande et l'atténuation devient plus petite, la détection des défauts augmente dans les profondeurs du matériau (de grande épaisseur). Mais la résolution obtenue est mauvaise, ce qui affaiblit la résolution des ondes diffractées entre les deux extrémités du défaut. Inversement, lorsque la fréquence est plus élevée, la résolution est meilleure mais la détection devient peu profonde, et la gamme de détection devient plus étroite. En conséquence, il est impossible de détecter tous les défauts sur la pièce.

Dans ce contexte, un autre travail [22] a permis l'élaboration d'un modèle analytique du transducteur permettant la construction d'un spectre de référence

appropriée pour l'opération de déconvolution, et représentant la dépendance du spectre de fréquence d'un faisceau sur la position d'un défaut par rapport à l'émetteur. Les résultats expérimentaux sont utilisés pour fournir une estimation de l'amélioration de la précision de dimensionnement du défaut.

Lors de cette étude, nous avons retenu aussi un travail de simulation par la méthode des éléments finis en utilisant le logiciel « ANSYS » [23]. Ce travail a permis la simulation du phénomène de diffraction permettant la constitution des images TOFD.

Une autre approche adoptée par plusieurs chercheurs est le fait qu'une image TOFD soit caractérisée par une texture. Dans ce contexte, C. F. Theresa Cenate [24] a mené une étude sur le bruit de structure qui est l'un des paramètres pouvant modifier la texture de l'image TOFD puisqu'il provient du phénomène de diffusion. Elle a mené des investigations dans le but de réduire le bruit de structure du à la forte température des matériaux utilisés dans l'inspection des installations nucléaires. La transformée en ondelettes (Coiflet/Symlet) avec un seuillage (universal) a été appliquée aux signaux A-Scan pour améliorer le rapport signal sur bruit des images TOFD.

D'autres auteurs [25-28] ont travaillé dans l'amélioration de la localisation de certains défauts dans une image TOFD en procédant au calcul analytique des paraboles dues à la diffraction des ondes ultrasonores.

L'article présenté par [29] compare la performance de 4 types de filtres dans la bande fréquentielle des signaux TOFD. Afin de concevoir un filtre efficace de haute performance à la réception du système TOFD, les auteurs constatent que dans les mêmes conditions des fréquences de travail, le filtre de Butterworth améliore la probabilité de détection.

Une autre étude a été proposée dans [30] qui est basée sur la corrélation entre l'évaluation analytique des images TOFD et les résultats expérimentaux obtenus sur la variation de l'amplitude et le temps de vol du signal diffracté en fonction de la profondeur, la hauteur et l'angle d'inclinaison des défauts.

La méthode (TOFD) est utilisée surtout dans le dimensionnement des défauts par la mesure du temps de vol de l'écho de l'onde longitudinale diffractée par le bord de ce défaut. Cette technique est limitée dans l'inspection près de la surface en raison de la superposition des signaux. Ici, cette limitation est surmontée en utilisant le signal d'onde diffractée de cisaillement (au lieu de l'onde longitudinale) ; elle est donc appelée S-TOFD. Des expériences ont été menées sur des échantillons avec des défauts proches de la surface d'un échantillon de plaque plane pour évaluer l'efficacité de la technique S-TOFD. Une augmentation de la précision de dimensionnement des défauts a été obtenue. Cette technique étant associée aux techniques de traitement du signal a permis d'améliorer encore plus ces résultats [31].

1.8. Conclusion

Dans ce chapitre, nous avons décrit les bases théoriques de la TOFD. Nous voyons que cette technique se présente comme une alternative aux techniques classiques de contrôle non destructif par ultrasons. En effet, elle présente un avantage certain sur la localisation et le dimensionnement des fissures et des défauts en général. Une étude montre que l'incertitude des mesures n'excède pas 3 dixièmes de millimètre [19]. Toutes les normes de contrôle dont les plus sévères dans les critères de rejet exigent une précision de l'ordre de 1mm.

Dans l'expérimentation, nous avons réalisé des images TOFD par immersion et par contact. Néanmoins, les images réalisées par contact à l'aide de l'Omniscan sont de faible résolution. Ce résultat rend l'implémentation d'algorithmes d'analyse d'images impossible. Pour cela, nous avons utilisé des images TOFD réalisées à l'échelle industrielle avec des défauts réels détectés et localisés par des inspecteurs niveau II. Ceci nous permettra de valider nos résultats de segmentation.

L'observation de près d'une image zoom sur un défaut a révélé qu'on peut compter sur l'information texturale d'un défaut pour la segmentation et la détection des défauts. C'est l'approche que nous avons adoptée et elle fera l'objet des prochains chapitres.

CHAPITRE 2

TEXTURE ET ANALYSE D'IMAGES

2.1. Introduction

Les images constituent l'un des moyens les plus importants qu'utilise l'homme pour communiquer avec ses semblables. Les efforts récents élargissent même cette communication aux machines. L'analyse d'images est l'ensemble des méthodes qui cherchent à rendre cette opération possible, plus simple et plus efficace. Cette dernière est née de l'idée et de la nécessité de remplacer l'observateur humain par la machine. Généralement on distingue deux types d'analyse : ceux de bas-niveau s'apparentent au traitement du signal et ceux de haut-niveau.

La segmentation est un traitement de bas-niveau qui consiste à créer une partition de l'image en plusieurs objets, chaque partie est un ensemble connexe de pixels ayant les mêmes propriétés (intensité, texture, couleur,... etc.) différentes de celles des parties voisines. C'est aussi un traitement qui est en amont de la reconnaissance de formes ou de l'interprétation de scènes.

Les deux approches les plus sollicitées de segmentation sont celles en détection de contours répondant au principe de discontinuité entre deux pixels et en analyse de régions qui se basent sur le principe de similarité. Une troisième approche consiste à utiliser les deux premières méthodes de segmentation, à savoir la segmentation en région avec comme conditions aux limites, la carte de contours de l'image d'origine.

La texture est un élément omniprésent dans la réalité. Chaque surface possède sa propre texture. La texture est donc un indice important dans la perception de la nature de la surface observée. L'être humain utilise la texture pour la perception de l'environnement, en particulier la reconstruction 3D. Nous distinguons aussi les frontières entre les régions de textures différentes, même si l'intensité moyenne est la même dans les deux régions. Dans certains domaines d'application de la vision artificielle, il est essentiel de pouvoir détecter les frontières entre les différentes régions de texture. Pensons simplement à l'analyse de scènes où la texture est utilisée.

Afin d'exposer plus en détail les différentes méthodes de segmentation basées sur l'analyse de texture, on se doit de présenter la notion de texture car elle est très souvent associée aux attributs permettant de caractériser l'homogénéité d'un ensemble connexe de pixels. Nous présenterons ensuite les principales méthodes d'analyse de texture utilisées afin d'extraire des caractéristiques texturales des régions d'une image. Pour enfin aborder les différentes approches liées à la segmentation d'image.

2.2. Notion de texture

Intuitivement, la notion de texture peut paraître familière, mais il s'avère rapidement difficile d'en donner une définition précise. La définition littéraire, dit que la texture est l'agencement spatial d'un même motif dans différentes directions de l'espace. Cette définition est limitative car elle ne tient pas compte des informations visuelles qui permettent de décrire la texture qualitativement à l'aide d'adjectifs tels que contrastée, grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière. L'information élémentaire qu'elle contient peut être transcrite en niveaux de gris. Cette information est, en général, une mesure physique liée à un système d'acquisition. Par exemple, pour un système d'imagerie TOFD, un récepteur ultrasonore détecte les vibrations transmises par une discontinuité de la matière et l'image issue de cette acquisition est une image en niveaux de gris. De par notre cadre applicatif (l'imagerie TOFD), nous avons travaillé uniquement sur des images en niveaux de gris.

2.2.1. Attributs visuels de la texture

Dans l'image 2.1, l'œil humain ne distingue de prime abord qu'une seule texture; il n'est pas enclin à discriminer les deux composantes qui la constituent [32].



Figure 2.1 : L'œil ne distingue qu'une texture

Ce phénomène apparaît lorsque les régions texturées ont des statistiques du deuxième ordre identiques (les statistiques de deuxième ordre désignent des propriétés de paires de pixels et utilisent donc souvent la notion de voisinage, de cooccurrence). Pour résoudre cette difficulté, Julesz et Bergen [33] ont introduit la théorie des textons. Le texton est un élément primitif d'une texture optique au niveau de sa perception. Les textons sont des caractéristiques locales des stimulus visuels extraites au niveau pré-attentif.

2.2.2. Texture et niveaux de gris

Sur des images à niveaux de gris, l'information fournie par la texture est indispensable pour distinguer différentes régions d'une image.

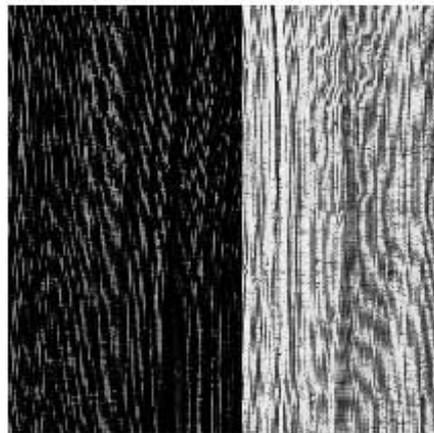


Figure 2.2 : Les niveaux de gris discriminent les régions

Dans l'image 2.2, on parlera de la partie claire et de la partie plus sombre.

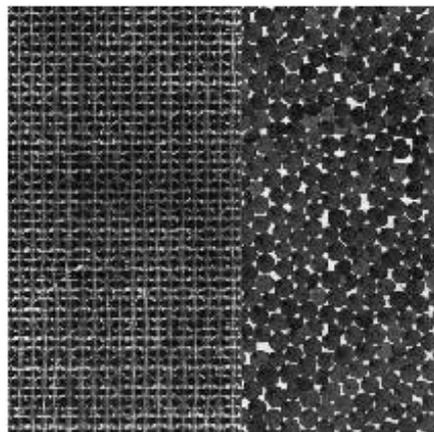


Figure 2.3 : La texture discrimine les régions

Dans l'image de la figure 2.3, on évoquera plutôt les aspects structuraux de chaque partie, ce qui permet alors de considérer la texture comme l'information qui établit une distinction entre ces régions.

2.2.3. Invariance par translation

Intuitivement, la notion de texture est associée à la perception de l'aspect homogène de certaines caractéristiques d'une région. A une échelle donnée, une texture présente le même aspect quelle que soit la zone observée : elle est invariante par translation. Cette propriété ne peut être vérifiée que si l'échelle choisie est pertinente au regard de la texture considérée. Cette propriété a une influence directe sur l'analyse texturale de l'image ; en effet, le fait d'analyser de petites parties d'une texture au lieu de la texture toute entière (mauvaise échelle) peut conduire à l'étude de zones ne possédant pas les mêmes caractéristiques.

L'image de la figure 2.4 présente deux fenêtres de visualisations cohérentes, elles fournissent la même information texturale.

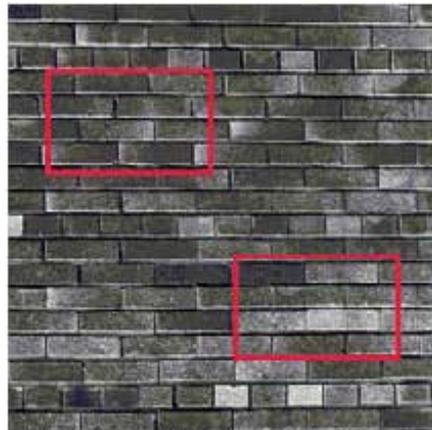


Figure 2.4 : La fenêtre de visualisation est satisfaisante

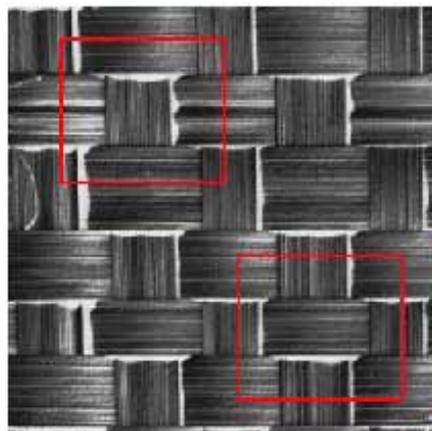


Figure 2.5: La fenêtre de visualisation n'est pas satisfaisante

L'image de la figure 2.5 présente deux fenêtres de visualisations incohérentes puisqu'on ne retrouve pas la même information texturale.

2.3. Classification des textures

Avant de donner une définition de la texture dans la partie suivante, nous allons voir comment il est possible de classer l'ensemble des textures en deux catégories [34].

2.3.1. Textures structurelles

On peut considérer les textures structurelles comme étant la répétition de motifs élémentaires. La répartition spatiale de ces motifs de base suit des règles de directions et de placements.

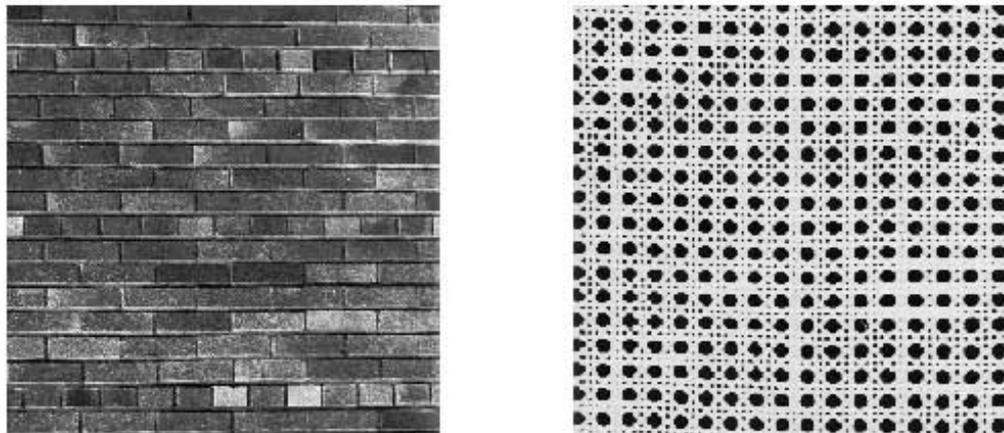


Figure 2.6 : Deux textures structurelles

Par exemple, l'image de gauche est composée d'un ensemble de briques (les éléments de base) disposées régulièrement de manière horizontale. Cette catégorie de texture a engendré les méthodes d'analyses structurelles [35-37]. Ces méthodes s'appuient donc sur le fait que les textures sont formées d'éléments structurants de base. L'idée générale sous-tendant ces méthodes est une recherche et une description de primitives (qui peuvent être paramétrées) suivie d'une définition de la structure, c'est à dire d'un ensemble de règles (syntaxiques ou autres) sur ces primitives.

2.3.2. Textures aléatoires

Contrairement aux textures structurelles, les textures aléatoires ont un aspect désordonné tout en apparaissant globalement homogènes.

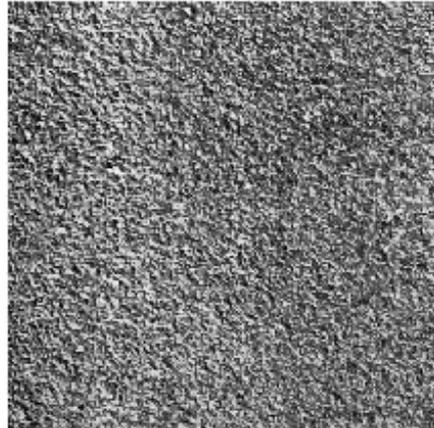


Figure 2.7 : Texture aléatoire

Cette catégorie de texture a fait l'objet de nombreux travaux de recherche fondés sur les méthodes d'analyse statistique [38,39]. Ici l'image est considérée comme étant associée à un processus aléatoire bidimensionnel.

C'est en particulier ce type de texture que nous allons tenter de caractériser dans notre approche.

Remarque : ces différentes catégories de texture montrent qu'il est difficile de donner une définition précise de la texture. Nous avons d'un côté une information structurée et constructive, et d'un autre côté une information désordonnée et plus difficile à décrire (même visuellement d'ailleurs). Nous pouvons cependant dire que la texture est une information obtenue à partir d'un ensemble de mesures locales (statistiques, géométriques, sémantiques, . . .) dans une région (fenêtre de visualisation) d'une image.

2.4. Analyse textuelle

L'étude de la texture a fait l'objet de nombreux travaux de recherche qui ont engendré une multitude de méthodes d'analyse [40], [41]. Ces méthodes ont pour objet de caractériser, décrire, discriminer, . . ., segmenter les textures. Nous nous attacherons plus loin à la présentation de certaines méthodes de segmentation. Dans un premier temps, nous allons aborder ici différentes méthodes permettant l'extraction d'attributs texturaux dans les images en niveaux de gris. L'accent sera mis sur les méthodes statistiques puisqu'elles sont directement en rapport avec nos travaux.

2.4.1. Méthodes statistiques

Les méthodes statistiques consistent à étudier les relations entre chaque pixel et ses voisins. Ces méthodes sont adaptées à l'étude des structures fines sans régularité apparente (textures aléatoires). Trois grandes classes de méthodes seront étudiées. Celles du premier ordre, celles d'ordre deux et celles d'ordre supérieur ; l'ordre d'une méthode étant ici le nombre de pixels mis en jeu pour l'évaluation de chaque résultat.

2.4.1.1. Méthodes d'ordre 1

L'analyse des régions d'une image par une méthode d'ordre 1 s'effectue directement à partir des niveaux de gris des pixels de l'image. Chaque pixel de la région sera donc représenté par une valeur commune à la région [34].

Soit h , l'histogramme des N_g niveaux de gris d'une image.

$$h(i) = \frac{\phi(i)}{S} \quad (2.1)$$

Où $\phi(i)$ est le nombre de pixels de niveau de gris i ;

Où S est la superficie de l'image (le nombre total de pixels de l'image).

➤ Le moment d'espace du 1^{er} ordre ou moyenne :

$$\mu = m_1 = \sum_{i=1}^{N_g} i.h(i) \quad (2.2)$$

➤ Le moment d'espace centré du 2nd ordre ou variance :

$$\sigma^2 = m_2 = \sum_{i=1}^{N_g} (i - \mu)^2 h(i) \quad (2.3)$$

➤ Le troisième moment :

$$m_3 = \sum_{i=1}^{N_g} (i - \mu)^3 h(i) \quad (2.4)$$

Le troisième moment caractérise l'obliquité de l'histogramme et est nul lorsque l'histogramme est symétrique.

➤ Le moment d'espace centré d'ordre k :

$$m_k = \sum_{i=1}^{N_g} (i - \mu)^k h(i) \quad (2.5)$$

➤ Entropie :

$$e = - \sum_{i=1}^{N_g} h(i). \log(h(i)) \quad (2.6)$$

L'entropie est une mesure de l'uniformité de l'histogramme. Si celui-ci est uniformément distribué, la valeur de l'entropie est maximale. Par contre, si l'histogramme présente une concentration quelconque, cette valeur tend vers 0.

Remarque : Les méthodes statistiques d'ordre 1 permettent une étude simple et rapide des textures. Cependant elles ne permettent pas d'étudier les relations entre deux pixels (utile pour la directivité par exemple). Des présentations plus poussées de ces méthodes pourront être trouvées dans [42]. On trouvera dans [43] une comparaison des méthodes statistiques d'ordre 1 contre celles d'ordre 2.

2.4.1.2. Matrice de cooccurrences

Les matrices de cooccurrences sont une méthode d'ordre 2. En effet, chaque résultat met en valeur les relations entre deux pixels. Les matrices de cooccurrences représentent donc les dépendances spatiales des niveaux de gris. Cette approche est devenue la plus connue et la plus utilisée pour extraire des caractéristiques de textures [34].

Soit une image I de taille $(N_x \times N_y)$, où chaque pixel a un niveau de gris compris entre 1 et N_g (ou 0 et N_g-1).

La matrice de cooccurrence de I contient les estimations de probabilité de transition d'un niveau de gris i en un niveau de gris j entre deux pixels séparés d'une distance d suivant l'orientation θ . Elle décrit donc, de manière statistique, les relations spatiales liant deux pixels voisins. La taille d'une telle matrice pouvant se révéler importante, on préfère manipuler des opérateurs ou indices de texture propres à chaque matrice. Ces opérateurs donnent une estimation d'une propriété de la texture. Pour économiser les ressources des calculateurs, on fixe la distance d à 1, et pour chaque indice on retient la moyenne des valeurs calculées pour les orientations 0° , 45° , 90° et 135° .

Afin d'obtenir une matrice de cooccurrence, il convient de recenser les transitions de NDG (niveau de gris) tel que montré dans la figure suivante (figure 2.8).

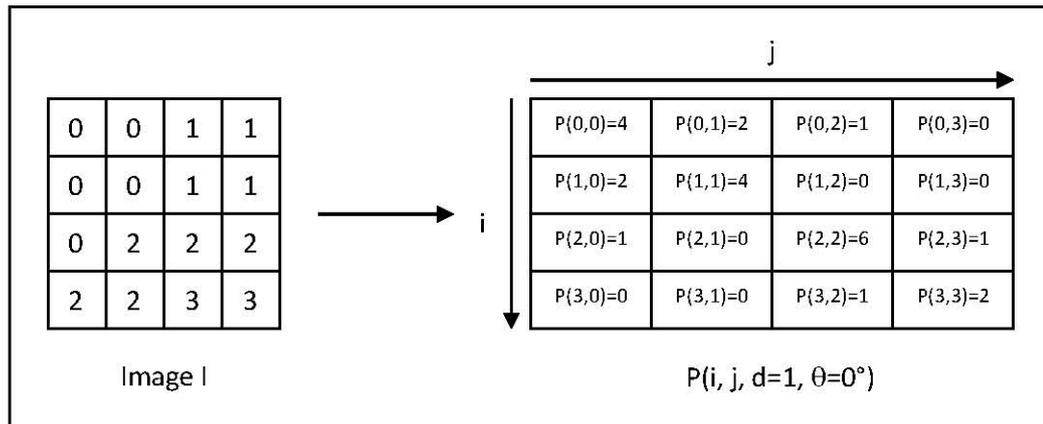


Figure 2.8 : Recensement des transitions

Cette matrice est symétrique parce que si un pixel de NDG i est voisin d'un autre pixel de NDG j alors un pixel de NDG j est voisin d'un pixel de NDG i . Pour la même raison, les termes de la diagonale sont systématiquement des nombres pairs.

On divise chaque élément de la matrice P par le nombre total R de transitions dans une image. Respectivement, suivant les orientations $0^\circ/90^\circ$ et $45^\circ/135^\circ$, on recense $R=2 \times N \times (N-1)$ et $R=2 \times (N-1) \times (N-1)$ transitions. La matrice résultante est dite de cooccurrence et est notée p (figure 2.9).

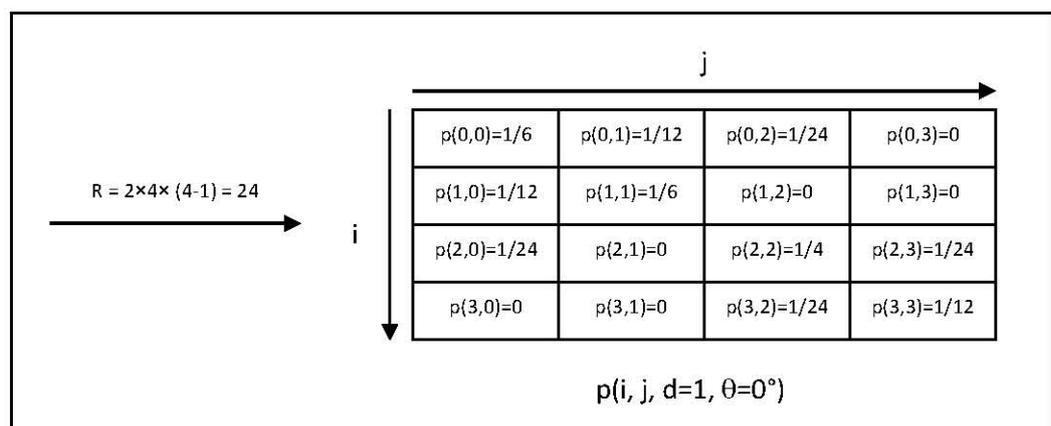


Figure 2.9 : Matrice de cooccurrence

Les quatorze indices découlant des matrices de cooccurrence ont été calculés en 1973 par HARALICK, SHANMUGAM, et DINSTEIN [44]. Cependant, ces indices se révèlent être non normalisés. Cette singularité est particulièrement gênante car elle implique des différences de poids entre les indices.

De cette représentation particulière de l'image découlent :

- ♦ Le moment angulaire du second ordre (*angular second moment*) : mesure l'homogénéité de l'image. Dans une image homogène, très peu de transitions sont dominantes. La matrice p d'une telle image aura peu d'entrées mais des termes $p(i, j)$ plus importants.

$$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)^2 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(\frac{P(i, j)}{R} \right)^2 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j)^2}{R^2} \quad (2.7)$$

Mathématiquement, les deux limites du numérateur sont 0 (aucune transition, l'image est un unique pixel, la matrice de cooccurrence est nulle) et R^2 (toujours la même transition, l'image est unie, la matrice de cooccurrence possède une unique valeur sur la diagonale valant R).

$$0 \leq \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j)^2 \leq R^2$$

⇓

$$0 \leq f_1 \leq 1$$

- ♦ Le contraste (*contrast*) : mesure le contraste ou le nombre de variations locales présentes dans l'image.

$$f_2 = \sum_{k=0}^{N_g-1} k^2 \left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right) = \sum_{k=0}^{N_g-1} k^2 \left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{P(i, j)}{R} \right) = \frac{\sum_{k=0}^{N_g-1} k^2 \left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j) \right)}{R} \quad (2.8)$$

avec $|i - j| = k$.

Les deux limites du numérateur sont pour $k=0$ (matrice de cooccurrence à valeurs uniquement sur la diagonale, image unie) et $k=N_g-1$ (matrice de cooccurrence à valeurs sur les diagonales extrêmes, image alternant les deux NDG extrêmes).

$$0^2 \cdot R \leq \sum_{k=0}^{N_g-1} k^2 \left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j) \right) \leq (N_g - 1)^2 \cdot R$$

⇓

$$0 \leq f_2 \leq (N_g - 1)^2$$

On normalise le contraste en divisant par $(N_g-1)^2$.

