



Felipe de Carvalho Gomes de Oliveira

**Comparação de Métodos de Extração de
Curvas de Dispersão Baseados em
Transformada de Fourier 2-D e Através do
Método Matriz Pencil**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Elétrica, do Departamento de Engenharia Elétrica da PUC-Rio.

Orientador: Prof. Alan Conci Kubrusly

Rio de Janeiro
Março de 2022



Felipe de Carvalho Gomes de Oliveira

**Comparação de Métodos de Extração de
Curvas de Dispersão Baseados em
Transformada de Fourier 2-D e Através do
Método Matriz Pencil**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Elétrica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Prof. Alan Conci Kubrusly

Orientador

Centro de Estudos em Telecomunicações (CETUC) – PUC-Rio

Prof. Arthur Martins Barbosa Braga

Departamento de Engenharia Mecânica (DEM) – PUC-Rio

Dr. Marcelo Roberto Baptista Pereira Luis Jimenez

Centro de Estudos em Telecomunicações (CETUC) – PUC-Rio

Rio de Janeiro, 25 de Março de 2022

Todos os direitos reservados. A reprodução, total ou parcial do trabalho, é proibida sem a autorização da universidade, do autor e do orientador.

Felipe de Carvalho Gomes de Oliveira

Graduado em Engenharia de Controle e Automação pela Universidade Federal do Rio de Janeiro.

Ficha Catalográfica

de Carvalho Gomes de Oliveira, Felipe

Comparação de Métodos de Extração de Curvas de Dispersão Baseados em Transformada de Fourier 2-D e Através do Método Matriz Pencil / Felipe de Carvalho Gomes de Oliveira; orientador: Alan Conci Kubrusly. – 2022.

156 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2022.

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Extração de curvas de dispersão. 3. Ondas ultrassônicas guiadas. 4. Logging de poço. 5. Transformada de Fourier em duas dimensões. 6. Operações morfológicas. I. Kubrusly, Alan. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Agradecimentos

Minha sincera gratidão ao meu orientador Alan Kubrusly, pelo seu tempo, instrução, conhecimento e paciência ao longo dos últimos anos, sem os quais essa dissertação não seria possível.

Agradeço também ao professor Arthur Braga, Auderi Santos e Giancarlo Faria por me incentivarem e ajudarem a dar início a esse trabalho. Agradeço profundamente ao Orlando Brito, por me inspirar a aliar conhecimentos práticos e teóricos na área de engenharia.

Agradeço ao CAPES, pela colaboração financeira que me permitiu ingressar no curso de mestrado da PUC-Rio.

Agradeço à ouronova, que me incentivou e ajudou na busca de aprimoramento possibilitada pelo mestrado, também à equipe do projeto TTiLT que me ajudou nesse trabalho, sobretudo a Bruno Greco e Roberth Llerena.

Agradeço à REPSOL, pelo investimento em pesquisa.

Agradeço à PUC-RIO, ao DEE e ao CETUC, por possibilitarem meus estudos.

Agradeço por todo o trabalho e dados de simulação oferecido pela equipe do LSFO. Agradeço em especial pela ajuda de Luis Paulo Brasil, Isabel Camerini e Juan Andrés Hidalgo.

Agradeço pelo suporte de meus familiares, sobretudo, a meus pais que sempre acreditaram na importância dos estudos para minha formação. Por último, agradeço à Julia Carapiá, pela sua companhia, suporte e paciência ao longo desses anos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

de Carvalho Gomes de Oliveira, Felipe; Kubrusly, Alan. **Comparação de Métodos de Extração de Curvas de Dispersão Baseados em Transformada de Fourier 2-D e Através do Método Matriz Pencil**. Rio de Janeiro, 2022. 156p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Ondas ultrassônicas guiadas são usadas em larga escala em ensaios não destrutivos (END) e *Structural Health Monitoring* (SHM), permitindo a inspeção de estruturas e equipamentos de forma não invasiva. A partir da transmissão de um sinal acústico sobre uma estrutura e a captação dos sinais de onda propagados por meio de sensores posicionados estrategicamente, é possível obter informações materiais do objeto inspecionado. Na área de óleo e gás, o uso desse tipo de ondas acústicas é de grande importância no levantamento do perfil da camada de cimento que reveste poços, que tem função de conferir integridade estrutural e isolar a estrutura interna de produção do poço das regiões freáticas do entorno. No processo de desativação e abandono do poço, é fundamental avaliar a qualidade do isolamento hidráulico do cimento, assim como identificar possíveis defeitos.