- ♦ La corrélation (*correlation*) : mesure les dépendances linéaires de niveaux de gris dans l'image

$$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i \cdot j \cdot p(i, j) - \mu_x \cdot \mu_y}{\sigma_x \cdot \sigma_y} \quad (2.9)$$

avec μ_x et μ_y les moyennes (*means*) de p_x et p_y ,

avec σ_x et σ_y les écart-types (*standard deviations*) de p_x et p_y ,

avec $p_x(i) = \sum_{j=1}^{N_g} p(i, j)$ = somme des $p(i, j)$ sur une ligne,

avec $p_y(j) = \sum_{i=1}^{N_g} p(i, j)$ = somme des $p(i, j)$ sur une colonne.

Il s'avère cependant que cette formulation est d'un abord difficile, aussi lui préférons-nous la suivante, issue de [8] et normalisée :

$$f_3 = \frac{\left| \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu_x)(j - \mu_y) p(i, j) \right|}{\sigma_x \cdot \sigma_y} \quad (2.10)$$

$$\text{avec } \mu_x = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i \cdot p(i, j) = \sum_{i=1}^{N_g} i \sum_{j=1}^{N_g} p(i, j) = \sum_{i=1}^{N_g} i \cdot p_x(i),$$

$$\text{avec } \mu_y = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} j \cdot p(i, j) = \sum_{j=1}^{N_g} j \sum_{i=1}^{N_g} p(i, j) = \sum_{j=1}^{N_g} j \cdot p_y(j),$$

$$\text{avec } \sigma_x^2 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ((i - \mu_x)^2 p(i, j)) = \sum_{i=1}^{N_g} \left((i - \mu_x)^2 \sum_{j=1}^{N_g} p(i, j) \right) = \sum_{i=1}^{N_g} ((i - \mu_x)^2 p_x(i)),$$

avec $\sigma_y^2 =$

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ((j - \mu_y)^2 p(i, j)) = \sum_{j=1}^{N_g} \left((j - \mu_y)^2 \sum_{i=1}^{N_g} p(i, j) \right) = \sum_{j=1}^{N_g} ((j - \mu_y)^2 p_y(j)).$$

- ♦ La somme des carrés ou variance (sum of squares or variance) :

$$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i, j) \quad (2.11)$$

$$\text{avec } \mu = \sum_{i=1}^{N_g} i \sum_{j=1}^{N_g} p(i, j)$$

Cette formule n'est pas normalisée : l'expérimentation l'a montré. C'est aussi la seule formule pour laquelle nous n'avons pas encore pu trouver de facteur de normalisation qui nous convienne.

- ♦ Le moment des différences inverses (inverse difference moment) : mesure l'homogénéité locale des niveaux de gris dans l'image.

$$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(\frac{p(i, j)}{1 + (i - j)^2} \right) \quad (2.12)$$

$f_5 = 1$ si la matrice de cooccurrence est diagonale.

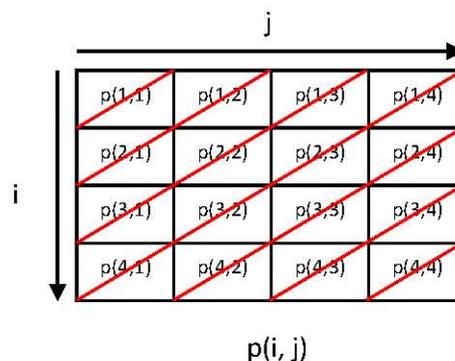
$f_5 = 0$ si la matrice de cooccurrence est nulle (l'image est un unique pixel).

- ♦ La moyenne de la somme (sum average) :

$$f_6 = \sum_{k=2}^{2N_g} (k \cdot p_{x+y}(k)) \quad (2.13)$$

$$\text{avec } p_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \text{ où } i + j = k \text{ (diagonales sur le schéma ci-dessous).}$$

dessous).



Si l'image est une image uniforme de NDG N_g : $f_6 = 2N_g$

On normalise en divisant par $2N_g$.

♦ L'entropie de la somme (sum entropy) : (à ne pas confondre avec la statistique du 1^{er} ordre dépendant de l'histogramme).

$$f_8 = - \sum_{k=2}^{2N_g} (p_{x+y}(k) \cdot \log(p_{x+y}(k))) \quad (2.14)$$

Pour éviter le cas singulier de $\log(0)$, deux solutions existent : 1°) ajouter une petite valeur ε à $p_{x+y}(k)$, ou 2°) ne pas tenir compte des $p_{x+y}(k) = 0$ grâce à un test. La seconde solution a été privilégiée.

Il est possible de normaliser f_8 en divisant par $\log(R)$ (solution retenue pour chaque entropie).

♦ La variance de la somme (sum variance) :

$$f_7 = \sum_{k=2}^{2N_g} ((k - f_8)^2 \cdot p_{x+y}(k)) \quad (2.15)$$

En supposant f_8 normalisée :

$$2 \leq k \leq 2N_g$$

$$1 \leq k - f_8 \leq 2N_g$$

$$1 \leq (k - f_8)^2 \leq 4N_g^2$$

$$1 \leq (k - f_8)^2 \cdot p_{x+y}(k) \leq 4N_g^2$$

Il est possible de normaliser f_7 en divisant par $4N_g^2$.

♦ L'entropie (entropy) :

$$f_9 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j) \cdot \log(p(i, j))) \quad (2.16)$$

Nous donne la version normalisée suivante [8] :

$$f_9 = 1 - \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(P(i, j)))}{R \cdot \log(R)} \quad (2.17)$$

Qui n'est qu'une normalisation de la première formule par $\log(R)$.

En effet :

$$\frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j) \cdot \log(p(i, j)))}{\log(R)} = \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(\frac{P(i, j)}{R} \cdot \log\left(\frac{P(i, j)}{R}\right) \right)}{\log(R)} = \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(P(i, j) \cdot \log\left(\frac{P(i, j)}{R}\right) \right)}{R \cdot \log(R)}$$

$$\begin{aligned}
& - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot (\log(P(i, j)) - \log(R))) \\
&= \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(P(i, j)) - P(i, j) \cdot \log(R))}{R \cdot \log(R)} \\
&= \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(P(i, j)))}{R \cdot \log(R)} + \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(R))}{R \cdot \log(R)} \\
&= \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(P(i, j)))}{R \cdot \log(R)} + \frac{\log(R) \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i, j)}{R \cdot \log(R)} \\
&= \frac{- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i, j) \cdot \log(P(i, j)))}{R \cdot \log(R)} + \frac{\log(R) \cdot R}{R \cdot \log(R)}
\end{aligned}$$

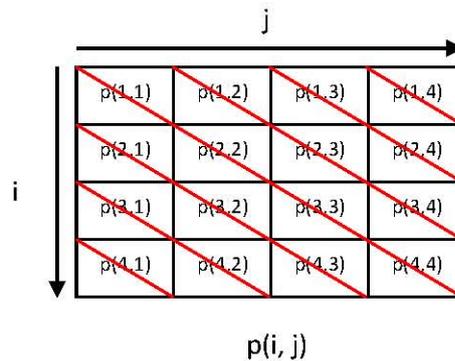
Rq : c'est de là qu'est venue l'idée de normaliser f_8 par $\log(R)$.

♦ La variance de la différence (difference variance) :

f_{10} = variance de p_{x-y}

avec $p_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)$ où $|i-j|=k$ et k variant de 0 à N_g-1

(diagonales sur le schéma ci-dessous).



En reprenant une formulation similaire à celles de f_3 et f_4 , on obtient :

$$f_{10} = \sum_{k=0}^{N_g-1} ((k - \mu_k)^2 p_{x-y}(k)) \quad (2.18)$$

Avec $\mu_k = \sum_{k=0}^{N_g-1} k \cdot p_{x-y}(k)$.

On normalise en divisant par $(N_g-1)^2$ (non rigoureux).

- ♦ L'entropie de la différence (*difference entropy*) :

$$f_{11} = - \sum_{k=0}^{N_g-1} (p_{x-y}(k) \cdot \log(p_{x-y}(k))) \quad (2.19)$$

On normalise en divisant par $\log(R)$.

- ♦ Les mesures informatives de corrélation (*information measures of correlation*) :

$$f_{12} = \frac{HXY - HXY1}{\max(HX, HY)} \quad (2.20)$$

$$f_{13} = \sqrt{(1 - e^{-2(HXY2 - HXY)})} \quad (2.21)$$

$$\text{avec } HXY = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j) \cdot \log(p(i, j))),$$

$$\text{avec } HXY1 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j) \cdot \log(p_x(i) \cdot p_y(j))),$$

$$\text{avec } HXY2 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p_x(i) \cdot p_y(j) \cdot \log(p_x(i) \cdot p_y(j))),$$

$$\text{avec } HX = \text{entropie de } p_x = - \sum_{i=1}^{N_g} (p_x(i) \cdot \log(p_x(i))),$$

$$\text{avec } HY = \text{entropie de } p_y = - \sum_{j=1}^{N_g} (p_y(j) \cdot \log(p_y(j))).$$

- ♦ Le coefficient de corrélation maximal (*maximal correlation coefficient*) :

$$f_{14} = (2^{\text{ème}} \text{ plus élevée valeur propre de } Q)^{1/2}$$

$$\text{où } Q(i, j) = Q(i, j) = \sum_{k=1}^{N_g} \frac{p(i, k) \cdot p(j, k)}{p_x(i) \cdot p_y(k)} \quad (2.22)$$

2.4.1.3. Matrice de longueurs de plage (LDP)

Soit une image I de taille $(N_x \times N_y)$, où chaque pixel a un niveau de gris compris entre 1 et N_g (ou 0 et N_g-1). Dans notre étude, $N_x = N_y = N = 256$ et $N_g = 256$ [34].

La matrice de LDP de I contient les estimations de probabilité d'un segment de longueur j et de NDG i pour une orientation θ donnée. Le principe sous-jacent réside en la représentation des images par des segments de droite de même luminance puis à en extraire les paramètres traduisant la répartition statistique de ces différents segments sur l'image étudiée. La taille des matrices de LDP est $N_g \times N_r$ où N_g est le niveau de gris maximum supposé ($N_g = 256$) et N_r la taille maximale des segments ($N_r = N$). Pour chaque indice, on retient la moyenne des valeurs calculées pour les orientations 0° , 45° , 90° et 135° .

Afin d'obtenir une matrice de longueurs de plage, il convient de recenser les segments homogènes de différentes tailles tel que montré dans la figure 2.10.

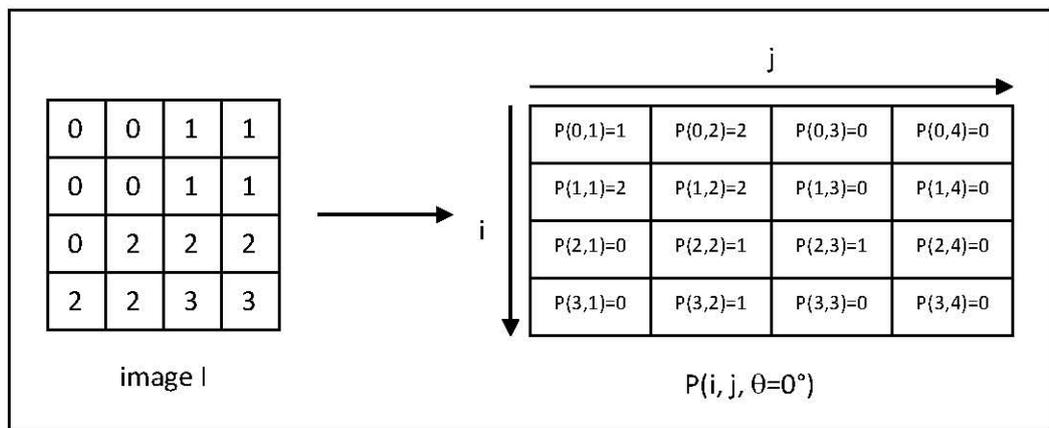


Figure 2.10 : Recensement des segments

Chaque pixel n'est totalisé qu'une seule fois par matrice P , donc la somme des segments par leur taille est égale au nombre de pixels, à la taille de l'image.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} (j \cdot P(i, j)) = N^2 = N_x N_y = N_r^2 = K$$

Soit SLP la somme des longueurs de plage (le nombre des ldp).

$$SLP = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P(i, j) \quad (2.23)$$

On divise chaque élément de la matrice P par SLP pour obtenir la matrice de probabilités (figure 2.11).

		j				
		→				
	i		$p(0,1)=1/10$	$p(0,2)=1/5$	$p(0,3)=0$	$p(0,4)=0$
			$p(1,1)=1/5$	$p(1,2)=1/5$	$p(1,3)=0$	$p(1,4)=0$
			$p(2,1)=0$	$p(2,2)=1/10$	$p(2,3)=1/10$	$p(2,4)=0$
			$p(3,1)=0$	$p(3,2)=1/10$	$p(3,3)=0$	$p(3,4)=0$
			$p(i, j, \theta=0^\circ)$			

Figure 2.11 : Matrice des longueurs de plage

Les cinq indices découlant des matrices de longueur de plages en 1975 par GALLOWAY [45] :

♦ L'accentuation des petites plages : est importante si l'image présente un grand nombre de petits segments.

$$R_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{p(i,j)}{j^2} = \frac{1}{SLP} \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i,j)}{j^2} \quad (2.24)$$

$$\frac{1}{N_r} \left(1 \left(N_r \cdot \frac{1}{N_r^2} \right) \right) \leq R_1 \leq \frac{1}{N_r^2} \left(N_r \left(N_r \cdot \frac{1}{1^2} \right) \right)$$

$$1 \left(\left(N_r \cdot \frac{1}{N_r} \right) \frac{1}{N_r^2} \right) \leq R_1 \leq N_r \left(\left(N_r \cdot \frac{1}{N_r^2} \right) \frac{1}{1^2} \right)$$

$$\frac{1}{N_r^2} \leq R_1 \leq 1$$

♦ L'accentuation des grandes plages : est importante si l'image présente un grand nombre de segments de grande taille.

$$R_2 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} (p(i,j) \cdot j^2) = \frac{1}{SLP} \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} (P(i,j) \cdot j^2) \quad (2.25)$$

$$\frac{1}{N_r^2} (N_r (N_r \cdot 1^2)) \leq R_2 \leq \frac{1}{N_r} (1 (N_r \cdot N_r^2))$$

$$N_r \left(\left(N_r \cdot \frac{1}{N_r^2} \right) 1^2 \right) \leq R_2 \leq 1 \left(\left(N_r \cdot \frac{1}{N_r} \right) N_r^2 \right)$$

$$1 \leq R_2 \leq N_r^2$$

On normalise en divisant par : $\frac{1}{N_r^2}$.

- ♦ L'hétérogénéité des niveaux de gris :

$$R_3 = SLP \sum_{j=1}^{N_r} \left(\sum_{i=1}^{N_g} p(i, j) \right)^2 = \frac{1}{SLP} \sum_{j=1}^{N_r} \left(\sum_{i=1}^{N_g} P(i, j) \right)^2 \quad (2.26)$$

$\sum_{j=1}^{N_r} P(i, j)$ est la sommation des termes d'une même ligne (somme des segments de même NDG) ; pour obtenir le résultat le plus élevé (mais aussi le moins élevé), différents cas de figure singuliers ont été analysés.

On normalise en divisant par : $\frac{N_r^2}{2}$.

- ♦ L'hétérogénéité des longueurs de plage : prend une valeur minimale si les segments sont également distribués entre leurs longueurs. Cet indice s'intéresse à la répartition des différents niveaux de gris par rapport aux différentes longueurs de segments.

$$R_4 = \frac{1}{SLP} \sum_{j=1}^{N_g} \left(\sum_{i=1}^{N_r} P(i, j) \right)^2 \quad (2.27)$$

$\sum_{i=1}^{N_g} P(i, j)$ est la sommation des termes d'une même colonne (somme des segments de même taille) ; pour obtenir le résultat le plus élevé (mais aussi le moins élevé), différents cas de figure singuliers ont été analysés.

On normalise en divisant par : $\frac{1}{N_r^2}$.

- ♦ Le pourcentage des plages : est le rapport entre le nombre total de segments et le nombre de pixels de l'image.

$$R_5 = \frac{SLP}{K} = SLP \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{p(i, j)}{K} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i, j)}{K} \quad (2.28)$$

$$N_r \leq SLP \leq N_r^2$$

$$\frac{1}{N_r} \leq R_5 \leq 1$$

2.4.2. Méthodes fondées sur un modèle

Les méthodes fondées sur un modèle décrivent la texture par un modèle probabiliste. Celle-ci est alors caractérisée par les paramètres de ce modèle. Parmi ces modèles, les principaux sont le modèle autorégressif (AR), les modèles

Markoviens et les champs de Gibbs ils sont souvent rencontrés dans la segmentation ou la classification d'images texturées [46-48]. Une méthode de segmentation non supervisée par Modèle de Markov Caché et les champs de Gibbs est donnée dans [49]. Enfin, [50] utilise aussi ce dernier modèle. Les publications traitant des champs de Gibbs sont nombreuses on les retrouvera dans [47] et [51].

Des alternatives à ce modèle existent. On notera par exemple [52] qui utilise les K plus proches voisins et [53] qui se sert d'histogrammes.

Il existe des modèles proches du modèle autorégressif (AR). Ce sont les modèles moving average (MA) et autorégressive moving average (ARMA). Dans [54] les auteurs proposent de caractériser les textures par un modèle SAR (Simultaneous Autoregressive) puis segmentent l'image en utilisant le maximum de vraisemblance. Dans [51] les textures sont de même caractérisées par le modèle SAR mais la segmentation est effectuée à partir de champs de Markov.

2.4.3. Autres méthodes

Il existe encore une multitude de méthodes d'étude de la texture. A titre informatif, voici les plus usuelles.

2.4.3.1. Méthodes structurelles

Les méthodes structurelles considèrent la texture comme un ensemble de Textons. La disposition de ces Textons suit des règles de déplacement. Ces méthodes sont particulièrement adaptées à l'étude des macro-textures.

Nous ne les approfondirons pas ici. En effet, le but de cet état de l'art est de répertorier les méthodes d'étude des micro-textures. Une présentation rapide en est donnée dans [55] qui approfondissent un peu plus le sujet tout en donnant de nombreuses références.

2.4.3.2. Modèles fractals

Les modèles utilisant la géométrie fractale appartiennent aussi aux méthodes fondées sur un modèle (voir [53]). La dimension fractale et la lacunarité d'une image sont, entre autres, utilisées pour en caractériser ses textures. Le problème ici est que les calculs s'exécutent sur des fenêtres de taille importante et demandent de grands temps de calculs.

2.4.3.3. Méthodes basées sur les décompositions atomiques

Les méthodes des décompositions atomiques viennent du monde du traitement du signal. Elles ont généralement été créées pour l'étude spectrale des

signaux monodimensionnels non stationnaires. Cependant, elles sont toujours applicables dans des dimensions supérieures. Elles sont donc adaptées à l'analyse de textures [56].

Décomposer un signal en atomes revient à le considérer comme une superposition de signaux élémentaires. Cette décomposition est fonction du temps (ou bien de l'espace à deux dimension) et des fréquences. La décomposition peut être réalisée par un maillage rectangulaire. Ce maillage correspond à l'analyse temps-fréquence, exemple les transformations de Fourier à court terme. Un maillage dyadique qui peut être utilisé correspond à l'analyse temps-échelles. Les ondelettes et les filtres de Gabor l'utilisent aussi.

La décomposition en ondelettes ou une banque de filtres de Gabor est donc utilisée pour mettre en évidence certaines propriétés du signal et décrivant les variations locales des niveaux de gris de la texture autour de leur valeur moyenne. L'utilisation d'une structure pyramidale de décomposition conduit à la caractérisation texturale de tout le voisinage.

2.5. Conclusion

Dans ce chapitre, nous avons présenté les méthodes d'analyse des textures les plus courantes. Nous avons vu que parmi ces méthodes les quatorze paramètres d'Haralick issues des matrices de cooccurrence ou bien les cinq paramètres de longueurs de plage peuvent donner une bonne description de la texture. Elles sont cependant assez lourdes en termes de calculs. Les méthodes d'ordre 1 sont beaucoup plus rapides, mais elles ne décrivent pas les relations spatiales entre les pixels.

Les modèles tels que le modèle autorégressif ou les champs de Markov donnent de bons résultats en analyse de texture. Par contre ces méthodes nécessitent des méthodes d'optimisation numérique avec un nombre très élevé de variables.

Comme alternative aux méthodes citées précédemment, les méthodes de décompositions pyramidales (analyse temps-fréquence ou temps-échelle), permettent la caractérisation texturale d'une image. Dans le chapitre trois nous décrivons le développement de ces méthodes de décomposition permettant la segmentation des images TOFD.

CHAPITRE 3

ANALYSE ET SEGMENTATION DES IMAGES TOFD

3.1. Introduction

Comme nous l'avons vu dans le chapitre précédent, en caractérisation de texture, à l'instar des attributs statistiques, nous avons besoin d'une représentation dans le domaine spatial et fréquentiel. La transformation la plus populaire est la transformée de Fourier. Elle permet de passer d'une représentation dans le domaine spatial à une représentation dans le domaine fréquentiel. Néanmoins, la transformée de Fourier présente l'inconvénient de fournir une information fréquentielle globale de l'image sans prendre en considération la localisation spatiale de la distribution des fréquences. La transformée de Fourier à court terme a été conçue pour remédier à ce problème. Toutefois, cette transformation ne peut représenter l'image qu'à une seule échelle ce qui n'est pas forcément adéquat pour discriminer les détails fins des détails grossiers contenus dans l'image [57]. L'une des alternatives pour pallier à ces limitations est la transformée en ondelettes ou d'une manière générale les décompositions en multirésolution. En effet, leur principe est d'analyser l'image par des atomes modulés en échelle, centrés en différentes positions afin de fournir une représentation échelle-espace.

Dans ce chapitre, nous présentons une approche de segmentation d'images TOFD basée sur la caractérisation texturale d'un défaut. Nous décrivons les paramètres de texture en utilisant la transformée en ondelettes. La transformée en ondelettes est un outil puissant pour la caractérisation de texture. La décomposition en ondelettes est une représentation spatio-fréquentielle d'une image, on parle d'analyse multirésolution. En quelque sorte, elle représente les composantes de fréquences d'une image à l'endroit où elles se trouvent. Pour le choix du canal de décomposition nous utilisons un critère de sélection basé sur l'analyse statistique des textures des sous images. Les paramètres d'ondelettes sont optimisés par l'Analyse en Composantes Principales (ACP) et utilisés comme vecteur d'attributs pour chaque pixel de l'image TOFD. Finalement, la

segmentation de l'image est donnée par la classification de chaque pixel de l'image par l'algorithme 'Fuzzy C-Means Iterative' FCMI comme « défaut » ou « non-défaut ». L'approche proposée sera testée sur des images réalisées au niveau du laboratoire et à l'échelle industrielle.

3.2. Analyse en multirésolution basée sur la transformée en ondelettes

La texture est une notion naturellement multi-échelles et qui est liée à un observateur humain. Sous sa forme classique, la transformation en ondelettes fait partie des représentations multi-échelles. Elle permet une observation hiérarchique de la texture du global vers le local, qui présente une similitude avec le système visuel humain et qui permet de caractériser les interactions spatiales intra-échelle de la texture.

L'utilisation de la décomposition en ondelettes pour le traitement d'images débute par les travaux de Mallat [58], commencés en 1985. Il a pu relier les filtres miroirs en quadrature, les algorithmes pyramidaux et les séries basés sur des ondelettes. Il faut attendre 1988 avant d'amener la théorie des ondelettes vers des applications pratiques. En effet, Daubechies [59] a su développer des ondelettes orthogonales à support compact en se basant sur les travaux d'Haar, de Mallat et de Meyer. C'est Haar, en 1909, qui a découvert la première ondelette. Elle n'était pas continue et avait une application restreinte. De son côté, Meyer a ouvert la voie à cette décomposition en effectuant une synthèse des nombreux précurseurs de la décomposition en ondelettes [60]. Regardons les fondements des ondelettes et pourquoi elles sont si populaires [61].

Avant de passer à l'analyse multirésolution, nous décrivons dans la section suivante la transformée en ondelettes continue et discrète.

3.2.1. La transformée en ondelettes

De la même façon que la transformée de Fourier peut se définir comme étant une projection sur la base des exponentielles complexes, on introduit la transformée en ondelettes comme la projection sur la base des fonctions ondelettes.

$$W_f(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad \text{avec } a, b \in \mathbb{R}, a \neq 0 \quad (3.1)$$

Les fonctions $\psi_{a,b}(t)$ sont obtenues à partir de dilatation et de la translation de la fonction mère $\psi(t)$. Les fonctions $\psi_{a,b}(t)$ sont par conséquent parfois appelées les ondelettes filles.

Tout comme la transformée de Fourier, la transformée en ondelettes est inversible :

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{a^2} W_f(a, b) \psi_{a,b} da db \quad (3.2)$$

Où : C_ψ est un coefficient dont l'expression est $C_\psi = 2\pi \int_{-\infty}^{+\infty} |\hat{\psi}(\omega)|^2 \frac{d\omega}{\omega}$

(avec $\hat{\psi}(\omega)$ transformée de Fourier de $\psi(t)$).

La transformée en ondelettes discrète (DWT, Discrete Wavelet Transform) est une implémentation utilisant un ensemble discret d'échelles et de translations d'ondelettes obéissant à certaines règles. En d'autres termes, cette transformée décompose le signal en un ensemble d'ondelettes mutuellement orthogonales, ce qui constitue la différence principale avec la transformée en ondelettes continue, où son implémentation en séries discrètes dans le temps est parfois appelée transformée en ondelettes continue discrète dans le temps (DT-CWT, discrete-time continuous wavelet transform).

L'ondelette peut être construite à partir d'une fonction d'échelle décrivant les propriétés d'échelle du signal. La restriction d'orthogonalité avec les translations discrètes implique certaines conditions mathématiques, par exemple l'équation de dilatation :

$$\phi(t) = \sum_{k=-\infty}^{+\infty} a_k \phi(S t - k) \quad (3.3)$$

Où S est un facteur d'échelle (prenant généralement une valeur de 2). De plus, la zone entre les fonctions doit être normalisée et la fonction d'échelle doit être orthogonale par translation, c'est-à-dire qu'on a :

$$\int_{-\infty}^{+\infty} \phi(t) \phi(t+l) dx = \delta_{0,l} \quad (3.4)$$

Après introduction de conditions supplémentaires (les restrictions précédentes ne produisent pas une solution unique) nous pouvons obtenir le résultat de toutes ces équations, c'est-à-dire un ensemble fini de coefficients a_k définissant la fonction d'échelle ainsi que l'ondelette. L'ondelette est obtenue à partir de la fonction d'échelle grâce à N où N est un entier pair.

L'ensemble des ondelettes forme alors une base orthogonale que nous utilisons pour décomposer le signal. Notez qu'en général seuls quelques coefficients a_k sont non nuls, ce qui simplifie les calculs.

Quelques fonctions d'échelle et d'ondelettes sont présentées dans les figures qui suivent (3.1, 3.2 et 3.3). La famille Daubechies est la famille la plus connue des ondelettes ortho-normales. Ses ondelettes sont généralement dénommées par le nombre de coefficients a_k non nuls, on parlera donc d'ondelettes Daubechies 4, Daubechies 6,...etc. Pour faire simple, les fonctions deviennent plus douces avec un nombre croissant de coefficients d'ondelettes. Comparez par exemple les ondelettes Daubechies 2 et 20 ci-dessous. La fonction la plus simple, l'ondelette de Haar, utilise une fonction porte comme fonction d'échelle.

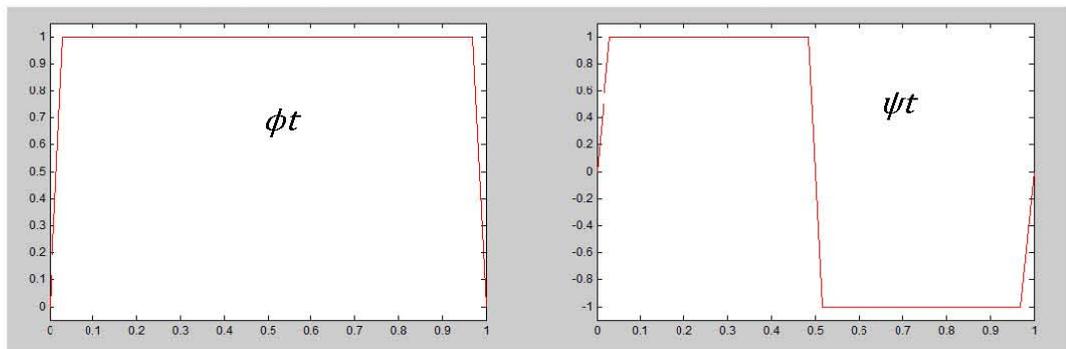


Figure 3.1 : Fonction d'échelle et l'ondelette de Haar

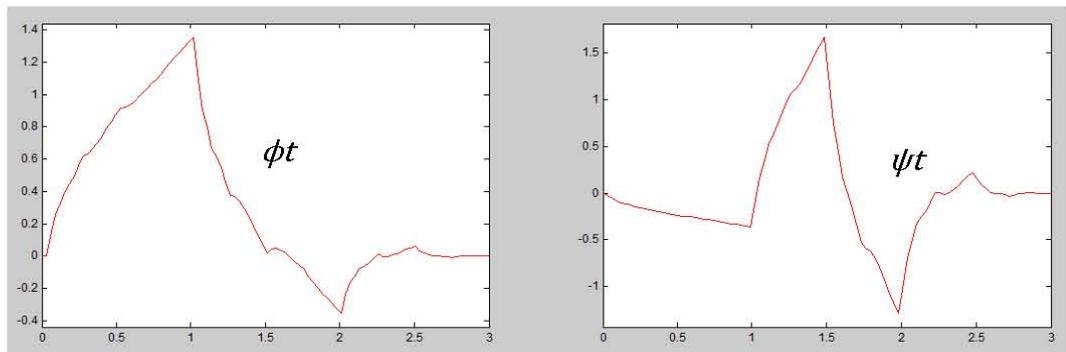


Figure 3.2 : Fonction d'échelle et l'ondelette de Daubechies 2

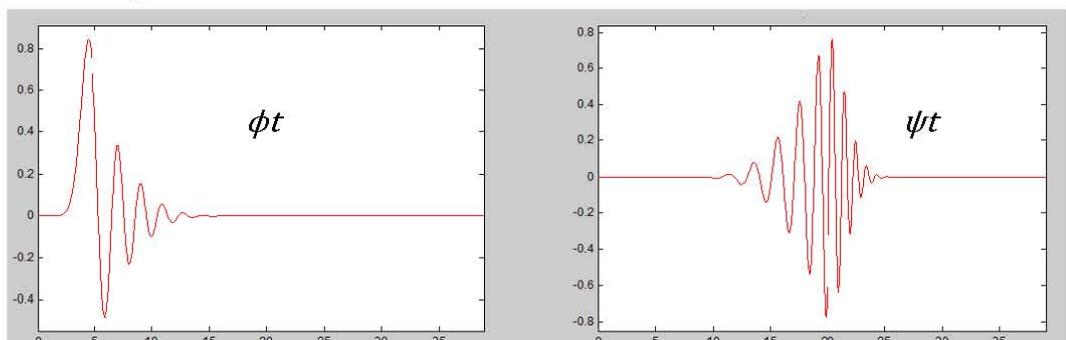


Figure 3.3 : Fonction d'échelle et l'ondelette de Daubechies 20

Il existe plusieurs types d'implémentation de l'algorithme DWT. Le plus connue et aussi le plus ancien est l'algorithme (pyramidal) de Mallat. Dans celui-ci deux filtres – un lissant et un non-lissant – sont construits à partir des coefficients d'ondelette, puis utilisés de manière récurrente pour obtenir les données pour toutes les échelles.

Dans lesquelles h est un filtre passe bas et g un filtre passe haut. Ces deux filtres forment des filtres miroirs en quadrature (FMQ) et ils sont définies par :

$$h(t) = \sqrt{2} \int_{-\infty}^{+\infty} \phi(2s - t)\phi(s)ds, \forall t \in \mathbb{R} \quad (3.5)$$

$$g(t) = \sqrt{2} \int_{-\infty}^{+\infty} \phi(2s - t)\psi(s)ds, \forall t \in \mathbb{R} \quad (3.6)$$

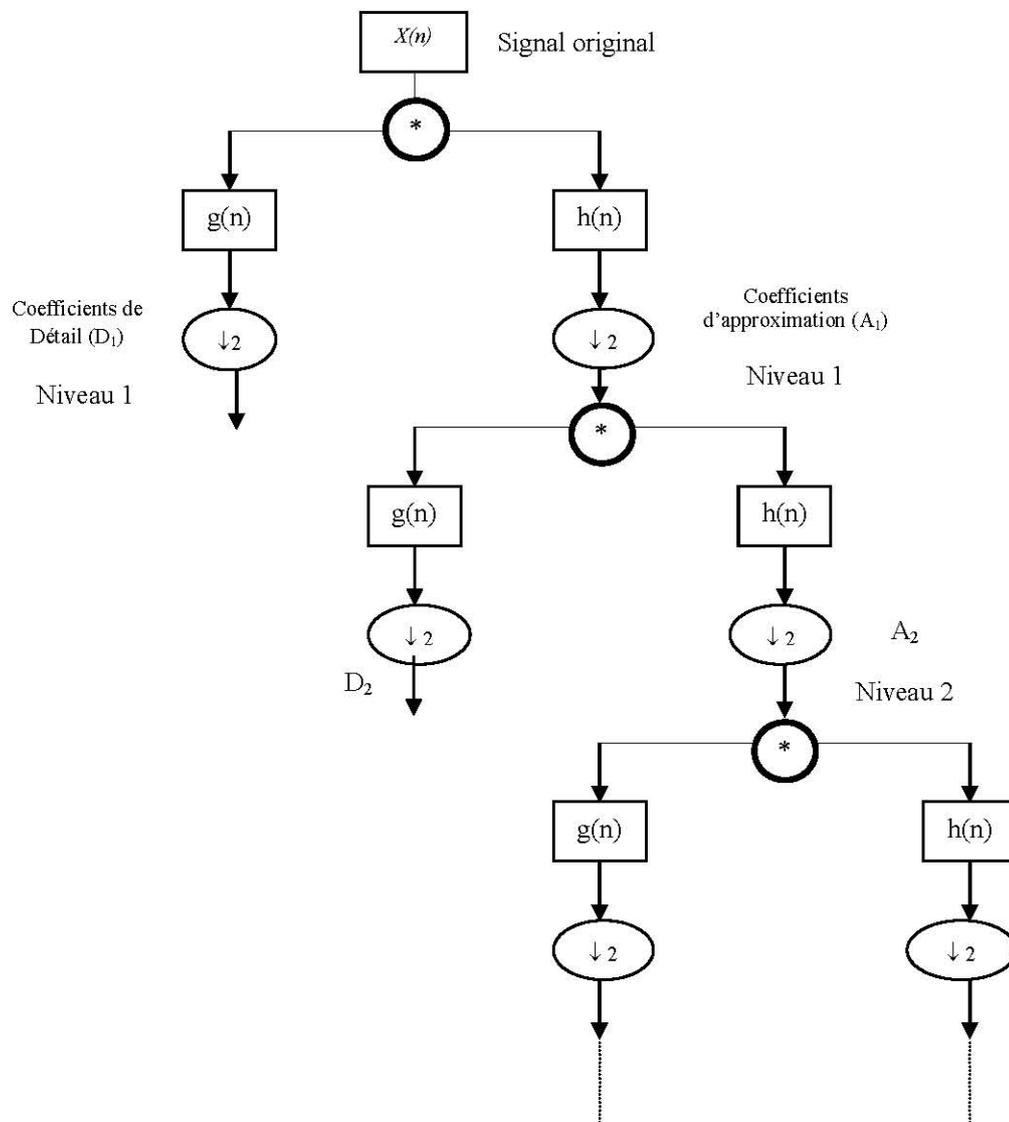


Figure 3.4 : Algorithme de décomposition d'un signal unidimensionnel en paquets d'ondelettes

Si le nombre total de données $D = 2^N$ est utilisé et que la longueur du signal est L , les premières $D/2$ données d'échelle $L/2^{N-1}$ sont calculées, puis les $(D/2)/2$ données d'échelle $L/2^{N-2}, \dots$ pour obtenir finalement 2 données d'échelle $L/2$. Le résultat de cet algorithme est un ensemble de même longueur que celle des données d'entrée, dans lequel les données sont généralement classées de la plus grande à la plus petite échelle. La figure 3.4 montre la décomposition d'un signal $X(n)$.

La reconstruction du signal original se fait à partir des signaux de détails et le dernier signal d'approximation à travers plusieurs itérations, le processus est illustré par la figure suivante :

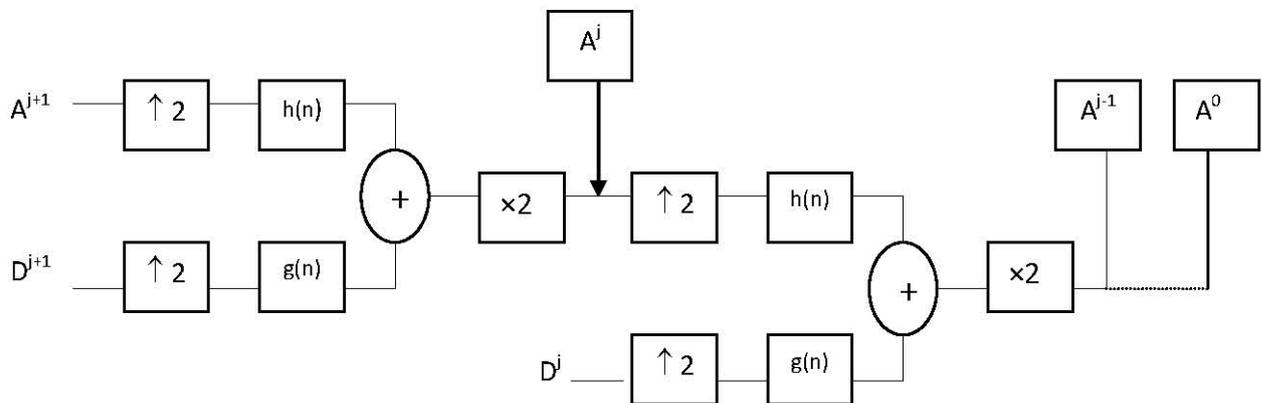


Figure 3.5 : Processus de reconstruction du signal

Avec : ($\uparrow 2$) : Interpolation par des Zéros, qui consiste à insérer des Zéros entre deux points successifs. ($\times 2$) : Multiplication par deux, afin de restituer parfaitement le signal de départ (original).

D'où la formule de reconstruction est :

$$A^j(n) = 2 \times [\sum_k h(n - 2k)A^{j+1}(k) + \sum_k g(n - 2k)D^{j+1}(k)] \quad (3.7)$$

3.2.2. Analyse multirésolution pour la décomposition des images

La généralisation à des signaux de deux dimensions, comme une image, est extrêmement simple. On traite les lignes et les colonnes d'une image séparément. Pour passer d'un niveau à un autre [62], de la même manière la résolution diminue successivement par puissance de deux.

Les coefficients d'approximations d'une image $f(x,y)$ à énergie finie à la résolution 2^j (c'est le niveau de décomposition) sont calculés par le produit de convolution suivant :

$$A_{2^j}f = \downarrow_{2^j}^n [\phi_{2^j}(-y) * (\downarrow_{2^j}^m [\phi_{2^j}(-x) * f(x,y)])] \quad (3.8)$$

Où $[m,n]$ la taille initiale de l'image $f(x,y)$, notons que les opérateurs $\downarrow_{2^j}^m$ et $\downarrow_{2^j}^n$ font le sous-échantillonnage le long de x de m échantillons à $\frac{m}{2^j}$ et le long de y de n échantillons à $\frac{n}{2^j}$. $\phi(x)$ est la fonction d'échelle unidimensionnelle et $\phi_{2^j}(x) = 2^j \phi(2^j x)$, en générale $\phi(x)$ est une fonction lisse dont la transformée de Fourier est concentrée dans les basses fréquences. La différence de l'information d'approximation de deux résolutions successives 2^j et 2^{j-1} , qui sont caractérisées respectivement par $A_{2^j}f$ et $A_{2^{j-1}}f$, peut être capturée par les coefficients de détail calculées par les convolutions suivantes :

$$D_{2^j}^1 f = \downarrow_{2^{j-1}}^n [\psi_{2^{j-1}}(-y) * (\downarrow_{2^{j-1}}^m [\phi_{2^{j-1}}(-x) * f(x,y)])] \quad (3.9)$$

$$D_{2^j}^2 f = \downarrow_{2^{j-1}}^n [\phi_{2^{j-1}}(-y) * (\downarrow_{2^{j-1}}^m [\psi_{2^{j-1}}(-x) * f(x,y)])] \quad (3.10)$$

$$D_{2^j}^3 f = \downarrow_{2^{j-1}}^n [\psi_{2^{j-1}}(-y) * (\downarrow_{2^{j-1}}^m [\psi_{2^{j-1}}(-x) * f(x,y)])] \quad (3.11)$$

Où $\psi(x)$ est la fonction d'ondelette unidimensionnelle avec $\psi_{2^j}(x) = 2^j \psi(2^j x)$. La fonction d'ondelette $\psi(x)$ est un filtre passe bande. $A_{2^j}f$ Peut être parfaitement reconstruite à partir de : $A_{2^{j-1}}f$, $D_{2^{j-1}}^1 f$, $D_{2^{j-1}}^2 f$ and $D_{2^{j-1}}^3 f$.

Les coefficients de détail et approximation peuvent être calculés par un algorithme pyramidal basé sur la convolution unidimensionnelle avec deux filtres. La figure 3.6 montre la décomposition de $A_{2^j}f$ en $A_{2^{j-1}}f$, $D_{2^{j-1}}^1 f$, $D_{2^{j-1}}^2 f$ et $D_{2^{j-1}}^3 f$. \tilde{H} et \tilde{G} dans la figure 3.6 sont respectivement un filtre passe-bas (1-D) et un filtre passe-haut (1-D). Comme le montre la figure 3.6, cet algorithme calcule d'abord la convolution des lignes de l'image $A_{2^j}f$ avec un filtre unidimensionnel et retient tous les autres colonnes, ensuite la convolution des colonnes des signaux résultants avec un autre filtre unidimensionnel et retient toutes les autres lignes. La décomposition pyramidale peut être appliquée continuellement aux sous images d'approximations et de détails jusqu'à atteindre la résolution désirée.

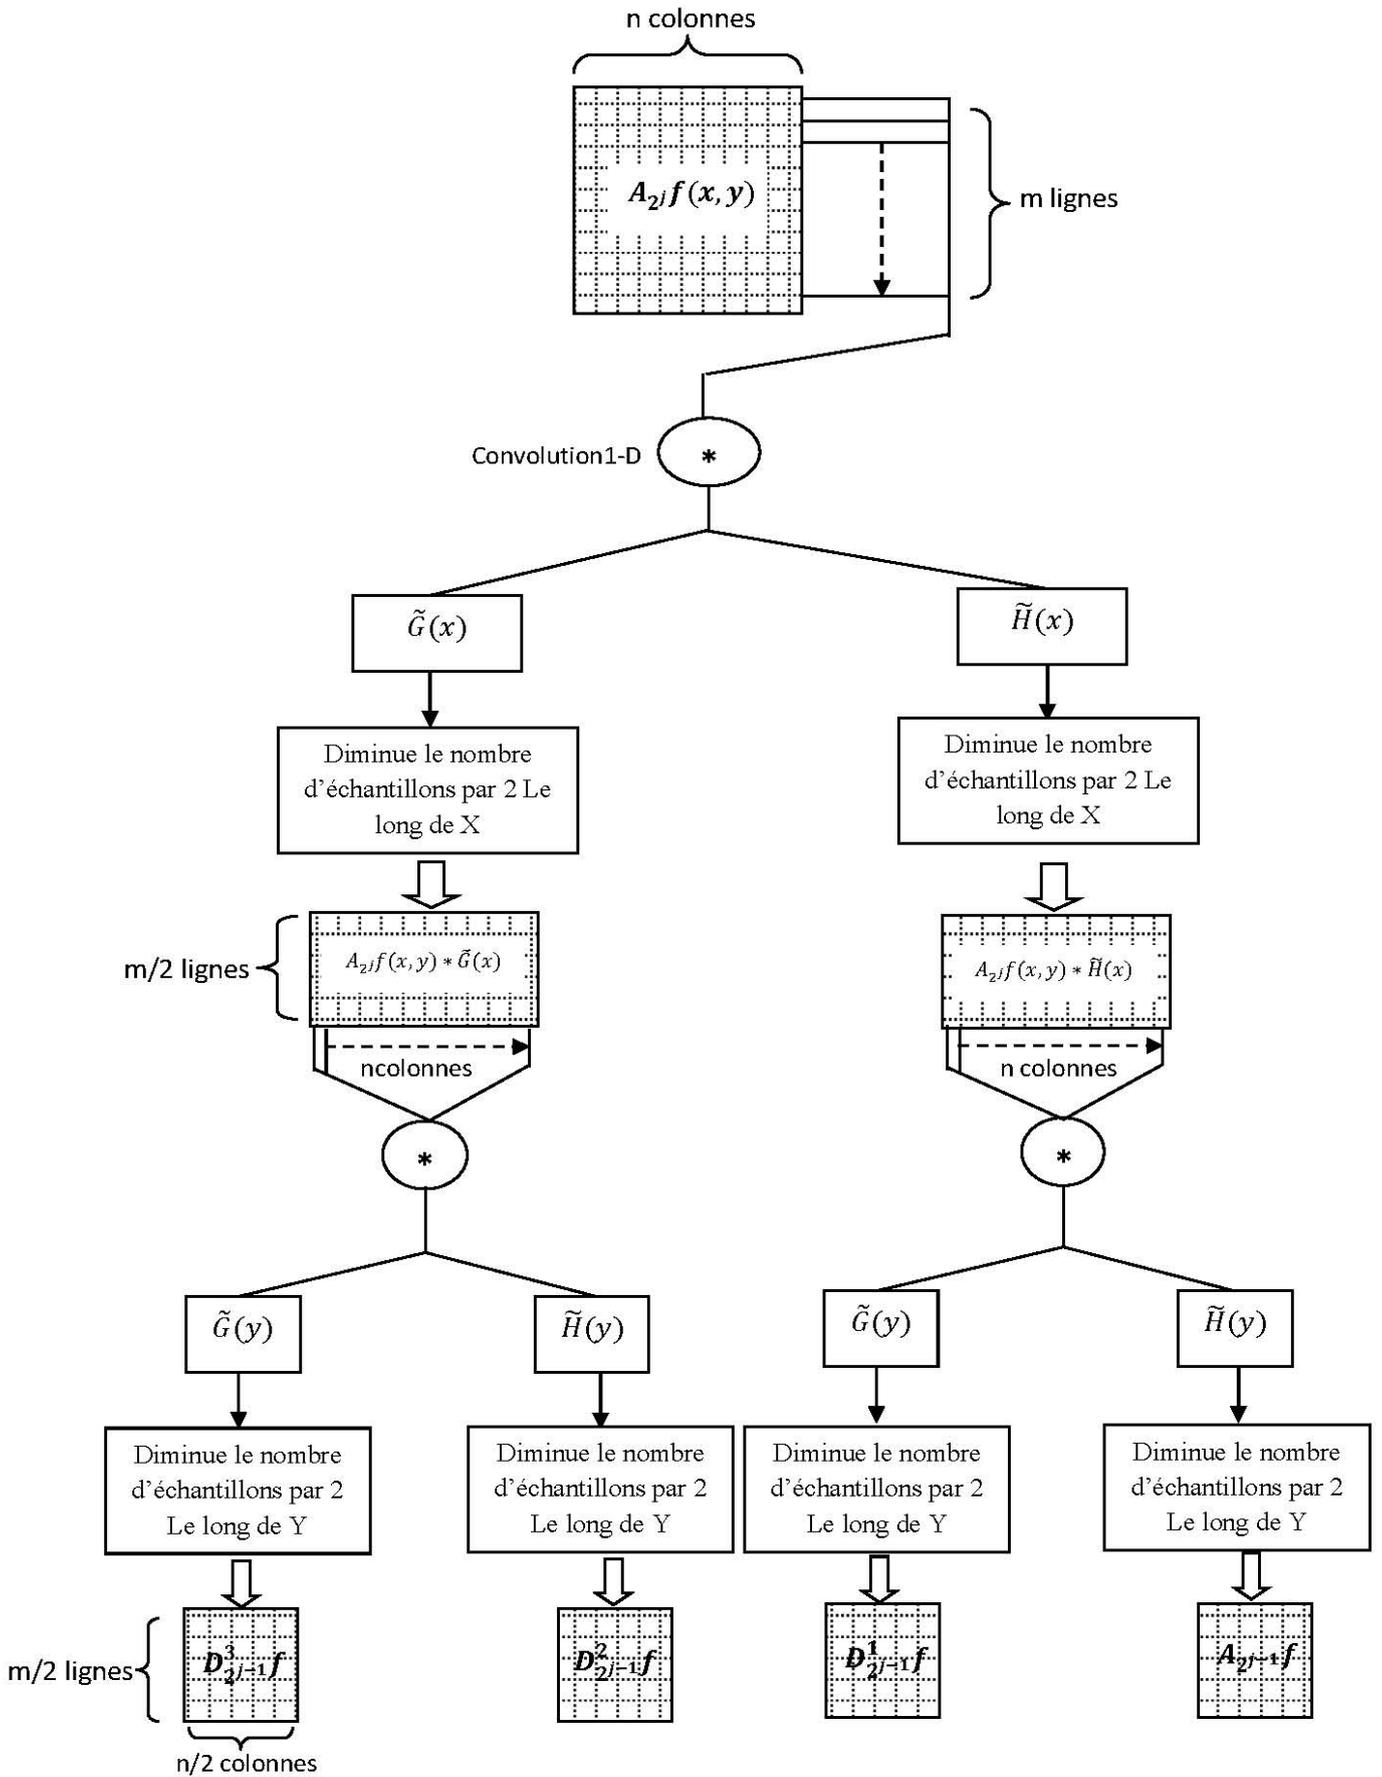


Figure 3.6: Décomposition en ondelettes d'une image par produit de convolution 1-D le long des lignes et des colonnes

La décomposition récursive d'une image entraîne la construction d'une structure arborescente, de type « quadtree », dans laquelle un nœud père représente l'image à décomposer et les nœuds fils le résultat de la décomposition d'où la notion de paquet d'ondelettes.

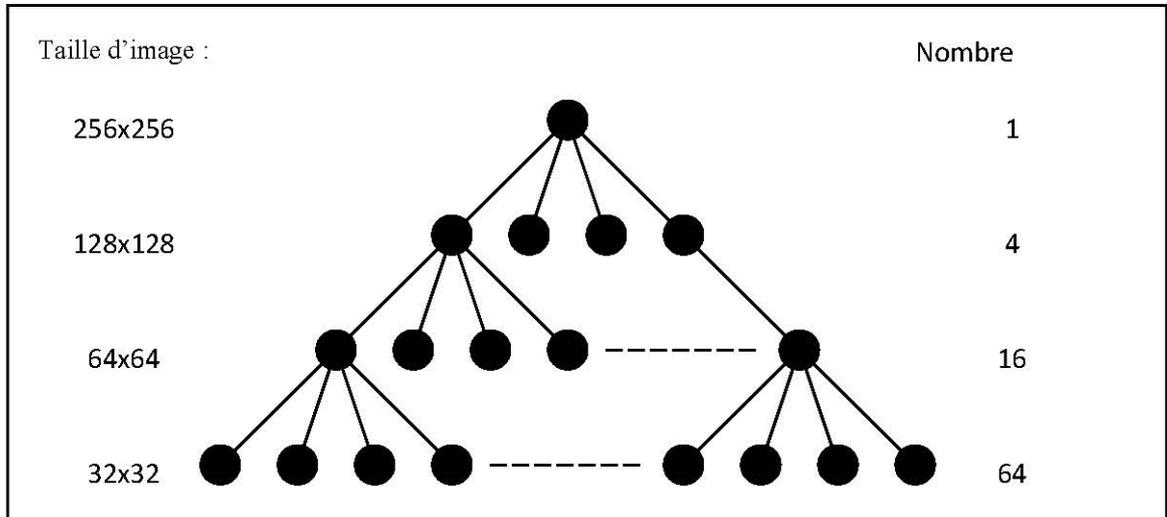


Figure 3.7 : Décomposition multirésolution par paquet d'ondelettes

La décomposition de toutes les sous-images et à toutes les résolutions est en général onéreuse en temps de calcul et sans grand intérêt pour la segmentation. Certains chercheurs [63,64] ont donc modifié l'algorithme pyramidal en introduisant un critère d'énergie qui permet d'estimer si la décomposition est nécessaire dans un canal fréquentiel donné. La décomposition réalisée devient donc plus adaptative et ne s'opère plus que sur les sous-images (en sortie de filtre) donnant des valeurs d'énergie suffisantes. Il en résulte une structure dont les nœuds représentent les canaux fréquentiels dominants.

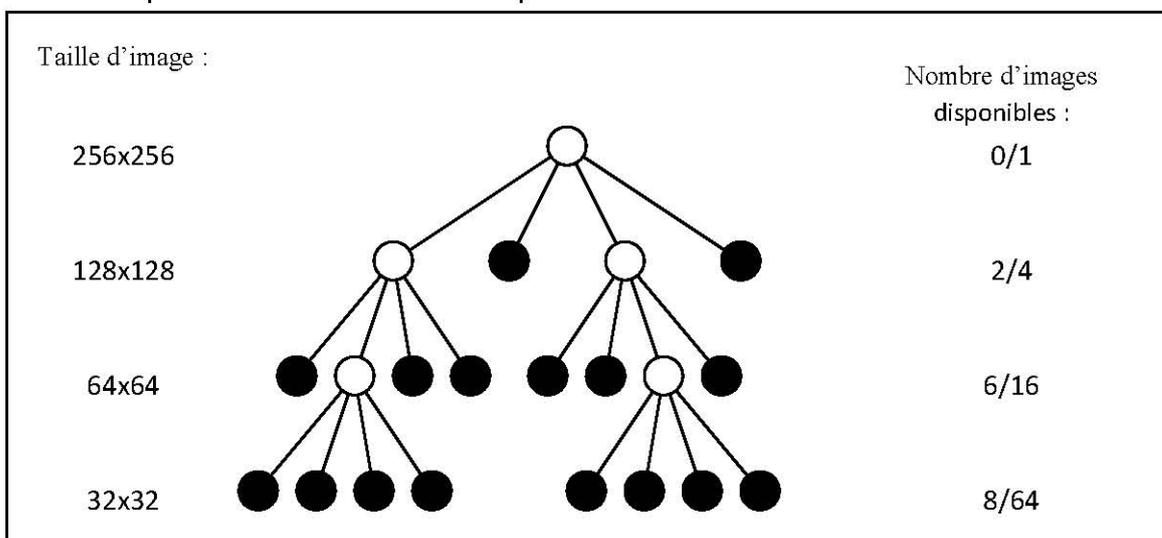


Figure 3.8 : Décomposition multirésolution adaptée d'une image

Le résultat de la figure 3.9 illustre le concept de la décomposition multirésolution adaptée pour une image TOFD.

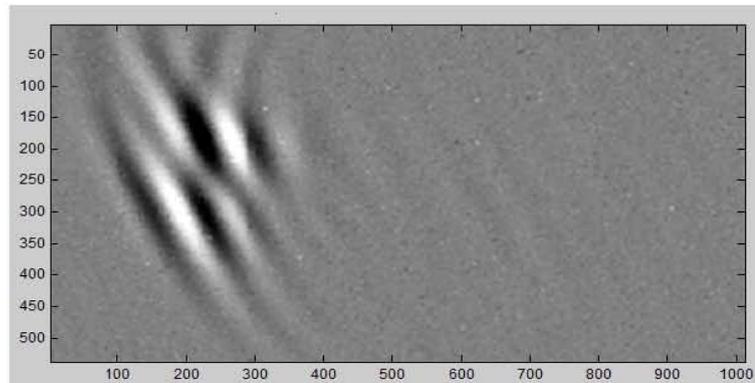


Image originale

A_3^{\square}	D_3^1	D_2^1	D_1^1
D_3^2	D_3^3		
D_2^2		D_2^3	
D_1^2			D_1^3

Disposition des sous images



Image décomposée en 3 niveaux

Figure 3.9: Exemple de décomposition d'une image TOFD par ondelettes

3.3. Procédure de segmentation

La segmentation d'images consiste, par une approche frontière ou région, à faire ressortir de l'image les principales informations quant à son contenu. D'un point de vue textuelle, cela revient à allouer à chaque pixel d'une image une

classe d'appartenance désignant une texture précise. La figure 3.10 présente un résultat idéal de segmentation d'une image texturée.

Notre approche de segmentation d'images TOFD basée sur la détection de la texture des défauts est un processus comprenant plusieurs étapes :

- Décompositions des images en sous-images (théorie de paquet d'ondelettes);
- Classement et sélection des sous-images (analyse statistique des textures);
- Réduction de l'espace de représentation;
- Classification des pixels.

La figure 3.10 représente de manière schématique ces étapes.

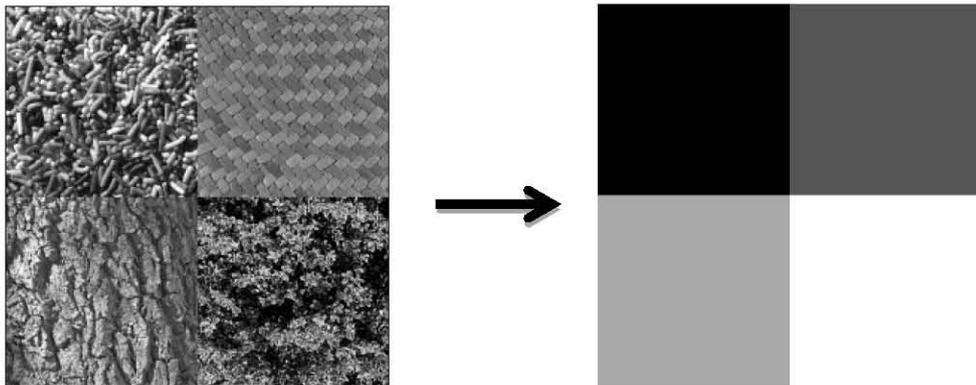


Figure 3.10: Segmentation idéale d'une image composée de 4 textures

a) *Décompositions des images fenêtres – Théorie des ondelettes*

Première approche :

Dans cette approche de segmentation, nous utilisons une fenêtre de sélection autour de chaque pixel d'une taille donnée afin de le caractériser dans sa région locale (voir la figure 3.11). Au cours de la première phase, l'image fenêtre est décomposée en quatre sous images par paquet d'ondelettes. Nous calculons pour chaque sous image la matrice de cooccurrence. Ensuite, comme

nous l'avons vu dans le chapitre précédent nous pouvons calculer les quatorze indices d'HARALICK de textures. Nous définissons les attributs statistiques comme critère de localisation de l'information dominante dans chaque sous-image (ils permettent le choix du canal de décomposition). Le critère de classification est un vecteur de cinq de ces indices.

Après plusieurs tests sur les images TOFD, nous avons observé que les cinq paramètres choisis sont pertinents parce qu'ils ont donné des valeurs de discrimination entre les défauts et le bruit de structure. Les cinq indices choisis sont:

- Le moment angulaire du second ordre.
- Le contraste.
- Le moment des différences inverses.
- La moyenne de la somme.
- L'entropie.

Le détail de calculs de ces indices est donné dans le chapitre 2.

La mesure texturale est obtenue par :

$$M_T = \sqrt{f_1^2 + f_2^2 + f_5^2 + f_6^2 + f_9^2} \quad (3.12)$$

Si la mesure texturale d'une sous-image est plus grande que les autres, nous allons continuer la décomposition dans cette région puisqu'elle contient plus d'information texturale. De la même manière nous répétons la décomposition jusqu'à ce que la taille minimale des sous-images ait excédé. Selon notre expérience de la taille la plus petite des sous-images est de 8×8 pixels. En regroupant toutes les images décomposées on obtient une image caractéristique de même taille que la fenêtre d'extraction. Cette image caractéristique sera transformée en vecteur d'attribut pour ce dernier pixel. Après, nous déplaçons la fenêtre par un Pixel, et on exécute le processus de décomposition. Répéter ces étapes sans interruption pour couvrir l'image entière. Ces ensembles d'images contiennent un ensemble de vecteurs d'attribut. On assume que ces vecteurs d'attributs qui correspondent à différentes résolution de l'image décomposée, caractérisent efficacement les différents contenus texturaux de l'image d'entrée.

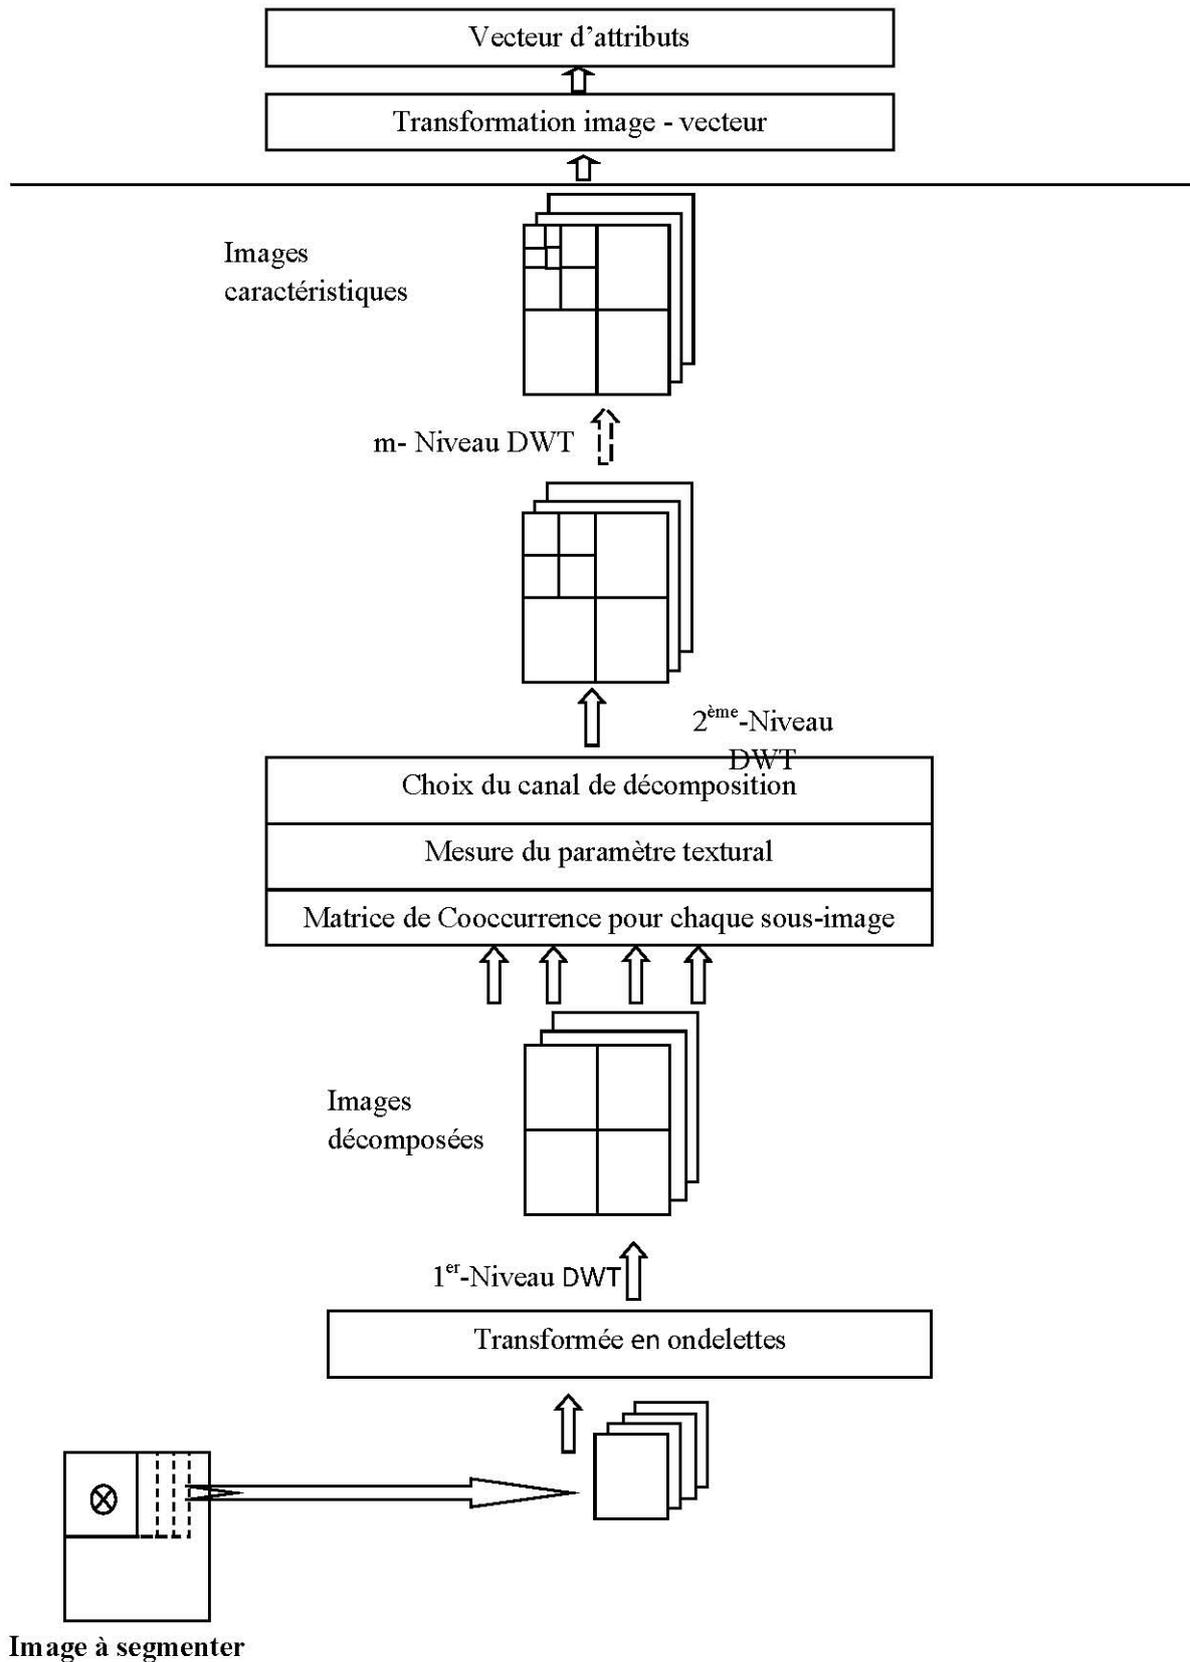


Figure 3.11: Paramètres d'ondelettes pour chaque pixel dans l'image à segmenter (première approche)

Deuxième approche :

De la même manière, on utilise la décomposition d'ondelettes récursive. Mais cette fois ci, on décompose l'ensemble de l'image à une structure arborescente, de type « quadtree » jusqu'à atteindre le niveau 3. Une fois la décomposition achevée, un certain nombre de sous-images est disponible mais toutes ne seront pas forcément utilisées dans le processus de segmentation. Il convient de faire un choix et, pour ce faire, on réutilise la mesure texturale de l'équation (3.12). On classe chacune des sous-images par ordre de distance croissante de l'image la plus « proche » (plus grande information) à la plus « éloignée » (plus faible information).

Afin de simplifier les traitements suivants, un nombre limité d'images (parmi les 85 potentielles) doit être conservé. Par ailleurs, l'expérimentation a montré que plus le nombre d'images retenues à ce niveau était important, meilleurs étaient les résultats de la segmentation. Cela s'explique par le fait qu'un plus grand nombre d'images conserve mieux et plus d'information qu'un nombre restreint. Au final, une vingtaine d'images ont été retenues.

A partir des sous-images sélectionnées (celles les plus proches de l'image initiale au sens de l'information qu'elles contiennent), on construit des images caractéristiques C_1, C_2, \dots, C_n de même taille que l'image initiale. Elles correspondent à un canal fréquentiel donné et on prend soin d'annuler toute contribution des autres canaux. On préserve ainsi les propriétés d'orthogonalité et d'unicité de la décomposition. Chacune d'entre elles est une variable décrivant un attribut à chaque pixel de l'image dans un canal fréquentiel donné.

A un pixel $I(i, j)$ de l'image initiale est associé un vecteur $[C_1(i, j), C_2(i, j), \dots, C_n(i, j)]$ de n composantes issues des images caractéristiques (figure 3.13).

La méthode de reconstruction des images caractéristiques reprend l'algorithme de décomposition d'une image (à l'aide des filtres G et H) mais en sens inverse, en éliminant les sous-images de faible information texturale de la dernière décomposition pour chaque niveau (voir la figure 3.12).

Avant d'aborder la phase de classification des pixels, les images caractéristiques sont lissées à l'aide d'un ou plusieurs filtres. Ceci permet de rapprocher les attributs de pixels appartenant à une même classe et d'accentuer la dissemblance entre attributs de pixels différents.

Ce lissage s'effectue grâce à un masque 5x5. Afin d'améliorer cette opération, on applique le masque d'un filtre médian et on le fait suivre d'un filtre passe-bas et d'un filtre passe-haut. Le filtre médian élimine les pixels dont le NDG est très différent de celui des pixels voisins, le passe-bas moyenne le NDG d'un pixel avec celui de ses voisins, et le passe-haut exacerbe les différences finales de NDG entre pixels voisins. Des essais sont encore nécessaires pour valider ces apports.

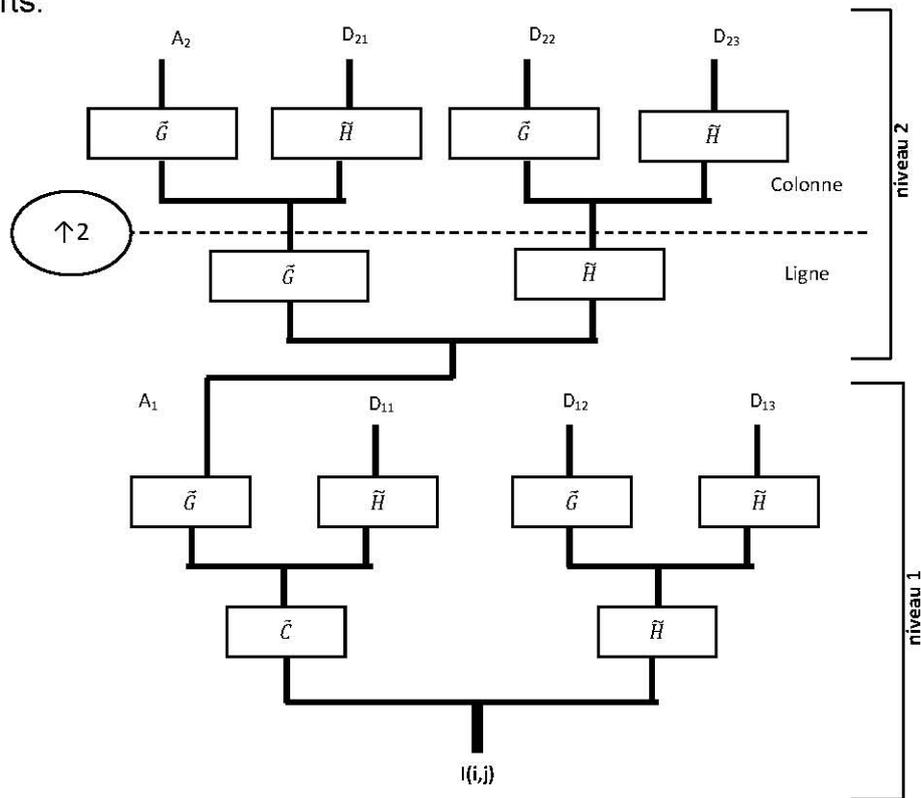


Figure 3.12: Reconstruction d'une image à partir des ondelettes

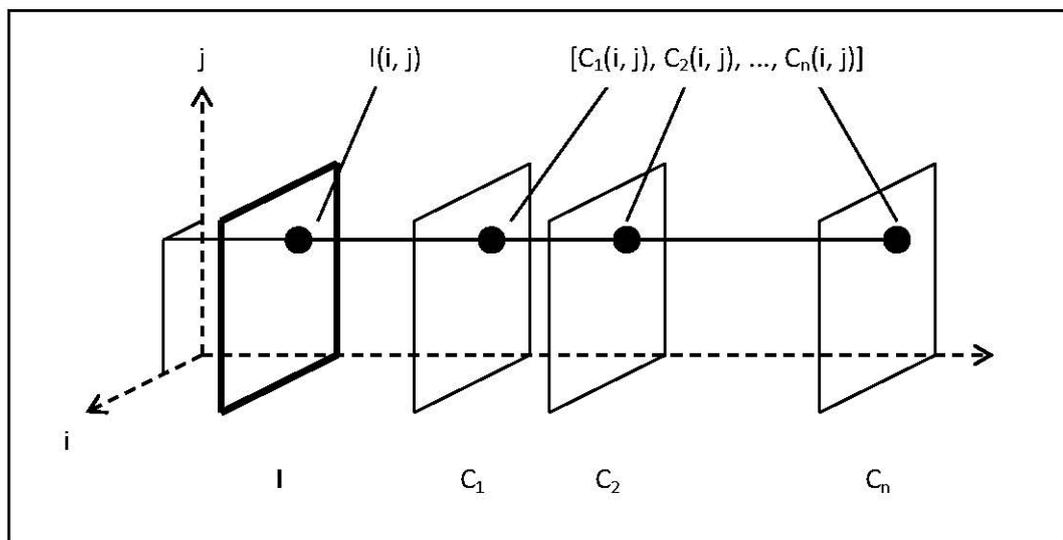


Figure 3.13 : Vecteur d'attributs de chaque pixel de l'image

b) *Réduction de l'espace de représentation*

Cette étape est importante car elle permet d'aboutir à un nombre réduit de variables décorréelées, décrivant chaque pixel de l'image. Ceci confère une plus grande précision à la classification des pixels, tout en réduisant les temps de calculs.

La transformation de Karhunen-Loeve est utilisée à cet effet. Elle consiste en une analyse en composantes principales (ACP). C'est une technique descriptive permettant d'étudier les relations qui existent entre les variables, sans tenir compte, a priori, d'une quelconque structure.

Le but de l'ACP est d'identifier la structure de dépendance entre des observations multi variables, afin d'obtenir une description ou une représentation compacte de ces dernières.

L'idée de base de l'ACP est de réduire la dimension de la matrice des données, en retenant le plus possible les variations présentes dans le jeu des données de départ. Cette réduction ne sera possible que si les variables initiales ne sont pas indépendantes et ont des coefficients de corrélation entre elles non nuls. Ces variables initiales sont transformées en de nouvelles variables, appelées composantes principales. Elles sont obtenues par combinaisons linéaires des précédentes et sont ordonnées et non corrélées entre elles. L'analyse en composantes principales cherche à identifier les vecteurs propres ortho-normaux et leurs valeurs propres correspondantes de la matrice de dispersion des variables originelles. Les vecteurs propres ortho-normaux sont utilisés pour construire les composantes principales et les valeurs propres sont les variances des composantes principales correspondantes [65].

Etant donné X une matrice de P variables numériques en colonnes décrivant les N vecteurs d'attributs (en lignes), nous proposons de rechercher une représentation de N vecteurs e_1, e_2, \dots, e_n , dans un sous-espace de l'espace initial. En d'autres termes, nous devons définir de nouvelles variables K , une combinaison de P de l'espace initial, ce qui ferait perdre le moins d'informations possible. Ces variables K seront appelées composantes principales et les axes qu'ils déterminent seront les axes principaux. Alors pour N pixels, nous aurons une matrice de taille $N \times P$ qui est donnée par:

$$e = [e_1, e_2, e_3, \dots, \dots, \dots, e_n]$$

La moyenne pour chaque vecteur :

$$M_e = \frac{1}{N} \sum_{m=1}^n e_m \quad (3.13)$$

Et pour chaque élément, on calcule la différence :

$$\rho_i = e_i - M_e \quad (3.14)$$

La matrice de covariance est calculée par :

$$C = \frac{1}{N} \sum_{m=1}^N \rho_m \rho_m^T = \frac{1}{N} A \times A^T \quad (3.15)$$

Avec : $A = [\rho_1 \rho_2 \rho_3 \dots \dots \dots \rho_N]$;

Cependant, la détermination des vecteurs propres de la matrice de covariance, il faudra un calcul excessif, la taille de cette matrice est $P \times P$.

Si v_i est le vecteur propre de $A \times A^T$, alors ses valeurs propres sont:

$$A^T A v_i = \lambda_i v_i \quad (3.16)$$

Les vecteurs propres de C sont calculés par :

$$\lambda_i = A \times v_i \quad (3.17)$$

Finalement, la composante principale de chaque vecteur d'attributs e_i est donnée par:

$$w_k = \lambda_k^T \times (e_i - M_e) \quad (3.18)$$

Les vecteurs w_k représentent les nouveaux paramètres complètement decorrèles et optimisés pour la classification.

c) *Classification des pixels*

L'algorithme de classification utilisé est connu sous le nom d'algorithme FCMI. Cet algorithme permet de fournir une partition optimale de l'ensemble des pixels de l'image initiale en k classes d'individus. Il nécessite cependant la connaissance préalable du nombre de classes ou régions homogènes composant l'image. Dans notre cas, nous avons deux classes possibles : « défaut » et « non-défaut ».

FCMI est un algorithme de classification supervisée en termes de classes et sans apprentissage. Issu de l'algorithme des C-moyennes (C-means), il introduit la notion d'ensemble flou dans la définition des classes : chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré, et tous les clusters sont caractérisés par leur centre de gravité [66].

La possibilité de nuance d'une information floue se trouve à l'origine des travaux de la théorie des ensembles flous, ce qui permet d'évoquer la notion d'incertitude et d'imprécision.

- **Logique classique :** Dans la théorie classique des ensembles, un objet appartient ou n'appartient pas à un ensemble.
- **La théorie des sous-ensembles flous :** Un sous-ensemble flou A est défini par une fonction d'appartenance $\mu_A(x)$ qui décrit le degré avec lequel l'élément x appartient à A .

$$\begin{array}{l} \textbf{Théorie Classique} \\ \mu(x) = \begin{cases} \mathbf{1} & \text{si } x \in A \\ \mathbf{0} & \text{si non} \end{cases} \end{array}$$

$$\begin{array}{l} \textbf{Théorie Floue} \\ \mu(x) \in [0, 1] \end{array}$$

Alors en logique floue, un objet peut appartenir à un ensemble et en même temps à son complément.

- Autre définitions :

Fuzzyfication ou quantification floue :

Cette première étape consiste à déterminer le degré d'appartenance de chaque variable d'entrée à chaque état. Celui-ci est déterminé à l'aide des fonctions d'appartenance définies dans le système.

Défuzzyfication :

En sortie, le système flou ne peut pas communiquer des valeurs floues qu'il peut seul exploiter. Il lui est donc nécessaire de fournir des valeurs précises, c'est le rôle de la défuzzyfication.

L'algorithme de la méthode FCMI se réalise comme suit:

1. Les N_c centres de gravité sont initialisés à des formes aléatoires dans l'espace des attributs :

$$y_i = x_i (i = 1 \text{ à } N_c) \quad (3.19)$$

2. Calcul de la distance entre chaque forme et chaque centre de gravité :

$$d_{ij} = \|x_j - y_i\| \quad (3.20)$$

3. Calcul de la matrice des valeurs d'adhésion (**Fuzzyfication**):

$$\mu_{ij} = \left[\sum_{l=1}^{N_c} \frac{d_{lj}^{2/(\beta-1)}}{d_{lj}} \right]^{-1} \quad (3.21)$$

β est un paramètre de contrôle de degré de flou.

si $d_{ij} = 0$ pour $l = l_0$ alors $\mu_{i_0j} = 1$ et ($\mu_{ij} = 0$ pour $l \leq i \leq N_c$ et $i \neq l_0$).

4. Les centres de gravité sont mis à jour en utilisant la formule suivante :

$$y_i = \frac{\sum_{j=1}^m \mu_{ij} x_j}{\sum_{j=1}^m \mu_{ij}} \quad (3.22)$$

Avec m: le nombre de formes.

Si les nouveaux centres sont déplacés, alors l'algorithme boucle à l'étape 2, sinon on continue.

5. Défuzzication:

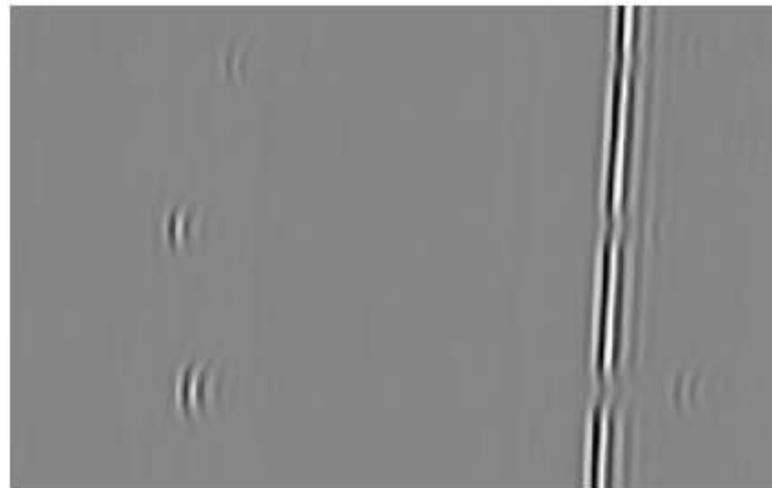
Si $\mu_{i_0j} = \max(\mu_{ij})$ alors $\mu_{i_0j} = 1$ et ($\mu_{ij} = 0$ pour $l \leq i \leq N_c$ et $i \neq l_0$). La forme

x_j appartient à la classe i_0 .

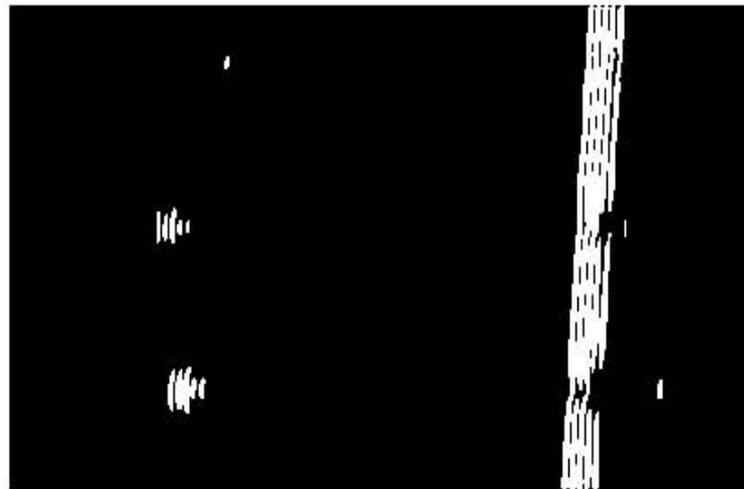
3.4. Résultats et discussions

Afin de vérifier la robustesse des deux approches proposées, nous les avons appliquées sur deux images réalisées au niveau du laboratoire à partir d'un contrôle ultrasonore par immersion.

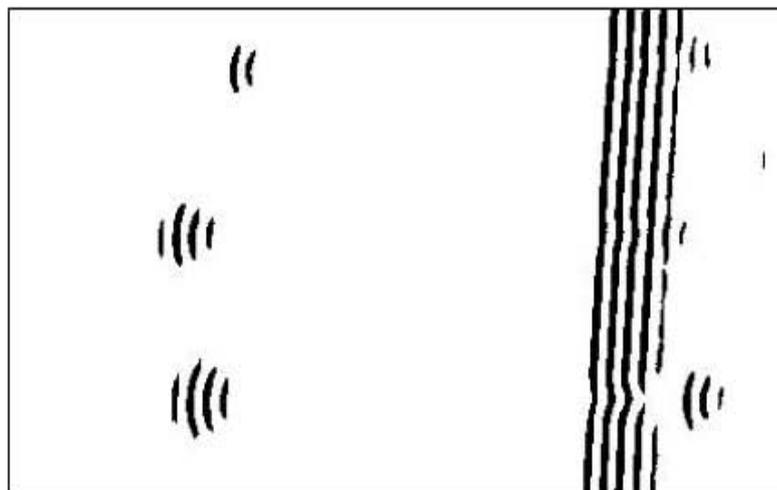
Les résultats obtenus sont illustrés par les images (figure 3.14b, 3.14c) et (figure 3.15b, 3.15c). Nous notons que les deux algorithmes développés donnent des résultats satisfaisants. Nous remarquons une bonne détection des défauts par les deux algorithmes. L'utilisation de ces résultats pour un dimensionnement des défauts est possible. Ceci permet de conclure que la première approche donne de meilleurs résultats. Ces derniers sont jugés très encourageants pour une éventuelle application à l'échelle industrielle.



(a)



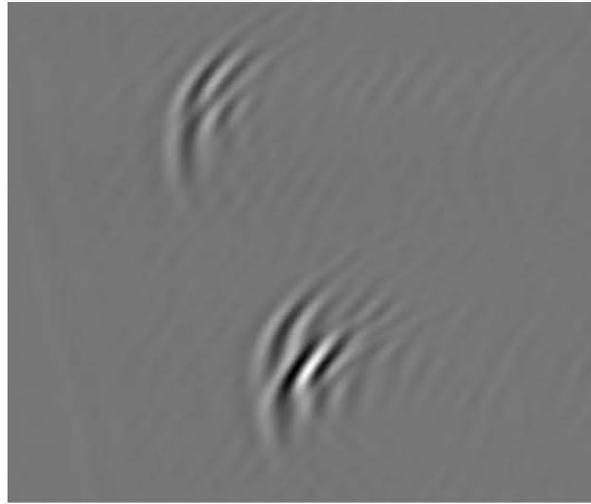
(b)



(c)

Figure 3.14: Résultats de segmentation de la première image TOFD réalisée au niveau du laboratoire (a), (b) : Segmentation par les paramètres d'ondelettes, (c) : Segmentation par les paramètres de GABOR.

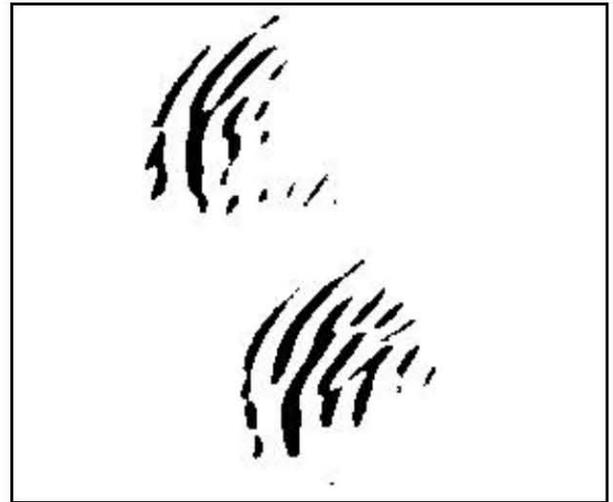
Afin de valider les résultats obtenus, nous avons testé les deux approches développées sur deux images réalisées à l'échelle industrielle en utilisant un contrôle ultrasonore par contact.



(a)



(b)



(c)

Figure 3.15: Résultats de segmentation de la deuxième image TOFD réalisée au niveau du laboratoire (a), (b) : Segmentation par les paramètres d'ondelettes, (c) : Segmentation par les paramètres de GABOR.

Pour la première approche, la taille de la fenêtre de sélection dépend de la taille des défauts dans l'image TOFD.

Une petite taille de la fenêtre de sélection diminue la robustesse des paramètres texturales, tandis qu'une taille supérieure mènera à un coût de calcul plus élevé. Empiriquement, l'utilisation d'une taille de 32×32 pixels donne un résultat très satisfaisant.

En conséquence, 2 niveaux de décomposition en ondelettes sont appropriés. La décomposition est implémentée en utilisant la base de Daubechies d'ordre 2. Nous avons, cependant, effectué les mêmes expériences avec d'autres ondelettes orthogonales, à savoir Haar, Daubechies d'ordre 4 à 16 et les filtres de Battle Lemarie. Dans nos expériences, les résultats offrent des performances à peu près semblables. En d'autres termes, les résultats obtenus sont pratiquement identiques donc nous estimons que le résultat est indépendant du choix de l'ondelette. Dans d'autres travaux, le choix d'ondelettes peut être cruciale.

Le test de la deuxième approche sur les images TOFD réalisées à l'échelle industrielle ne donne pas de bons résultats à cause de la décomposition globale de l'image par rapport à la première approche, où on décompose une fenêtre autour de chaque pixel et ça revient à la décomposition de la texture locale de ce dernier. Néanmoins, nous avons testé cette approche sur des images composées de deux textures de la base de Brodatz comme le montre la figure 3.16. Nous obtenons les meilleurs résultats pour des segmentations d'images aux textures homogènes (figures 3.16.a et 3.16.b). Pour l'image 3.16.c, s'il est possible de deviner et de retrouver les régions d'origines à partir de l'image segmentée, les résultats ne sont guère exploitables en l'état actuel. Nous pouvons toujours améliorer ce résultat en cherchant d'avantage sur le choix de l'ondelette et les paramètres statistiques pour le choix du canal de décomposition parce que dans notre application les cinq paramètres statistiques choisis sont dédiés à l'élimination du bruit de structure dans la détection du défaut. Et nous avons remarqué que cette approche a donné de bons résultats sur les images du laboratoire. Ceci est dû forcément à l'absence du bruit de structure dans ces derniers.

La mise en œuvre de l'algorithme de l'ACP a optimisé et réduit la taille des vecteurs d'attributs jusqu'à 70%. À partir de cela, nous avons réduit le temps de calcul et donné plus de précision.

Dans la phase finale, l'implémentation de l'algorithme de classification FCMI donne très peu de variation dans la performance. La raison en est que les vecteurs d'attributs extraits à partir des deux images et optimisés par l'ACP contiennent très peu d'échantillons mixtes.

Les résultats obtenus sont illustrés par les images (figure 3.17b, 3.17c) et (figure 3.18b, 3.18c). Nous notons que la première approche développée donne des résultats satisfaisants par rapport à la deuxième approche où on constate la détection des défauts et la détection du bruit de structure. L'utilisation des résultats de la première approche pour un dimensionnement du défaut est possible. En effet, les images 3.17b et 3.18c présentent des lignes très fines qui caractérisent les bords du défaut.

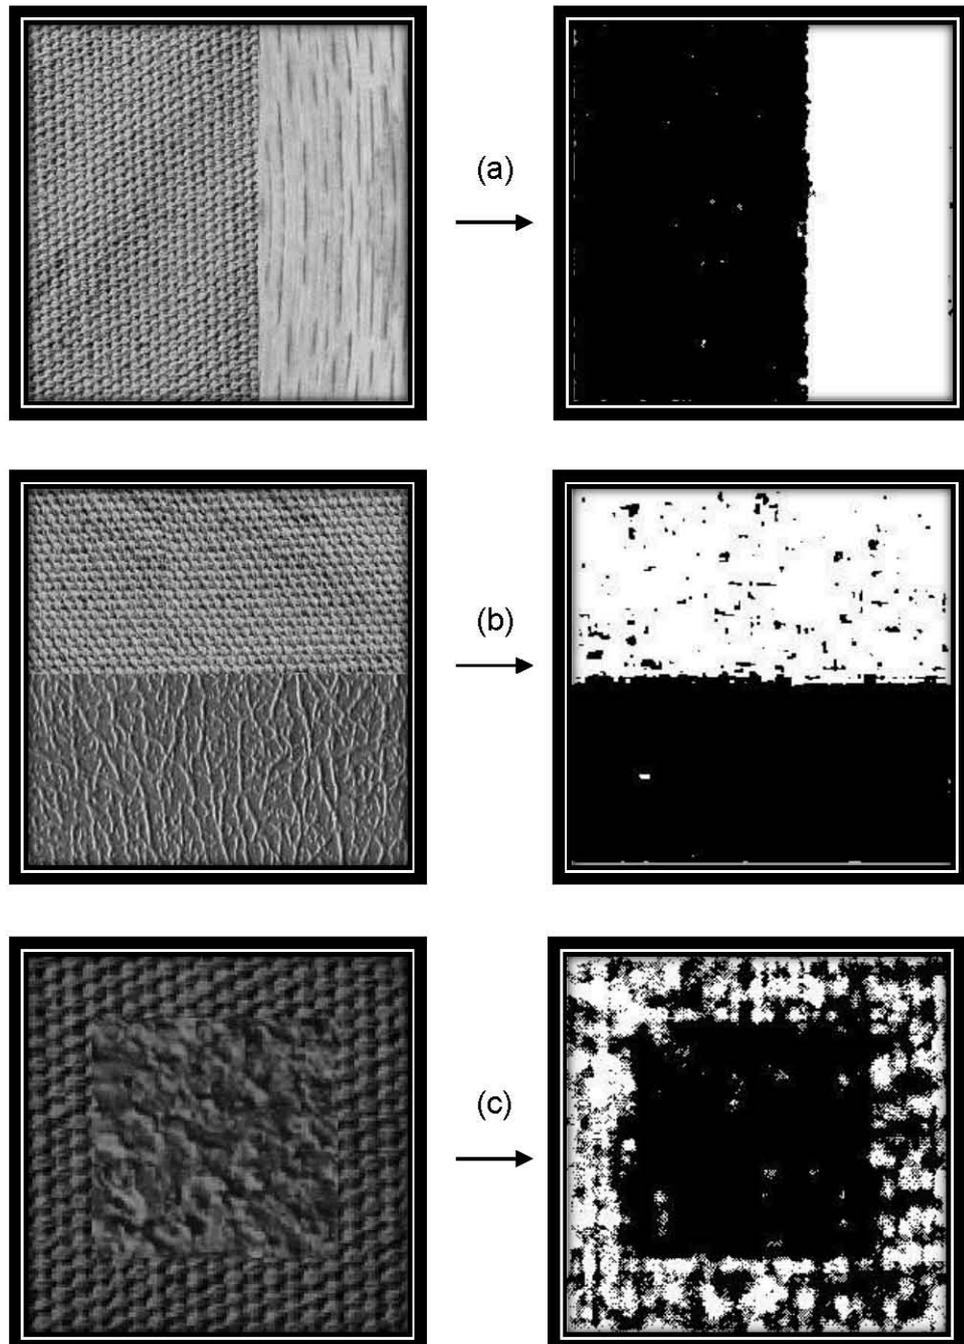
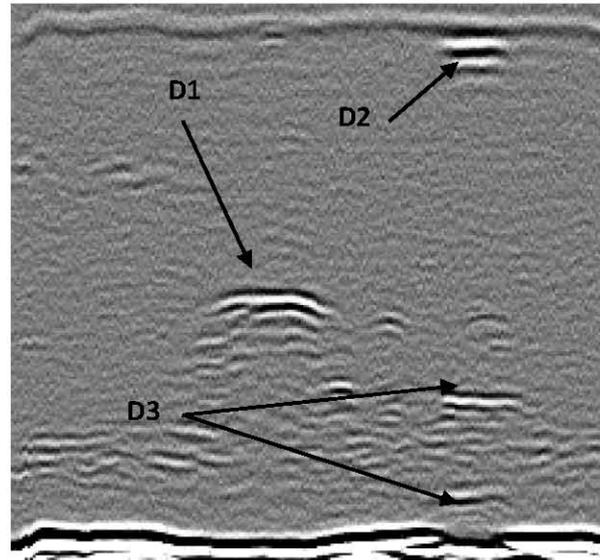


Figure 3.16: Résultats de segmentation de la deuxième approche sur des images composées de deux textures de la base Brodatz



(a)

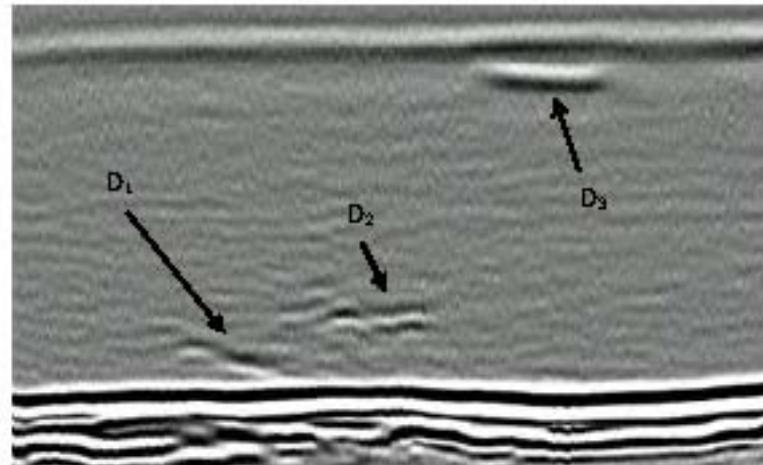


(b)



(c)

Figure 3.17: (a) Image TOFD industrielle, (b) Image segmentée par la 1^{ère} approche, (c) Image segmentée par la 2^{ème} approche



(a)



(b)



(c)

Figure 3.18: (a) Image TOFD industrielle, (b) Image segmentée par la 1^{ère} approche, (c) Image segmentée par la 2^{ème} approche

3.5. Conclusion

Deux procédures de segmentation de l'image TOFD pour la détection de défauts basées sur la caractérisation textuelle ont été présentées.

Dans la phase finale pour chaque procédure, nous avons utilisé l'algorithme de FCMI pour classer chaque pixel comme «défaut» ou «non-défaut» et cette phase se traduira par une image segmentée. Cet algorithme de classification opère sans apprentissage et cela engendra un inconvénient majeur qui est le temps de calcul.

Cependant, l'utilisation de l'ACP nous a permis de réduire la taille des vecteurs d'attributs et de l'optimiser pour avoir plus de précision.

Les résultats obtenus par la première approche développée sont satisfaisants. Nous remarquons une bonne détection des défauts et une élimination des échos issus du bruit de structure, et ceci est dû à l'implémentation de cinq paramètres d'Haralick pour le choix du canal de décomposition. On ne retrouve pas ce résultat dans la deuxième approche du fait de la décomposition intégrale de l'image. Cette deuxième approche peut être améliorée pour être dédiée à la segmentation des autres types de textures.

Dans le chapitre suivant, nous allons envisager de développer une autre technique supervisée basée sur les banques de filtres de Gabor pour améliorer la segmentation en termes de temps de calcul.

CHAPITRE 4

SEGMENTATION SUPERVISEE DE TEXTURE BASEE SUR LES BANQUES DE FILTRES DE GABOR

4.1. Introduction

Des méthodes générales ont été développées en reconnaissance des formes pour extraire automatiquement des informations des données pertinentes afin de caractériser les classes de formes (apprentissage) et d'assigner automatiquement des données à ces classes (reconnaissance). L'apprentissage ou modélisation est une étape clé dans la chaîne de reconnaissance de formes. L'apprentissage se charge d'acquérir la connaissance et de l'organiser en classes ou en modèles de références. Cela exige de l'apprentissage de bien définir les classes de formes et leurs séparatrices de manière à bien distinguer les familles de formes homogènes. Il est, ainsi, possible d'identifier les nouvelles formes par rapport aux classes de formes créées lors de l'étape de l'apprentissage. Il existe deux types d'apprentissage : supervisé et non supervisé [67].

- L'apprentissage supervisé : l'apprentissage est dit supervisé si les différentes familles de formes sont connues a priori et si la tâche d'apprentissage est guidée par un superviseur ou concepteur.
- L'apprentissage non supervisé : on l'appelle aussi, suivant l'approche utilisée, classification automatique ou apprentissage sans professeur. Il s'agit, à partir d'échantillon de référence et de règles de regroupement ou de modélisation, de construire automatiquement les classes ou les modèles sans intervention de l'opérateur.

La décision ou le classement est l'étape de reconnaissance proprement dite. Son rôle est d'identifier la forme test à partir de l'apprentissage réalisé, selon des critères de comparaison.

La méthode SVM (Séparateur à Vaste Marge) est d'une efficacité remarquable surtout dans les cas de classification binaire (deux classes) et elle utilise un apprentissage supervisé. Les SVMs constituent un nouveau type d'algorithmes d'apprentissage, originellement introduits par Vladimir Vapnik [68].

L'objectif de ce chapitre est d'implémenter une méthode de segmentation rapide et efficace de l'image TOFD par classification de chaque pixel avec un apprentissage supervisé par les SVMs.

L'étape de caractérisation s'opère sur la texture des défauts en utilisant les banques de filtres de Gabor.

Le filtre de Gabor est une fonction de noyau gaussien modulée par une onde plane sinusoïdale. Tous les filtres de Gabor peuvent être générés à partir d'une ondelette mère par dilatation et rotation. Ces filtres représentent un choix approprié pour les tâches nécessitant une mesure simultanée dans les deux domaines : espace et fréquence.

Les filtres de Gabor sont optimisés par l'Analyse en Composantes Principales (ACP) et utilisés comme vecteur d'attributs pour chaque pixel de l'image TOFD. L'approche proposée est testée sur des images réalisées au niveau du laboratoire et à l'échelle industrielle.

4.2. Méthode SVM

Les SVMs sont basés sur un algorithme d'apprentissage ayant comme fonction de décision un hyperplan optimal dans un espace de grande dimension D . La projection dans cet espace est réalisée pour pallier à la non linéarité de séparation. A partir des données d'apprentissage $\{(x_i, y_i)\}$ où $x_i \in R^d$ et $y_i = \{-1, +1\}$, l'algorithme consiste à représenter les points x_i dans cet espace D par une transformation non linéaire construite à partir d'une famille de fonctions $\{\phi_k\}$ sous certaines conditions. La série $\phi_k(x) \cdot \phi_k(y)$ converge vers une fonction K appelée noyau (Kernel) [69].

4.2.1. Linéarité et non linéarité :

Parmi les modèles des SVMs, on constate les cas linéairement séparables et les cas non linéairement séparables. Les premiers sont les plus simples de SVM car ils permettent de trouver facilement le classificateur linéaire. Dans la plupart des problèmes réels il n'y a pas de séparation linéaire possible entre les données, le classificateur de marge maximale ne peut pas être utilisé car il fonctionne seulement si les classes de données d'apprentissage sont linéairement séparables [70].

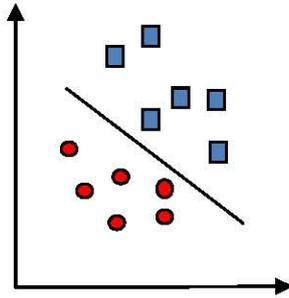


Figure 4.1 : Exemple de données linéairement séparables

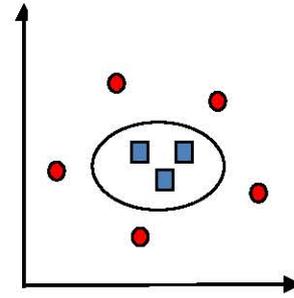
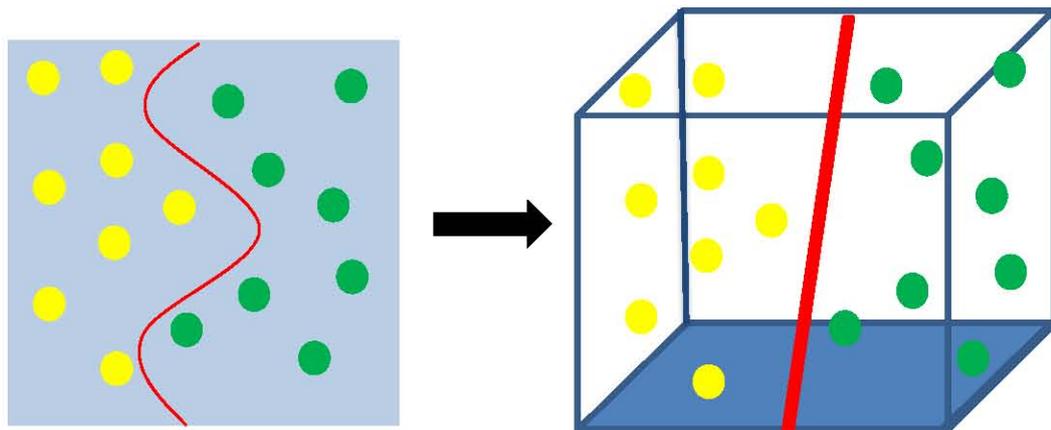


Figure 4.2 : Exemple de données non linéairement séparables

Pour surmonter les inconvénients des cas non linéairement séparables, l'idée des SVMs est de changer l'espace des données. La transformation non linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace. On va donc avoir un changement de dimension. Cette nouvelle dimension est appelée «espace de redescription». En effet, intuitivement, plus la dimension de l'espace de redescription est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée. Ceci est illustré par le schéma suivant (figure 4.3) :



A : données dans R^2 appartenant à deux classes non linéairement

B : l'image des données de la figure (a) dans R^3 en utilisant la

Figure 4.3: Exemple de redescription de l'espace

On a donc une transformation d'un problème de séparation non linéaire dans l'espace de représentation en un problème de séparation linéaire dans un espace de redescription de plus grande dimension. Cette transformation non linéaire est réalisée à travers une fonction noyau. En pratique, quelques familles de fonctions noyaux paramétrables sont connues et il revient à l'utilisateur de SVM d'effectuer des tests pour déterminer celle qui convient le mieux pour son application. On peut citer les exemples de noyaux suivants : polynomiale, gaussien, sigmoïde ...etc.[71].

4.2.2. Principe des SVMs

Pour deux classes d'exemples donnés, le but des SVMs est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec la méthode SVM, ce classificateur est un classificateur linéaire appelé hyperplan. Dans le schéma qui suit (figure 4.4), on détermine un hyperplan qui sépare les deux ensembles de points, les supports vecteurs, la marge et les hyperplans canoniques.

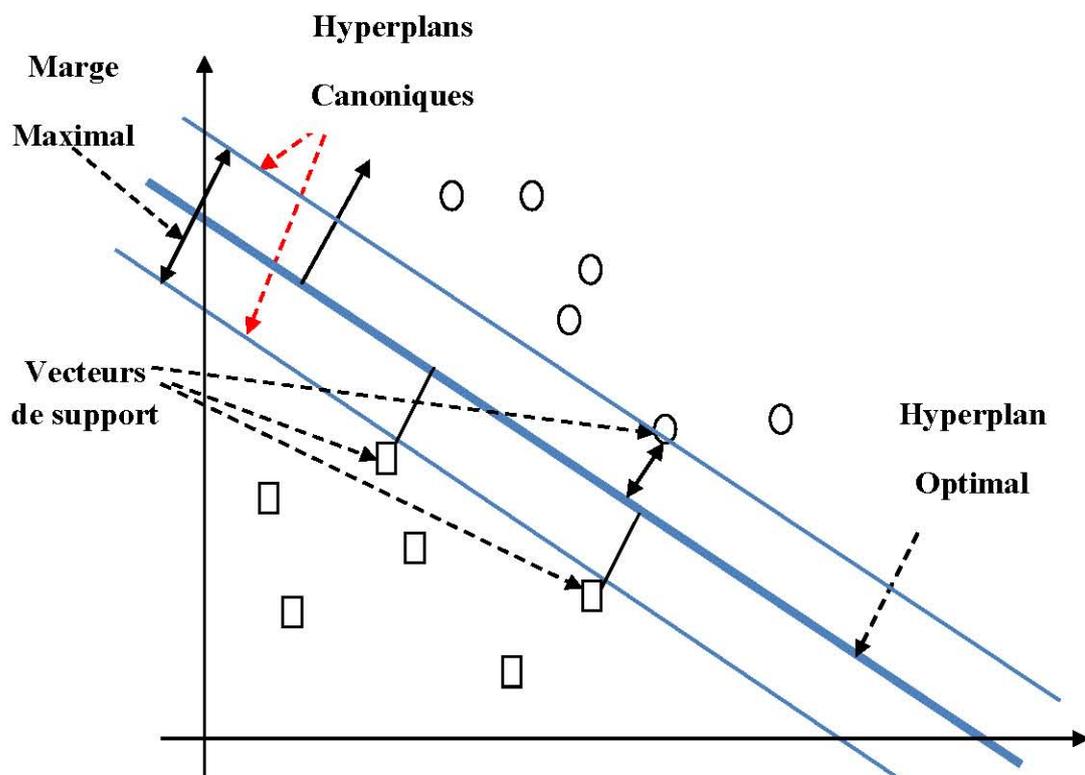


Figure 4.4 : Illustration des notions de base des SVMs

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsque l'on classe un nouvel exemple. De plus, si l'on trouve le classificateur qui se comporte le mieux vis-à-vis des données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples.

4.2.2.1. Principe des données linéairement séparables

Les SVMs sont par essence des classificateurs bi-classes qui visent à séparer les exemples de chaque classe Ω_q , $1 \leq q \leq 2$, au moyen d'un hyperplan $H(w, b)$ choisi de manière à garder un maximum de marge de séparation entre n'importe quels exemples d'apprentissage et $H(w, b)$. De façon plus formelle, en se donnant les exemples $\{(x_1, y_1), \dots, (x_l, y_l)\}$ dans $\mathbb{R}^d \times \{-1, +1\}$ et en munissant \mathbb{R}^d d'un produit scalaire, il s'agit de déterminer l'hyperplan optimal :

$$H(w, b): w \cdot x + b = 0; w \in \mathbb{R}^d, b \in \mathbb{R} \quad (4.1)$$

Solution de :

$$\max_{(w \in \mathbb{R}^d, b \in \mathbb{R})} \min\{ \|x - x_i\|; x \in \mathbb{R}^d, w \cdot x + b = 0, i = 1 \dots l \}$$

L'équation de l'hyperplan est donnée par :

$$w \cdot x + b = 0 \quad (4.2)$$

En utilisant une mise à l'échelle appropriée de w et b et en supposant dans un premier temps que les données sont linéairement séparables, il est possible de contraindre les exemples de chaque classe à satisfaire les conditions :

$$w \cdot x_i + b \geq +1 \quad y_i = +1 \quad (4.3)$$

$$w \cdot x_i + b \leq -1 \quad \text{pour } y_i = -1 \quad (4.4)$$

Qui peuvent être combinées en une même inégalité :

$$y_i(w \cdot x_i + b) - 1 \geq 0, \forall i \quad (4.5)$$

Les deux hyperplans sont :

$$\begin{cases} \text{H1: } w \cdot x_i + b = -1 & (4.6) \\ \text{H2: } w \cdot x_i + b = +1 & (4.7) \end{cases}$$

Permettent de définir la marge. Remarquons que H1 et H2 sont parallèles (ils ont la même normale w) et qu'il n'existe aucun point entre les deux, grâce aux formules (4.3) et (4.4). Par suite la marge n'est autre que la distance entre H1 et H2 qui vaut $\frac{2}{\|w\|}$

La figure 4.5 donne une illustration.

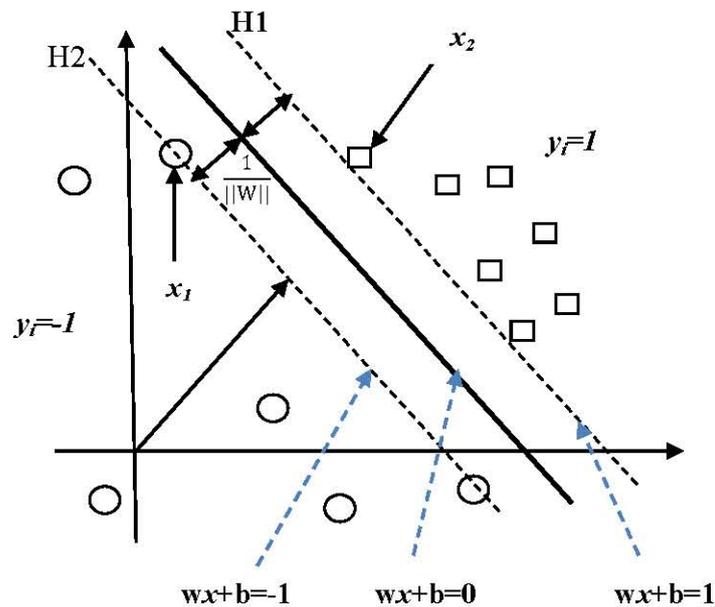


Figure 4.5 : Les hyperplans

De la figure 4.5 on a :

$$\begin{cases} w \cdot x_1 + b = -1 & (4.8) \\ w \cdot x_2 + b = 1 & (4.9) \end{cases}$$

$$(4.9) - (4.8) \xrightarrow{\text{Donne}} w \cdot (x_2 - x_1) = 2 \quad (4.10)$$

$$\frac{(4.10)}{\|w\|} \xrightarrow{\text{Donne}} \frac{w}{\|w\|} (x_2 - x_1) = \frac{2}{\|w\|}$$

Les points qui se trouvent sur les hyperplans H1 et H2 sont appelés les vecteurs supports. Le problème posé ne dépend en fait que de ces points particuliers en ce sens que si tous les autres points sont éliminés, la solution du

problème reste la même. Ainsi, l'hyperplan optimal est solution du problème d'optimisation.

On peut donc en déduire que maximiser la marge revient à maximiser $\frac{2}{\|w\|}$.

Et la maximisation de $\frac{2}{\|w\|}$ se ramène à la minimisation de $\frac{\|w\|^2}{2}$.

Notons que l'on choisit de minimiser $\frac{\|w\|^2}{2}$ plutôt que $\frac{\|w\|}{2}$ car cela facilite la résolution du problème. Donc on a le problème de minimisation sous contraintes suivant :

$$\begin{cases} \text{minimiser} & \frac{\|w\|^2}{2} \\ \text{sous les contraintes} & y_i(w \cdot x_i + b) \geq 1 \quad i = 1, \dots, l. \end{cases} \quad (4.11)$$

l : c'est le nombre de points à classifier.

x_i : sont les points à classifier.

$y_i = \pm 1$: C'est la classe de x_i

w, b : deux paramètres à trouver.

Nous sommes en présence d'un problème sous contraintes d'inégalités, on utilise la forme duale pour faciliter la résolution de ce problème.

Le problème de l'équation (4.11) est un problème d'optimisation sous contraintes qui est résolu en introduisant des multiplicateurs de Lagrange α_i tel que $0 \leq i \leq l$ est un Lagrangien. Il y a deux raisons pour cela : La première est que la contrainte dans (4.11) sera remplacée par une contrainte simple sur les multiplicateurs du Lagrangien qui sera plus facile à traiter. La deuxième, pour rendre le problème sous forme quadratique et le résoudre par des méthodes existantes [72].

Lagrangien s'écrit de la manière suivante :

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^l \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (4.12)$$

Où les coefficients $\alpha_i \geq 0$ sont appelés multiplicateurs de Lagrange associés à chaque contraintes i et $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_l)$.

Au point-selle la dérivée du Lagrangien par rapport aux variables primaires doit s'annuler. Ceci s'écrit :

$$\frac{\partial L(w,b,\alpha)}{\partial w} = \mathbf{0} \xrightarrow{\text{Conduit à}} w = \sum_{i=1}^l \alpha_i y_i x_i. \quad (4.13)$$

$$\frac{\partial L(w,b,\alpha)}{\partial b} = \mathbf{0} \xrightarrow{\text{conduit à}} \sum_{i=1}^l \alpha_i y_i = 0 \quad (4.14)$$

Avec $\alpha_i \geq 0$

En substituant (4.13) et (4.14) dans (4.12) l'expression de L devient :

$$\begin{aligned} L(w, b, \alpha) &= \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^l \alpha_i [y_i (w \cdot x_i + b) - 1] \\ &= \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle - \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle - b \underbrace{\sum_{i=1}^l \alpha_i y_i}_0 + \sum_{i=1}^l \alpha_i \\ &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \end{aligned}$$

Maintenant il faut maximiser ce Lagrangien par rapport aux variables duales α_i et le problème quadratique sera :

$$\left\{ \begin{array}{l} \max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \\ \text{sous les contraintes} \left\{ \begin{array}{l} \sum_{i=1}^l \alpha_i y_i = 0 \\ \alpha_i \geq 0 \quad i = 1, \dots, l \end{array} \right. \end{array} \right. \quad (4.15)$$

Après la résolution de ce problème on trouve les multiplicateurs de Lagrange optimaux α_i . Donc on peut trouver w , en remplaçant dans l'équation (4.13) :

$$w = \sum_{i=1}^l \alpha_i y_i x_i$$

Le b est obtenu en utilisant n'importe quel vecteur de support (x_c, y_c) dans l'équation :

$$y_c (w \cdot x_c + b) = 1.$$

En remplaçant w et b dans l'équation de l'hyperplan (4.2):

$$\sum_{i=1}^l y_i \alpha_i \langle x_i, x \rangle + b = 0 \quad (4.16)$$

Le Lagrangien L doit être minimisé par rapport aux variables dites primales w et b , et maximisé par rapport aux variables duales α_i ce sont les conditions de Karush-Kuhn-Tucker (KKT) [40].

Pour notre problème la condition de Kuhn et Tucker devient :

$$\alpha_i [y_i (\langle x_i, w \rangle + b) - 1] = 0$$

D'où :

- $y_i (\langle x_i, w \rangle + b) \neq 1 \xrightarrow{\text{implique que}} \alpha_i = 0$ (la contrainte est inactive)

Ou bien

- $\alpha_i \neq 0 \xrightarrow{\text{implique}} y_i (\langle x_i, w \rangle + b) = 1$ c.-à-d. que le point est situé sur l'un des hyperplans canoniques (contrainte active).

Les seuls points pour lesquels les multiplicateurs de Lagrange ne s'annulent pas sont donc les points tels que $\langle x_i, w \rangle + b = \pm 1$, qui sont les points situés sur les hyperplans canoniques, ces points sont appelés vecteurs de support. En d'autres termes, seuls les vecteurs de support participent à la construction de l'hyperplan optimal ($\alpha_i \neq 0$).

La deuxième remarque découle de la première. Un nombre restreint de points participe à la construction de l'hyperplan, les autres points ne participent pas à sa construction. Donc l'agrandissement de l'ensemble de données à moins d'influence que dans autres méthodes où tous les points participent à la solution. En particulier, le fait d'ajouter des points à l'ensemble de données qui ne sont pas des vecteurs supports n'a aucune influence sur la solution finale.

4.2.2.2. Principe des données non linéairement séparables

Le classificateur à marge maximale que nous venons de présenter, permet d'obtenir de très bons résultats lorsque les données sont linéairement séparables. L'intérêt principal d'un tel classificateur réside dans le fait qu'on contrôle facilement la capacité et donc le pouvoir de généralisation. Naturellement, la majorité des problèmes sont non linéairement séparables. Géométriquement, cela reviendrait à avoir une courbe qui marquerait la frontière entre les points positifs et négatifs. L'inconvénient de ce genre de méthode provient du fait que le nombre de paramètres à calculer est très élevé. L'idée retenue dans SVM va dans un autre sens, on tente de trouver une transformation de l'espace d'entrée vers un autre

espace de dimension supérieure à celle de l'espace d'entrée, dans lequel les données deviennent linéairement séparables. Ce nouvel espace est appelé « **espace de Redescription** ». La figure 6.4 donne une représentation imagée d'une telle transformation. Nous pouvons alors appliquer la méthode à marge maximale dans l'espace de redescription.

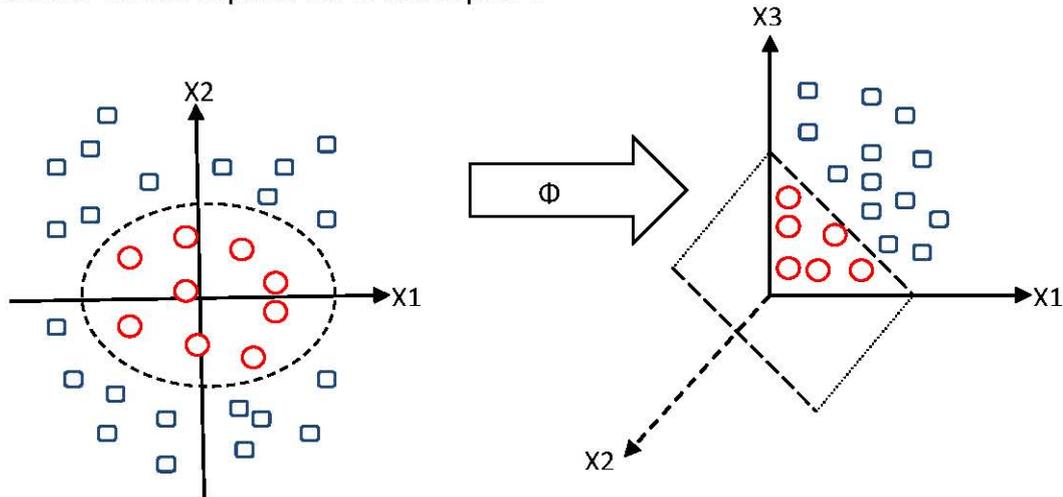


Figure 4.6 : Une transformation rend les données linéairement séparables

Donc on applique aux vecteurs d'entrée x_i une transformation non-linéaire Φ .

$$(x_1, x_2, \dots, x_l) \xrightarrow{\Phi} (\Phi(x_1), \Phi(x_2), \dots, \Phi(x_l))$$

Le problème d'optimisation se transcrit dans ce cas par :

$$\left\{ \begin{array}{l} \max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle \Phi(x_i), \Phi(x_j) \rangle \\ \text{sous les contraintes} \quad \left\{ \begin{array}{l} \sum_{i=1}^l \alpha_i y_i = 0 \\ \alpha_i \geq 0 \quad i = 1, \dots, l \end{array} \right. \end{array} \right. \quad (4.17)$$

Où $\langle \cdot, \cdot \rangle$ dénote le produit scalaire dans le nouvel espace.

L'équation de l'hyperplan séparateur dans le nouvel espace devient :

$$\sum_{i=1}^l y_i \alpha_i \langle \Phi(x_i), \Phi(x) \rangle + b = 0 \quad (4.18)$$

Le problème de cette formulation est qu'elle contient un produit scalaire entre vecteurs dans l'espace de redescription, ce qui est coûteux en termes de calculs lorsque la dimension de l'espace de redescription augmente. Suivant la théorie de Hilbert, une famille de fonctions K permet l'écriture suivante :

$$K(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle$$

Le problème d'optimisation devient dans ce cas :

$$\left\{ \begin{array}{l} \max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) \\ \text{sous les contraintes} \quad \left\{ \begin{array}{l} \sum_{i=1}^l \alpha_i y_i = 0 \\ \alpha_i \geq 0 \quad i = 1, \dots, l \end{array} \right. \end{array} \right. \quad (4.19)$$

D'où l'expression de l'hyperplan séparateur en fonction de la fonction noyau :

$$\sum_{i=1}^l y_i \alpha_i K(x_i, x) + b = 0 \quad (4.20)$$

L'intérêt des fonctions noyau se résume par les points suivant :

- Le calcul se fait dans l'espace d'entrée, ceci est beaucoup moins coûteux qu'un produit scalaire dans un espace de grande dimension.
- La dimension de l'espace de redescription n'a pas besoin d'être connue.
- La transformation Φ n'a pas besoin d'être connue, seule la fonction noyau intervient dans les calculs.

Seules les fonctions qui satisfont la condition de Mercer, sont dites des fonctions noyau [73].

Le noyau linéaire : $k(x, y) = x \cdot y$

Le noyau polynomial de degré δ : $k(x, y) = (x \cdot y)^\delta$

Le noyau radial (RBF- Radial basis function) exponentiel ou bien gaussien :

$$k(x, y) = \exp \left(-\frac{\|x-y\|^2}{2\sigma^2} \right)$$

σ : La largeur de la gaussienne.

Il est possible de composer des nouveaux noyaux en utilisant des noyaux existants. En prenant $K_1(\cdot)$ et $K_2(\cdot)$ des fonctions satisfaisant la condition de Mercer, $\alpha \in R^+$ et B une matrice définie positive, alors les fonctions suivantes sont des noyaux :

- $K(x, z) = K_1(x, z) + K_2(x, z)$.
- $K(x, z) = \alpha K_1(x, z)$.
- $K(x, z) = K_1(x, z) K_2(x, z)$.
- $K_2(x, z) = x^T B z$.

Il reste cependant un problème : nous avons toujours conservé l'hypothèse que les données sont linéairement séparables, soit dans l'espace d'entrée soit dans l'espace de redescription (de dimension supérieure). La plupart du temps, les données comportent du bruit. On pourrait trouver un espace de redescription induit par un noyau qui rendrait les données linéairement séparables. Cependant, cela reviendrait à apprendre le bruit des données.

Au lieu de cela, il paraît plus raisonnable d'admettre que certains points (supposés bruités) soient mal classés par notre classificateur, en ne laissant que peu de points mal classés de chaque côté de ce classificateur. Cette notion introduit à son tour un nouveau paramètre sous la forme d'une constante C qu'il faut donc aussi l'optimiser.

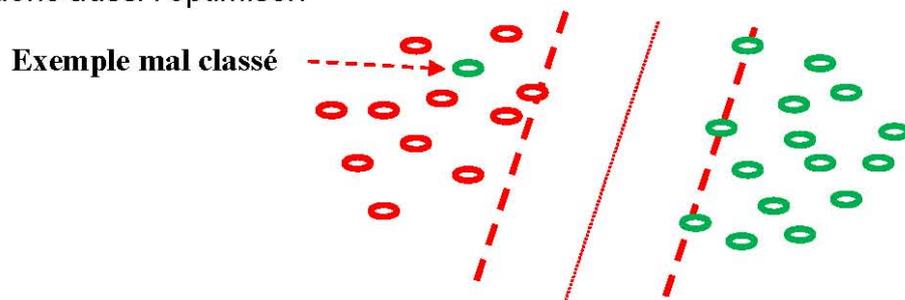


Figure 4.7 : Cas de données non séparables

Du point de vue de notre problème primal, cela revient à relaxer la contrainte imposant que tous les points soient bien classés.

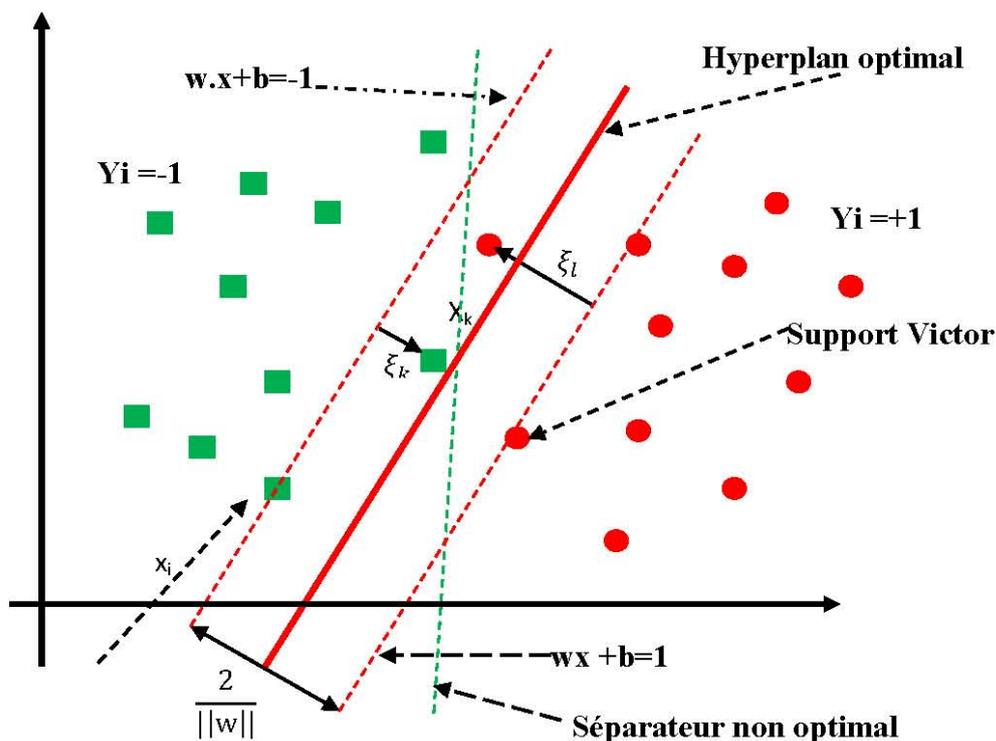


Figure 4.8 : Compromis entre marge maximale et bruit

La figure 4.8 montre que les SVMs réalisent un compromis entre la meilleure marge et les erreurs.

Donc lorsque les données ne sont pas séparables les contraintes de (3.11) sont relâchées pour permettre des erreurs (bruit), cela en introduisant des variables de relâchement ξ_i pour chaque contrainte i .

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad \forall i = 1 \dots l$$

$$\xi_i \geq 0 \quad \forall i = 1 \dots l$$

Pour contrôler le compromis entre marge et point biens classés, on va intégrer une constante C dans la fonction objective pour contrôler la largeur de la marge :

$$\left\{ \begin{array}{l} \text{minimiser} \\ \text{sous les contraintes} \end{array} \right. \quad \left\{ \begin{array}{l} \frac{\|w\|^2}{2} + c \sum_{i=1}^l \xi_i \\ y_i(w \cdot x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \quad i = 1, \dots, l \end{array} \right.$$

C : est un paramètre choisi par l'utilisateur, plus il est grand plus le nombre de points mal classés est petit.

Comme précédemment la formulation lagrangienne s'écrit de la manière suivante :

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i [y_i(w \cdot x_i + b) - 1 + \xi_i] - \sum_{i=1}^l \beta_i \xi_i \quad (4.21)$$

Les dérivées de L par rapport à ω , b et ξ_i donnent :

$$\frac{\partial L(\omega, b, \xi, \alpha, \beta)}{\partial \omega} = 0 \quad \xrightarrow{\text{Conduit à}} \quad y = \sum_{i=1}^l \alpha_i y_i x_i \quad (4.22)$$

$$\frac{\partial L(\omega, b, \xi, \alpha, \beta)}{\partial b} = 0 \quad \xrightarrow{\text{conduit à}} \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (4.23)$$

$$\frac{\partial L(\omega, b, \xi, \alpha, \beta)}{\partial \xi_i} = 0 \quad \xrightarrow{\text{conduit à}} \quad C - \alpha_i - \beta_i = 0 \quad (4.24)$$

Avec $\alpha_i \geq 0$ et $\beta_i \geq 0$

En substituant (4.22) et (4.23) dans (4.24) l'expression de L devient :

$$L(w, b, \alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (4.25)$$

(4.25) doit être maximiser par rapport à α et β , β n'apparaît pas dans (4.25) donc maximisons (4.25) par rapport à α et qu'il existe β qui vérifie (4.24).

$$(3.24) \Rightarrow C - \alpha_i - \beta_i = 0 \Rightarrow C - \alpha_i = \beta_i$$

Comme $\beta_i \geq 0$ donc $C - \alpha_i \geq 0 \xrightarrow{\text{implique}} \alpha_i \leq C$.

Donc le problème d'optimisation quadratique sera :

$$\left\{ \begin{array}{l} \max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \\ \text{sous les contraintes} \left\{ \begin{array}{l} \sum_{i=1}^l \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C \quad i = 1, \dots, l \end{array} \right. \end{array} \right. \quad (4.26)$$

Il existe dans ce cas trois statuts différents pour le point x_i en regardant sa variable duale α_i :

- $\alpha_i = 0$: le point est bien classé et n'est pas sur un des deux hyperplans canoniques. On peut dire que le point est un non vecteur de support.
- $0 < \alpha_i < C$: le point est bien classé et se trouve sur un des hyperplans canoniques. Il s'agit donc d'un vecteur de support.
- $\alpha_i = C$: le point est mal classé.

L'équation de l'hyperplan reste la même :

$$\sum_{i=1}^l y_i \alpha_i \langle x_i, x \rangle + b = 0 \quad (4.27)$$

Dans ce cas on appelle classificateur par classificateur à marge molle. Donc pour le classificateur à marge molle il faut choisir le paramètre C qui contrôle en fait le nombre de points mal classés, il est à noter que l'ensemble des points pour lesquels α_i est différent de zéro inclus non seulement les « points de support » habituels sur la marge, mais aussi les points qui sont du mauvais côté de leur hyperplan. Pour ceux-ci on obtiendra une valeur de $\alpha_i = C$, i.e. si on prenait une valeur de C plus grande, ces points pourraient devenir des points correctement classifiés ou des points sur la marge.

Avec $C \rightarrow \infty$ on a une contrainte dure : tous les points doivent être bien classés. En général une meilleure solution est obtenue avec un $C > 0$ et fini. C'est un paramètre de régularisation.

4.3. Extraction des paramètres de Gabor

Les filtres de GABOR ou les filtres gaussiens constituent une classe particulière des filtres linéaires, ils sont bien adaptés à l'analyse d'images texturées de par leur compromis optimal de localisation spatiale et fréquentielle.

La fonction de Gabor bidimensionnelle dans le domaine spatial, se définit comme étant la somme de deux fonctions sinusoïdales l'une paire et réelle et l'autre impaire et imaginaire, modulée par une gaussienne.

Le filtre de Gabor permet donc de détecter la présence locale d'une fréquence correspondant à celle de sa sinusoïde.

La fonction de Gabor se donne alors sous la forme de [74]:

$$h(x, y) = g(x', y') \times \exp(2\pi j(U_x + V_y)) \quad (4.28)$$

Avec :

$$g(x', y') = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left\{-\frac{1}{2}\left[\left(\frac{x}{\sigma_x}\right)^2 + \left(\frac{y}{\sigma_y}\right)^2\right]\right\} \quad (4.29)$$

Où : σ_x, σ_y : sont des constantes d'espace de l'enveloppe gaussienne qui déterminent l'étendue de l'onde suivant les axes x et y respectivement. (ou écarts-types de la modulation Gaussienne).

Les coordonnées (x', y') se déduisent de (x, y) par :

$$(x', y') = (x \cos \theta + y \sin \theta, -x \sin \theta + y \cos \theta) \quad (4.30)$$

Où :

L'angle de rotation θ de (x', y') par rapport à (x, y) donne l'orientation de l'enveloppe gaussienne dans le domaine spatial.

La réponse impulsionnelle d'un filtre de Gabor dans le domaine de Fourier est donnée par l'expression suivante:

$$H(u, v) = \exp \left[-2\pi^2 \left((\sigma_x (u - U))^2 + (\sigma_y (v - V))^2 \right) \right] \quad (4.31)$$

où:

(u,v): paramètres de positionnement fréquentiel.

et que [(u-U)', (v- V)'] est obtenu par rotation du point [(u-U), (v-V)] par le même angle θ .

H(u, v) est une Gaussienne passe-bande, sa fréquence centrale est donnée par son module :

$$F = \sqrt{U^2 + V^2} \quad (4.32)$$

Et son orientation
$$\varphi = \operatorname{arctg} \left(\frac{V}{U} \right) \quad (4.33)$$

Présentés ainsi, les filtres de GABOR jouissent de quatre degrés de liberté qui permettent d'extraire une partie de l'information spectrale de l'image, Il s'agit de :

- la taille du filtre.
- la fréquence fondamentale **F**.
- l'étendu spatial de l'enveloppe (écarts types σ_x, σ_y).
- l'orientation θ .

Les filtres de Gabor sont une classe particulière des filtres, ceux sont des filtres orientés. Ils permettent de mettre en évidence des textures ainsi que des zones homogènes d'une image. Grâce à la forme gaussienne des filtres, les enveloppes des images filtrées apportent une information spectrale locale en chaque pixel. De plus, elle renseigne sur le contenu énergétique de l'image dans la direction du filtre choisie.

Chaque filtre a une partie réelle et imaginaire qui sont stockés dans des masques de taille $M \times M$ nommés respectivement $R_{f_p q}$ et $I_{f_p q}$, où $f_p = 1, \dots, S$, dénotes l'échèle de la fréquence, et $q = 1, \dots, L$, dénotes l'orientation.

L'implantation du filtre de Gabor peut se réaliser par multiplication dans le domaine de Fourier, ou par convolution dans le domaine spatial par la formule suivante :

$$G_{pq} = [(W \circledast R_{f_{pq}})^2 + (W \circledast I_{f_{pq}})^2]^{1/2} \quad (4.34)$$

Où \circledast dénote l'opération de convolution à deux dimensions.

Le résultat d'un filtrage par le filtre de Gabor à différentes fréquences et différentes orientations, sera un vecteur sur chaque point de l'image où chaque élément du vecteur correspond à un élément de la banque de filtres appliqués. Pour chaque point de l'image (x, y) à traiter, une banque de Gabor sera extraite [75] et [76].

Cette banque permet d'extraire un renseignement sur l'environnement immédiat de chaque pixel, et donne ainsi pour chaque point un vecteur caractérisant la texture à laquelle il appartient comme le montre la figure suivante :

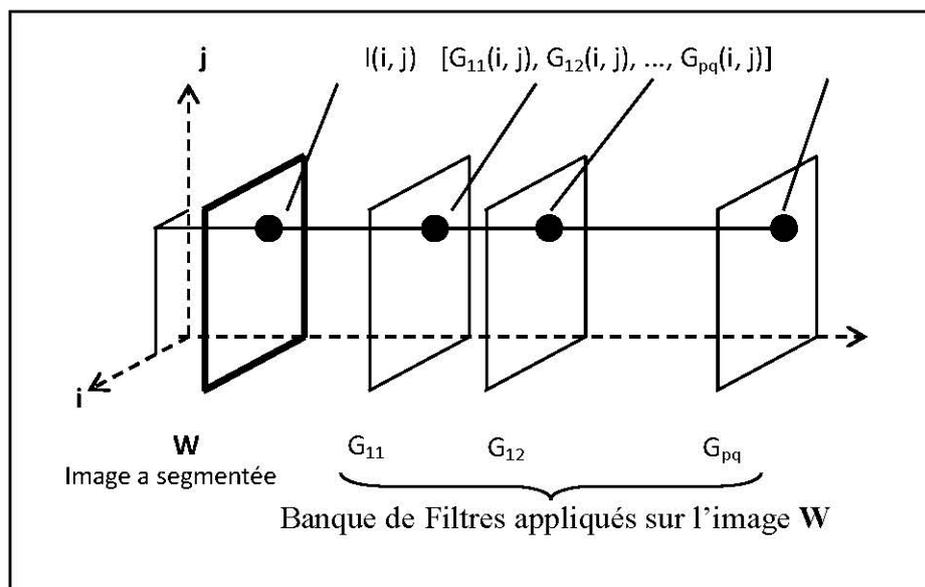


Figure 4.9 Vecteur d'attributs pour chaque pixel de l'image

4.4. Résultats et discussions

En premier temps nous allons tester les paramètres de Gabor par rapport à celle d'ondelettes. Nous allons suivre le même schéma de segmentation du chapitre 3 à savoir l'utilisation de l'ACP pour l'optimisation des paramètres et le FCMI pour la classification de chaque pixel. Afin de comparer les résultats des deux chapitres, nous allons tester les approches de segmentation sur les mêmes images TOFD.

Après plusieurs tests nous avons opté pour une banque qui contient 64 filtres de Gabor dont : $S = 8$ échelles de fréquences, et $L = 8$ orientations, avec la taille du filtre $M = 27$ et $\sigma_x = \sigma_y = \frac{M-1}{2}$.

Un exemple de tracé de filtre de Gabor, pris de la banque choisi est donné par la figure 4.10.

L'implémentation de l'ACP a optimisé et réduit de 50% la taille des vecteurs.

Pour l'étape de classification par l'algorithme FCMI, les meilleurs résultats sont obtenus avec les paramètres suivants :

- $\beta = 1.01$ (le degré de floue).
- $\alpha = 10^3$ (le seuil de convergence qui permet la minimisation itérative des erreurs).

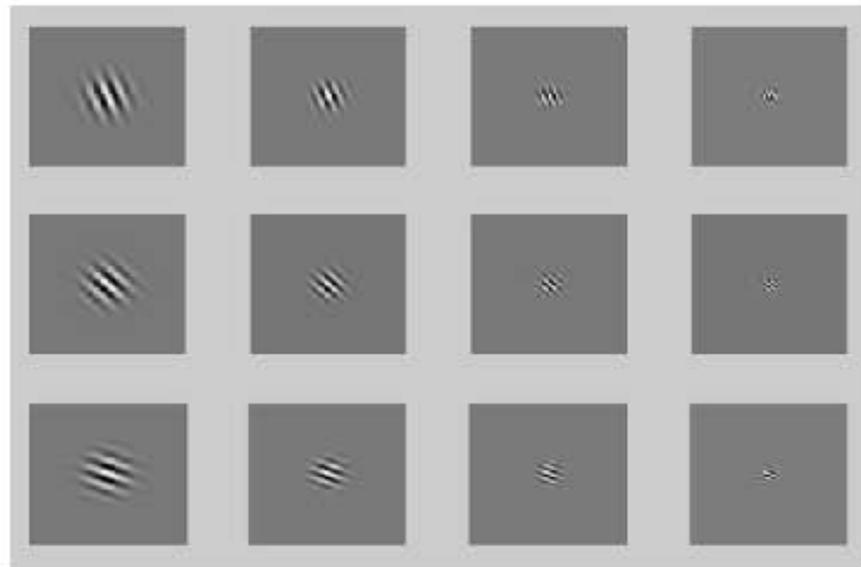


Figure 4.10 : Exemple de la banque de filtres de Gabor utilisée

Les résultats obtenus sont illustrés par les images (figure 4.11b, 4.11c) et (figure 4.12b, 4.12c). Il est à rappeler que l'objectif de la segmentation souhaitée,

est de détecter la position des deux bords du défaut afin de le dimensionner par la suite.

Les résultats que nous avons obtenus, montrent l'élimination des différentes arcs de paraboles et ne laissent que deux paraboles (figure 4.11 c) caractérisant chaque bord du défaut. A travers ces résultats, nous estimons que les deux algorithmes développés donnent des résultats satisfaisants. Nous remarquons une bonne détection des défauts par les deux algorithmes. L'utilisation de ces résultats pour un dimensionnement défauts est possible, ceci permet de conclure que l'algorithme par les paramètres d'ondelettes donne de meilleurs résultats. En effet, les images 4.11c et 4.12c présentent des lignes très fines caractérisées les bords du défaut. Il faut noter que les paramètres de Gabor offrent une simplicité d'implémentation qui résulte une nette rapidité dans les calculs par rapport aux paramètres d'ondelettes.

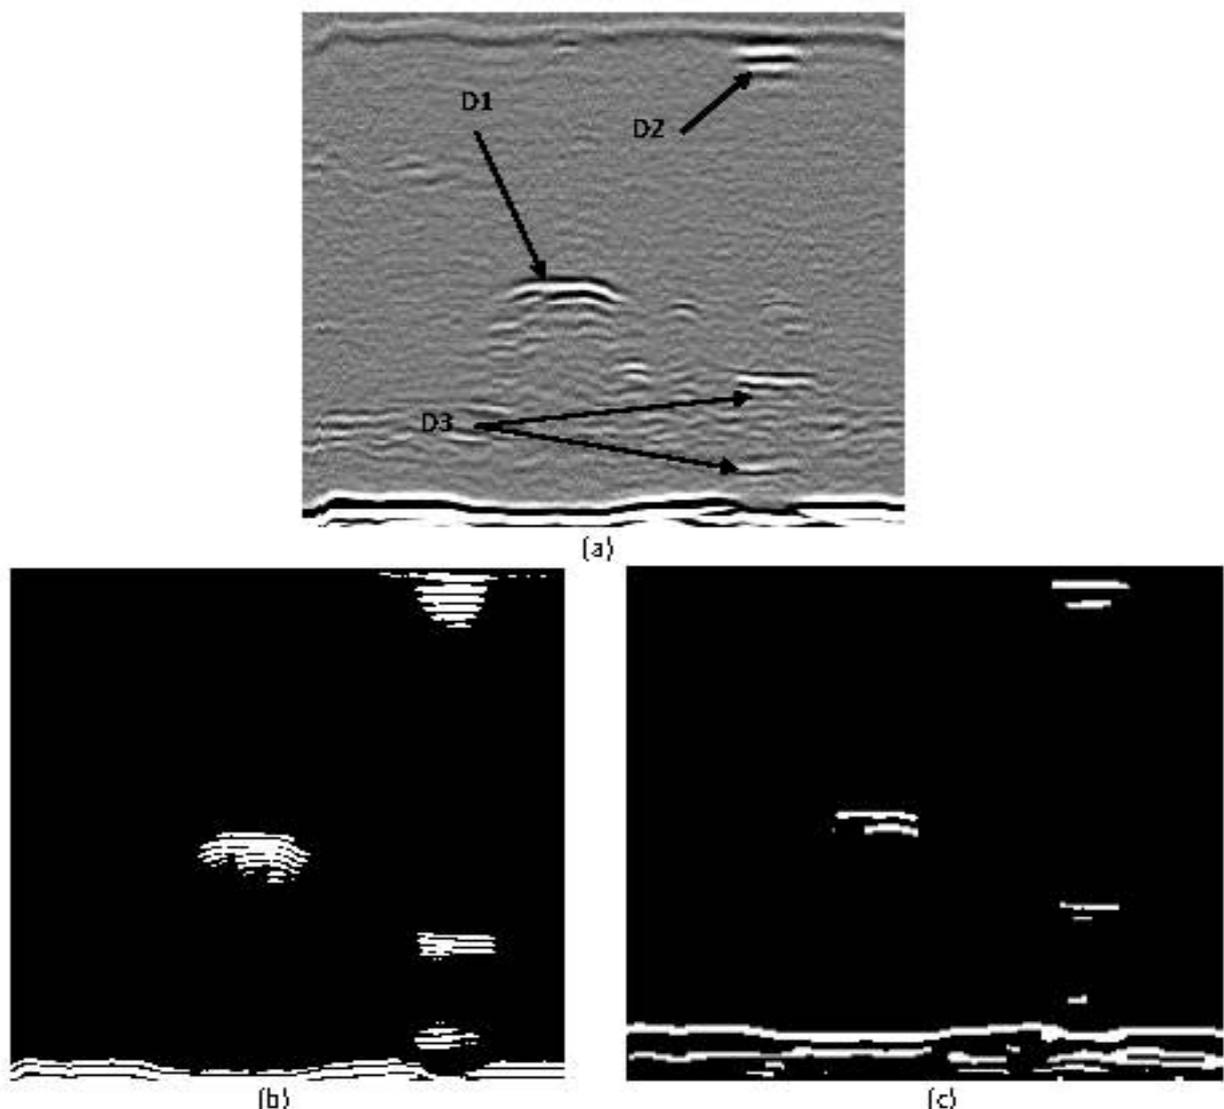
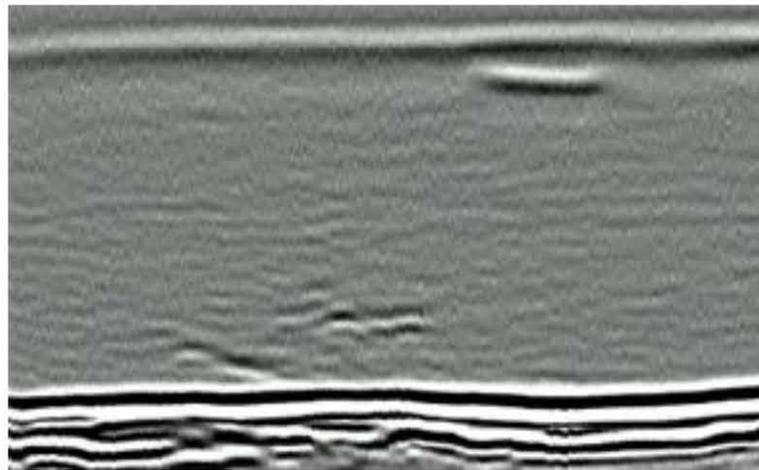


Figure 4.11: (a) Image TOFD industrielle, (b) Image segmentée avec les paramètres de Gabor, (c) Image segmentée avec les paramètres d'ondelettes



(a)



(b)



(c)

Figure 4.12: (a) Image TOFD industrielle, (b) Image segmentée avec les paramètres de Gabor, (c) Image segmentée avec les paramètres d'ondelettes

Après avoir comparé les paramètres de Gabor avec ceux des d'ondelettes, implémentons les SVMs afin de procéder à la classification.

La phase d'apprentissage est schématisée par la figure 4.13. Nous avons utilisé l'image zoom sur un défaut comme base d'apprentissage des SVMs. Tel que pour la première classe, nous sélectionnons 20 pixels dans la zone de défaut et pour la deuxième classe, 20 pixels de la zone saine.

Après plusieurs tests, les meilleurs résultats sont obtenus avec la fonction noyau polynomiale et polynôme homogène de degré entre 4 et 9 et $C=100$.

La segmentation de l'image TOFD est donnée par la phase test comme le montre le schéma synoptique de la figure 4.14. Nous procédons au chargement de l'image à segmenter, puis au filtrage en utilisant la même banque de filtres de Gabor utilisée dans la phase d'apprentissage. Ensuite, on extrait pour chaque pixel le vecteur d'attributs et on le multiplie par la matrice de transformation de l'ACP pour obtenir un nouveau vecteur optimisé et prêt pour la classification. Finalement, la segmentation est donnée par le calcul de la distance entre le nouveau vecteur d'attributs et les données d'apprentissage afin de lui affecter une classe comme défaut ou non défaut.

Le résultat obtenu est illustré par l'image (figure 4.15b). Nous notons que l'approche développée à ce stade ne donne pas un résultat satisfaisant où on constate la détection des défauts plus des erreurs de classification qui ne sont pas forcément du bruit de structure. On peut améliorer ce résultat par l'augmentation de nombre de pixel dans la phase d'apprentissage. En effet, en utilisant 100 pixels le résultat est nettement amélioré comme le montre l'image (figure 4.15c). Ce dernier est encourageant pour une éventuelle application à l'échelle industrielle. Reste à augmenter la base d'apprentissage pour avoir à l'avenir des résultats de détection fiable et offre une possibilité du dimensionnement.

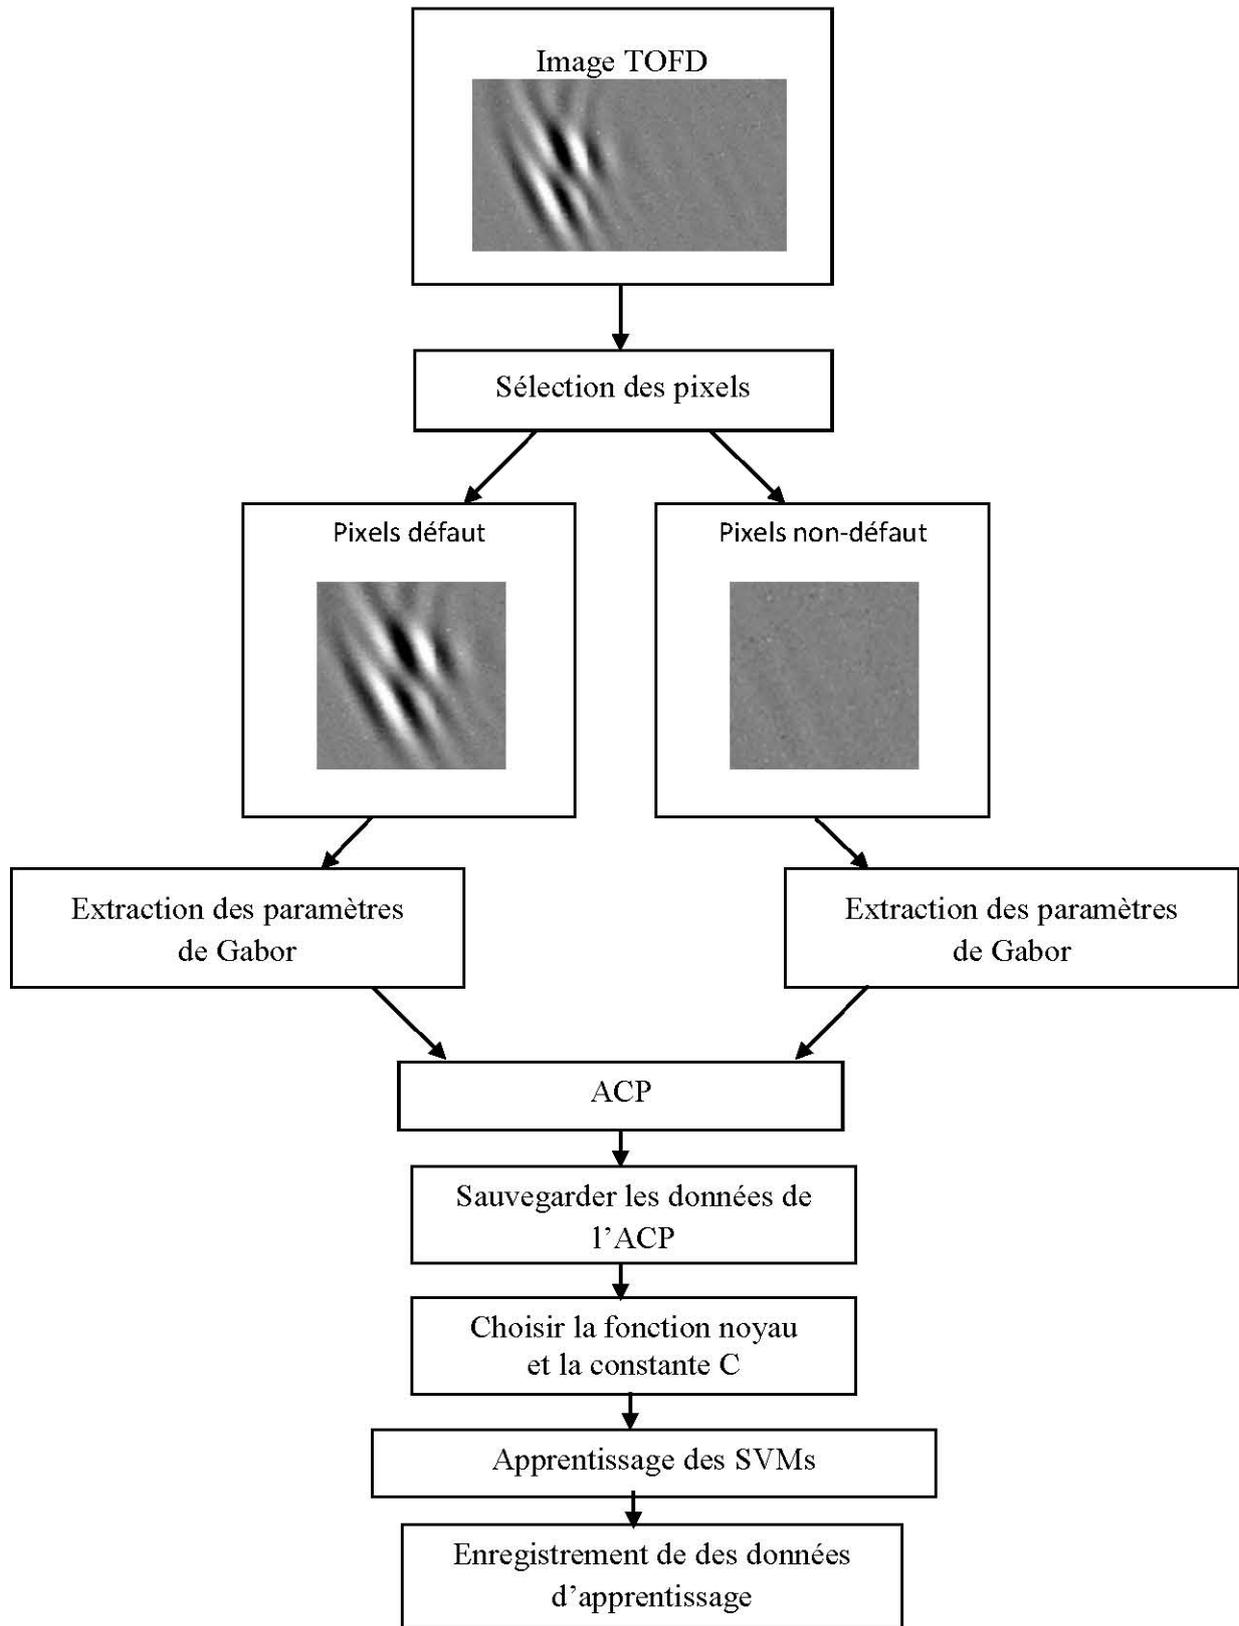


Figure 4.13 : Schéma synoptique de la phase d'apprentissage

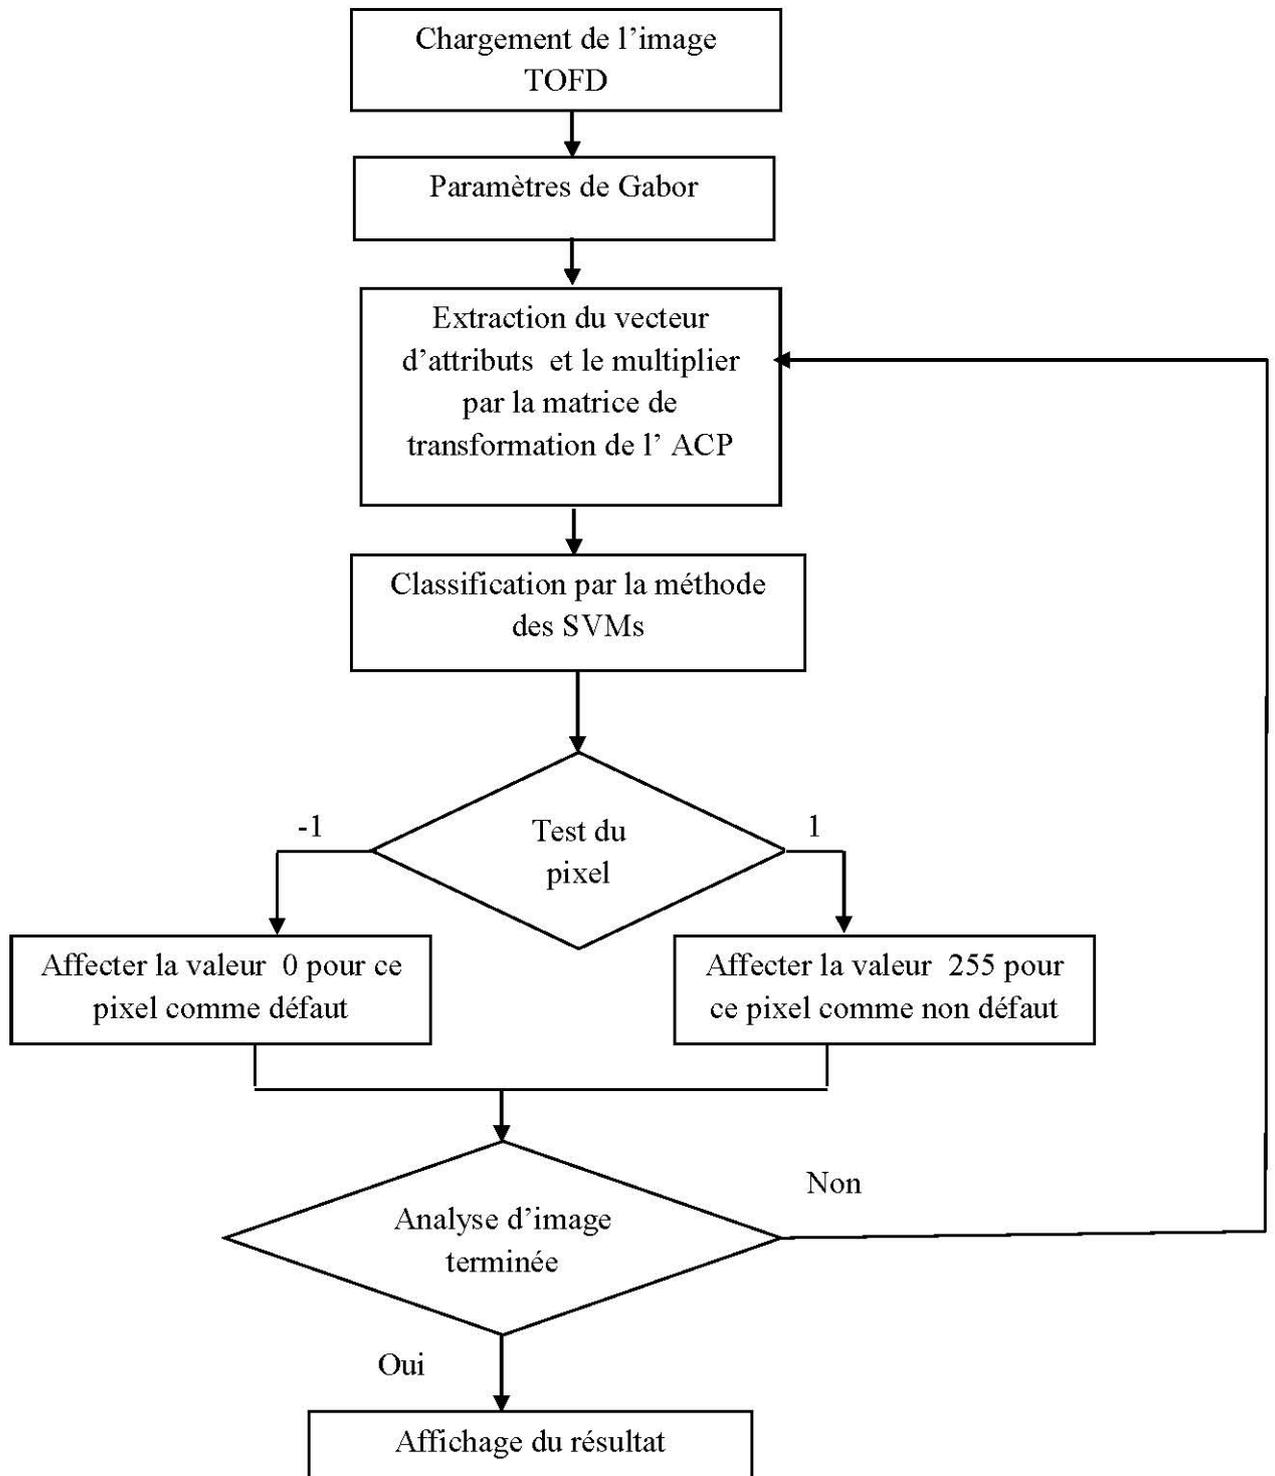
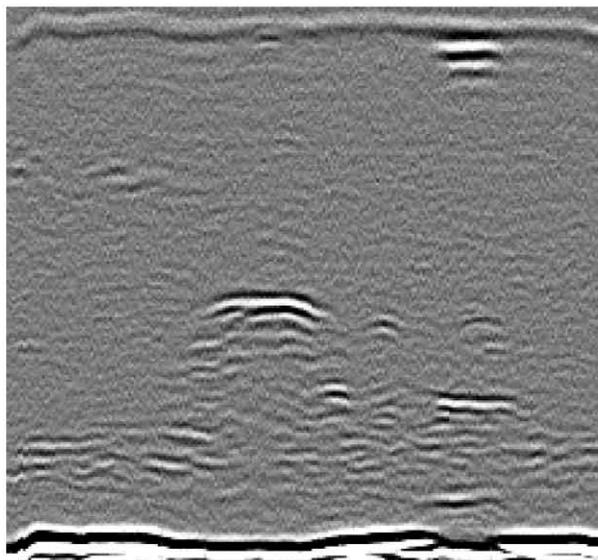
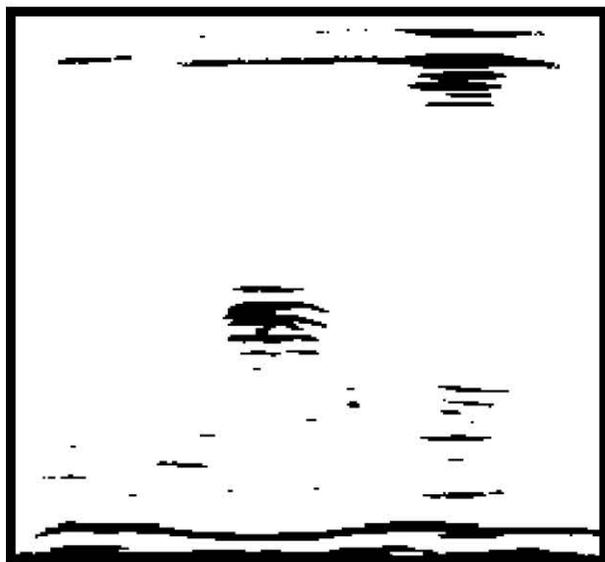


Figure 4.14 : Schéma synoptique de la phase test



(a)



(b)



(c)

Figure 4.15: (a) Image TOFD industrielle, (b) Image segmentée avec 40 points d'apprentissage, (c) Image segmentée avec 100 points d'apprentissage

4.5. Conclusion

Dans ce chapitre, nous avons développé une approche supervisée pour la segmentation des images TOFD. Cette approche est basée sur la classification de chaque pixel comme défaut ou non défaut par les SVMs. Pour la caractérisation de ces derniers nous avons utilisé une banque de filtre de Gabor. En premier temps, nous les avons comparés avec les paramètres d'ondelettes. Nous avons remarqué une bonne détection des défauts par les deux algorithmes. L'utilisation de ces résultats pour un dimensionnement des défauts est possible, et permet de conclure que l'algorithme par les paramètres d'ondelettes donne de meilleurs résultats. Ces résultats sont publiés dans la revue 'J Nondestruct Eval' [77]. Il faut noter que les paramètres de Gabor offrent une simplicité d'implémentation qui résulte une nette rapidité dans les calculs par rapport aux paramètres d'ondelettes.

L'implémentation des SVMs pour la classification a montré des limites en fonction de la taille de la base d'apprentissage. La formation d'une grande base d'apprentissage avec plusieurs types de défauts rend la segmentation plus fiable en termes de détection.

Nous estimons que la méthode proposée dans ce chapitre est fiable et rapide. La combinaison de ces deux paramètres permet de se doter d'un moyen robuste et efficace dans la détection des défauts à partir d'une image ultrasonore de type TOFD dans le contrôle non destructif d'un matériau.

CONCLUSION

Dans ce travail, nous avons discuté des bases théoriques de la TOFD. Nous avons montré que cette technique se présente comme une alternative aux techniques classiques de contrôle non destructif par ultrasons, particulièrement dans son pouvoir de détection des défauts, de leurs localisations et de leurs dimensionnements.

Les images TOFD réalisées dans nos expérimentations par contact sont de faible résolution. La difficulté de l'implémentation d'algorithmes d'analyse de ces images impossible, nous a conduits à importer des images TOFD réalisées à l'échelle industrielle avec des défauts réels détectés et localisés par des inspecteurs niveau II. L'observation de près d'une image zoomée sur un défaut a révélé qu'on peut compter sur l'information texturale d'un défaut pour la segmentation et la détection des défauts. Ceci nous a servi d'idée de base dans nos investigations.

Nous avons présenté les méthodes d'analyse des textures les plus courantes. Nous avons vu que parmi ces méthodes les quatorze paramètres d'Haralick issues des matrices de cooccurrence ou bien cinq paramètres des longueurs de plage peuvent donner une bonne description de la texture. Elles sont cependant assez lourdes en termes de calculs. Les méthodes d'ordre un sont beaucoup plus rapides. Cependant elles ne décrivent pas les relations spatiales entre les pixels. De plus, nous avons utilisé d'autres méthodes venant du monde du traitement du signal qui sont bien adaptées à l'analyse de textures et qui correspondent à l'analyse temps-fréquence et temps-échelles tels que les filtres de Gabor et les ondelettes.

Nous avons ensuite présenté deux procédures de segmentation de l'image TOFD pour la détection de défauts basées sur la caractérisation texturale par décomposition en ondelettes.

Dans la phase finale pour chaque procédure, nous avons utilisé l'algorithme de FCMI pour classer chaque pixel comme «défaut» ou «non-défaut» et cette phase se traduira par une image segmentée. Cet algorithme de classification opère sans apprentissage avec cependant un temps de calcul assez long.

Cependant, l'utilisation de l'ACP nous a permis de réduire la taille des vecteurs d'attributs et de l'optimiser pour avoir plus de précision.

Les résultats obtenus par la première approche proposée sont satisfaisants. Nous remarquons une bonne détection des défauts et une élimination des échos issus du bruit de structure.

La deuxième approche basée sur la décomposition intégrale de l'image ne donne pas le même résultat. Elle peut être améliorée pour être dédiée à la segmentation des autres types de textures.

Notre contribution en termes de temps de calcul est basée sur une approche supervisée pour la segmentation des images TOFD. Cette approche est basée sur la classification de chaque pixel comme défaut ou non défaut par les SVMs. Pour la caractérisation de ces derniers, nous avons utilisé une banque de filtre de Gabor. En premier temps, nous les avons comparés avec les paramètres d'ondelettes. Nous avons remarqué une bonne détection des défauts par les deux algorithmes. L'utilisation de ces résultats pour un dimensionnement des défauts possible, permet de conclure que l'algorithme par les paramètres d'ondelettes donne de meilleurs résultats. Nous avons remarqué que les paramètres de Gabor offrent une simplicité d'implémentation avec une nette rapidité dans les calculs par rapport aux paramètres ondelettes.

L'implémentation des SVMs pour la classification a montré des limites en fonction de la taille de la base d'apprentissage. La formation d'une grande base d'apprentissage avec plusieurs types de défauts rend la segmentation plus fiable en termes de détection.

Nous estimons que la méthode proposée est fiable et rapide. La combinaison de ces deux paramètres permet de se doter d'un moyen robuste et efficace dans la détection des défauts à partir d'une image ultrasonore de type TOFD dans le contrôle non destructif d'un matériau.

Néanmoins, la méthode TOFD a un problème de résolution dans la mesure du temps d'arrivée des ondes diffractées par les bords du défaut, notamment les défauts proches de la face avant et de la face arrière de la pièce, nous envisageons, comme perspectives, de l'associer avec les méthodes SAFT en vue de focaliser les ondes et d'améliorer la résolution axiale et latérale.

REFERENCES

1. Charlesworth, J.P., and Temple, J.A.G., "Engineering Applications of Ultrasonic Time-of-Flight Diffraction", Second Edition, Research Studies Press LTD, Baldock, Hertfordshire, England, (2001), 254 p.
2. Mix, P.E., "Introduction to Nondestructive Testing: A Training Guide", Second Edition, John Wiley & Sons, Inc., (June 2005), 712 p.
3. Dubé, N., "Advances in Phased Array Ultrasonic Technology Applications", Olympus NDT, Waltham, Massachusetts, USA, (2007), 512 p.
4. Rose, J.L., "Ultrasonic Waves in Solid Media", Cambridge University Press, London, (September 2004), 476 p.
5. Gordon, J.E., "The New Science of Strong Materials: or, Why you don't Fall Through the Floor", Second Edition, Penguin Books, Harmondsworth, UK, (1976), 287 p.
6. Doyle, P.A. and Scala, C.M., "Crack Depth Measurement by Ultrasonics: A Review", Ultrasonics, Elsevier, V.16, n° 4, (July 1978), 164 - 170.
7. Cook, D., "Crack Depth Measurement with Surface Waves", British Acoustical Society Proceedings, Spring Meeting, University of Loughborough, (April 1972).
8. Silk, M.G., "Accurate Techniques for Defect Sizing in Pressurized Components", Conference on Periodic Inspection of Pressurized Components, V. 11, n° 4, Institution of Mechanical Engineers, London, UK, (May 1979), 155 - 162.
9. Silk, M.G., "A Separable Probe Technique for Accurate Crack Sizing using Ultrasonic Diffraction", Ultrasonics International 79, Proceedings of a conference, held at Graz, Austria, IPC Science and Technology Press, Guildford, Surrey. 3, (May 1979), 415 - 426.
10. Silk, M.G., "Defect Detection and Sizing in Metals using Ultrasound", International Materials Reviews, V. 27, n°1, (January 1982), 28 - 50.
11. Silk, M.G., "The Fundamental Accuracy of Ultrasonic Time-of-Flight Testing Techniques", Conference on Periodic Inspection of Pressurized Components, London, (September 1982), 125 - 133.
12. Silk, M.G., "Ultrasonic Developments in the UK for RPV Weldments", International Seminar on Advances in Non-Destructive Examination for Structural Integrity, Applied Science Publishers, V. 14, n°20, Essex, UK, (1982), 101 - 116.

13. Silk, M.G., "The Use of Diffraction-based Time-of-Flight Measurements to Locate and Size Defects", *British Journal of NDT*, V. 26, n°4, (1984), 208 - 213.
14. Silk, M.G. and Lidington, B.H., "Defect Sizing Using an Ultrasonic Time Delay Approach", *British Journal of NDT*, V. 17, n° 2, (March 1975), 33 - 36.
15. Silk, M.G., Lidington, B.H. and Hammond, G.F., "A Time Domain Approach to Crack Location and Sizing in Austenitic Welds", *British Journal of NDT*, V. 22, n°2, (March 1980), 55 - 61.
16. Haines, N.F., Langston, D.B., Green, A.J. and Wilson, R., "Assessment of the Reliability of Ultrasonic Inspection Methods", *Conference on Periodic Inspection of Pressurized Components*, V. 14, n°17, Institution of Mechanical Engineers, London, UK, (1982), 239 - 255.
17. Harker, A.H., "Numerical Modelling of the Scattering of Elastic Waves in Plates", *Journal of NDE*, V. 4, n° 2, (1984), 89 - 106.
18. Miller, J.J., "Ultrasonic Measurement of Crack Depth in Thick-Walled Cylinders", Report n°. AD707760 (WVT-7017), U.S. Government, (1970).
19. Lidington, B.H., Silk, M.G., Montgomery, P. and Hammond, G.F., "Ultrasonic Measurements of the Depth of Fatigue Cracks", *British Journal of NDT*, V.18, n°6, (1976), 165 - 170.
20. Spies, M., Rieder H., Dillhöfer, I., Schmitz V. and Müller, W., "Synthetic Aperture Focusing and Time-of-Flight Diffraction Ultrasonic Imaging-Past and Present", *Journal of NDE*, V. 31, n°4, (December 2012), 310 - 323,
21. Prager, J., Kitze, J., Acheroy, C., Brackrock, D., Brekow, G. and Kreutzbruck, M., "SAFT and TOFD - A Comparative Study of Two Defect Sizing Techniques on a Reactor Pressure Vessel Mock-up", *Journal of NDE*, V. 32, n°1, (March 2013), 1 - 13.
22. Sinclair, A.N., Fortin, J., Shakibi, B., Honarvar, F., Jastrzebski, M. and Moles, M.D.C., "Enhancement of Ultrasonic Images for Sizing of Defects by Time-of-Flight Diffraction", *NDT & E International*, Elsevier, V. 43, n°3, (April 2010), 258 - 264.
23. Chen, H., Zuo, M.J., Wang, X., and Hoseini, M.R., "An Adaptive Morlet Wavelet Filter for Time-of-Flight Estimation in Ultrasonic Damage Assessment", *Measurement*, Elsevier, V. 43, n°4, (May 2010), 570 - 585.
24. Theresa Cenate, C. F., Sheela Rani, B. and Venkataraman, B., "Multi-scale Wavelet Algorithm based Noise Reduction in Ultrasonic Images at Elevated Temperatures", *IEEE International Conference on Recent Trends in Information Technology*, (2013), 382 - 386.

25. Petcher, P.A. and Dixon, S., "Parabola Detection Using Matched Filtering for Ultrasound B-scans", *Ultrasonics*, Elsevier, V. 52. N°1, (January 2012), 138 - 144.
26. Petcher, P.A. and Dixon, S., "A modified Hough Transform for Removal of Direct and Reflected Surface Waves From B-scans", *NDT & E International*, Elsevier, V. 44, n°2, (March 2011), 139 - 144.
27. Merazi-Meksen, T., Boudraa, M., and Boudraa, B., "Mathematical Morphology for TOFD Image Analysis and Automatic Crack Detection", *Ultrasonics*, Elsevier, V. 54, n°6, (August 2014), 1642 - 1648.
28. Merazi-Meksen, T., Boudraa, B., Draï, R. and Boudraa, M., "Automatic Crack Detection and Characterization During Ultrasonic Inspection", *Journal of NDE*, V. 29, n°3, (September 2010), 169 - 174.
29. Jin, W., Hao, L. and Zhong-chang, C., "Design of TOFD Receiving Filter On DSP Builder", *IEEE Far East Forum on Nondestructive Evaluation/Testing (FENDT)*, (2014), 1 - 4.
30. Wu Ying-yon, Gao Xiao-rong, Guo Jian-qiang, Wang Ze-yong, Zhao Quan-ke and Shen Yan, "Ultrasonic TOFD Image Registration Algorithm of Sub-pixel Accuracy Based on DFT", *IEEE Far East Forum on Nondestructive Evaluation/Testing (FENDT)*, (2014), 84 - 88.
31. Baskaran, G., Balasubramaniam, K. and Lakshmana Rao, C., "Shear-wave Time of Flight Diffraction (S-TOFD) technique", *NDT & E International*, Elsevier, V. 39, n°6, (September 2006), 458 - 467.
32. Mavromatis, S., "Analyse de Texture et Visualisation Scientifique", Thèse de doctorat, Université de la Méditerranée, (2001).
33. Julesz, B. and Bergen, J.R., "Human factors and behavioral science: Textons, the Fundamental Elements in Preattentive Vision and Perception of Textures", *Bell System Technical Journal*, V.62, n°6, (July-August 1983), 1619 - 1645.
34. Mirmehdi, M., Xie, X. and Suri, J., "Handbook of Texture Analysis", Imperial College Press, London, (2008), 407 p.
35. Kim, H.B. and Park, R.H., "Extracting Spatial Arrangement of Structural Textures Using Projection Information", *Pattern Recognition*, Elsevier, V. 25, n°3, (March 1992), 237 - 245.
36. Tomita, F., Shirai, Y. and Tsuji, S., "Description of Textures by a Structural Analysis", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, V. 4, n°2, (February 1982), 183 - 191.

37. Vilnrotter, F.M., Nevatia, R. and Price, K.E., "Structural Analysis of Natural Textures", IEEE Transactions on Pattern Analysis and Machine Intelligence, V. 8, n°1, (January 1986), 76 - 89.
38. Ferryanto, S., "A kolmogorov-Smirnov Type Statistic for Detecting Structural Changes of Textures", Pattern Recognition Letters, V.16, n°3, (March 1995), 247 - 256.
39. Gagalowicz, A., "A New Method for Texture Field Synthesis: Some Applications to the Study of Human Vision", IEEE Transactions on Pattern Analysis and Machine Intelligence, V. 3, n°5, (September 1981), 520 - 533.
40. Connors, R.W. and Harlow, C.A., "A Theoretical Comparison of Texture Algorithms", IEEE Transactions on Pattern Analysis and Machine Intelligence, V. 2, n°3, (April 1980), 204 - 222.
41. Haralick, R.M., "Statistical and Structural Approaches to Texture", Proceedings of IEEE, V. 67, n°5, (May 1979), 786 - 804.
42. Herlidou, S., "Caractérisation Tissulaire en Imagerie par Résonance Magnétique Nucléaire par l'Analyse de Texture : Etude du Tissu Musculaire et de Tumeurs Intracrâniennes", Thèse de doctorat, Université de Rennes 1, (1999).
43. Franklin, S.E., Wulder, M.A. and Gerylo, G.R., "Texture Analysis of Ikonos Panchromatic Data for Douglas-fir Forest Age Class Separability in British Columbia", International Journal of Remote Sensing, V. 22, n°13, (September 2001), 2627 - 2632.
44. Haralick, R.M., Shanmugam, K. and Dinstein, I., "Textural Features for Image Classification", IEEE Transactions on Systems, Man and Cybernetics, V. SMC-3, n°6, (November 1973), 610 - 621.
45. Galloway, M.M., "Texture Analysis Using Gray Level Run Lengths", Computer Graphics and Image Processing, V.4, n°2, (June 1975), 172 - 179.
46. Luo, J. and Savakis, A.E., "Self-supervised Texture Segmentation Using Complementary Types of Features", Pattern Recognition, V. 34, n°11, (November 2001), 2071 - 2082.
47. Noda, H., Shirazi, M.N. and Kawaguchi, E., "MRF-based Texture Segmentation Using Wavelet Decomposed Images", Pattern Recognition, V. 35, n°4, (April 2002), 771 - 782.
48. Dubuisson-Jolly, M.-P. and Gupta, A., "Color and Texture Fusion: Application to Aerial Image Segmentation and GIS Updating", Image and Vision Computing, V.18, n°10, (July 2000), 823 - 832.

49. Cocquerez, J.-P. et Philipp, S., "Analyse d'images : Filtrage et segmentation", Masson, Elsevier, (1995), 456 p.
50. Do, M. N., "Directional Multiresolution Image Representations", PhD thesis, Swiss Federal Institute of Technology Lausanne, Switzerland, (2001).
51. Bouman, C. and Liu, B., "Multiple Resolution Segmentation of Textured Images", IEEE Transactions on Pattern Analysis and Machine Intelligence, V. 13, n°2, (February 1991), 99 - 113.
52. Hauta-Kasari, M., Parkkinen, J., Jaaskelainen, T. and Lenz, R., "Multi-spectral Texture Segmentation Based on the Spectral Coocurrence Matrix", Pattern Analysis and Applications, V. 2, n°4, (October 1999), 275 - 284.
53. Meignen, S., "Problèmes d'Echelle dans la Segmentation par Ondelettes d'Images Texturées", Thèse de doctorat, Université Joseph Fourier, Grenoble, France, (2001).
54. Wee Kheng Leow and Seow Yong Lai, "Invariant Matching of Texture for Content-Based Image Retrieval", Workshop on Texture Analysis in Machine Vision, Oulu, Finland, (1999).
55. Sonka, M., Hlavac, V. and Boyle, R., "Image Processing, Analysis and Machine Vision", Chapman & Hall Computing, Springer, (January 1993), 580 p.
56. Tardif, P.-m., "Segmentation d'Images de Texture par des Modèles Multirésolutions", Thèse de doctorat, Université Laval, Québec, (2001).
57. Flandrin, P., "Temps-fréquence", Hermès, 2^{ème} édition, Paris, (1998), 386p.
58. Mallat, S., "An Efficient Image Representation for Multiscale Analysis", Proceedings of Machine Vision Conference, Lake Tahoe, US, (February 1987).
59. Daubechies, I., "Orthonormal Bases of Compactly Supported Wavelets", Communications on Pure and Applied Mathematics, V. 41, n°7, (November 1988), 909 - 996.
60. Mayer, F., Averbuch, A., and Coifman, R., "Multilayered Image Representation: Application to Image Compression", IEEE Transactions on Image Processing, V. 11, n°9, (September 2002), 1072 - 1080.
61. Mallat, S., "A Wavelet Tour of Signal Processing: The Sparse Way", Third Edition, Academic Press, (December 2008), 832 p.
62. Mallat, S.G., "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation", IEEE Transactions on Pattern Analysis and Machine Intelligence, V. 11, n°7, (July 1989), 674 - 693.

63. Chang, T. and Kuo, C.C.J., "Texture Analysis and Classification with Tree Structured Wavelet Transform", IEEE Transactions on Image Processing, V. 2, n°4, (October 1993), 429 - 441.
64. Zarita, R. and Lelandais, S., "Wavelets and High Order Statistics for Texture Classification", Scandinavian Conference on Image Analysis, Lappeenranta, Finland, (June 1997), 95 - 102.
65. Sophian, A., Tian, G. Y., Taylor, D. and Rudlin, J., "A Feature Extraction Technique Based on Principal Component Analysis for Pulsed Eddy Current NDT", NDT & E international, V. 36, n°1, (January 2003), 37 - 41.
66. Friedman, M. and Kandel, A., "Introduction to the Pattern Recognition: Statistical, Structural, Neural and Fuzzy Logic Approaches", (Series in Machine Perception and Artificial Intelligence), Imperial College Press, V. 32, London, UK, (December 1999), 329 p.
67. Jain, A.K., "Fundamentals of Digital Image Processing", Prentice Hall Information and System Sciences Series, Editor Thomas Kailath, (1989).
68. Vapnik, V.N., "The Nature of Statistical Learning Theory", Springer-Verlag, New York, (2000). 314 P.
69. Platt, J.C., "Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines", Technical Report MSR-TR-98-14, (April 1998).
70. Sholkopf, B. and Smola, A.J., "Learning with Kernels", The MIT Press, Cambridge, MA, (2002).
71. Boser, B.E., Guyon, I.M. and Vapnik, V.N., "A Training Algorithm for Optimal Margin Classifiers", Proceedings of the fifth Annual Workshop on Computational Learning Theory, ACM, Pittsburgh, (1992), 144 - 152.
72. Kharroubi, J., "Etude de Techniques de Classement : Machines à Vecteurs Supports pour la Vérification Automatique du Locuteur", Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications, Paris, (2002).
73. Suykens, J.A.K., Vandewalle, J. and De Moor, B., "Optimal Control by Least Squares Support Vector Machines", Neural Networks, V. 14, n°1, (January 2001), 23 - 25.
74. Gabor, D., "Theory of Communications", Journal of the Institution of Electrical Engineers, V. 93, n°26, (1946), 429 - 457.
75. Jain, A.K. and Farrokhnia, F., "Unsupervised Texture Segmentation Using Gabor Filters", Pattern Recognition, V. 24, n°12, (December 1991), 1167 - 1186.

76. Zuñiga Alvaro G., Florindo Joao B. and Bruno Odemir M., "Gabor wavelets combined with volumetric fractal dimension applied to texture analysis", *Pattern Recognition Letters*, Elsevier, V. 36, n°18, (January 2014), 135 - 143.
77. Kechida, A., Draï, R. and Guessoum, A., "Texture Analysis for Flaw Detection in Ultrasonic Images", *Journal of Nondestructive Evaluation*, V. 31, n° 2, (June 2012), 108 - 116.