A propagação de ondas guiadas em uma estrutura se dá, em geral, por meio de múltiplos modos e apresenta característica dispersiva, que se traduz numa dependência da velocidade de fase das ondas com a frequência, e uma relação não linear entre número de onda e frequência. A relação de dispersão carrega informações do meio de propagação, tal como constantes elásticas e dimensões, e pode ser visualizada a partir de curvas no plano frequência-número de onda ($f-k$). Diferentes técnicas vêm sendo exploradas para a obtenção das relações de dispersão a partir de sinais no domínio do tempo captados por sensores ultrassônicos em posições espaciais distintas.

Este trabalho explora três métodos distintos para a extração das curvas de dispersão, ou seja, obter os pontos $f-k$ associados aos modos de propagação, a partir de um conjunto de sinais dependentes do espaço-tempo. O primeiro algoritmo se baseia em uma técnica pré-existente que usa uma Transformada de Fourier bidimensional (2-D FT) sobre a matriz de dados de sinais de sensores ultrassônicos no espaço-tempo, gerando uma matriz de amplitudes no plano $f-k$ onde os máximos locais representam pontos pertencentes a

curvas de dispersão. A representação da matriz como uma imagem f-k permite a visualização das curvas de dispersão como conjuntos contíguos de pixels de maior clareza. Propõe-se um novo algoritmo baseado em operações morfológicas de processamento de imagem para a identificação de pixels relativos aos pontos das curvas de dispersão na imagem f-k, após um pré-processamento da mesma. A segunda técnica consiste no pré-processamento dessa mesma imagem f-k, obtida pela 2-D FT, e uso de um algoritmo pré-existente de detecção de estruturas curvilíneas em imagens para identificar os pontos correspondentes às curvas f-k. O terceiro método é uma adaptação, proposta aqui, de um algoritmo pré-existente para estimar os números de onda das curvas de dispersão relativos a cada frequência através de uma matriz Pencil. Propõe-se também um algoritmo original para a separação dos pontos f-k encontrados pelas três técnicas de extração em curvas distintas.

Os algoritmos utilizados para a obtenção das curvas de dispersão têm seu desempenho avaliado em três conjuntos de dados distintos de simulações por elementos finitos, a saber, uma de placa de alumínio fina sob distintos valores de tração axial aplicada paralelamente à direção de propagação das ondas; um poço multicamada sem *tubing* possuindo diferentes tipos de defeito de cimentação—channeling, qualidade de cimento baixa, descolamento interno e externo—, assim como sem defeito; e um pouco multicamada com *tubing* sob os mesmos defeitos de cimentação e também sem defeito. Compara-se a capacidade dos algoritmos de extração das curvas de dispersão de oferecer informações sobre mudanças materiais entre os casos simulados. Avalia-se também a precisão e custo computacional dos mesmos.

Palavras-chave

Extração de curvas de dispersão; Ondas ultrassônicas guiadas; Logging de poço; Transformada de Fourier em duas dimensões; Operações morfológicas.

Abstract

de Carvalho Gomes de Oliveira, Felipe; Kubrusly, Alan (Advisor). **Comparison of Extraction Methods for Dispersion Curves Using 2-D Fourier Transform and Matrix Pencil Method**. Rio de Janeiro, 2022. 156p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Ultrasonic guided waves are widely used in the fields of Non-Destructive Evaluation (END) and Structural Health Monitoring (SHM), allowing the inspection of structures and pieces of equipment in a non-invasive manner. Through the transmission of an acoustic signal over a given object and the acquisition of the signal from the propagated waves using a group of sensors in predefined positions, it is possible to obtain material information regarding the investigated structure. In the Oil & Gas industry, the use of this type of wave is integral to the logging of the cement layer that outlines the walls of wellbores, which has the purpose of guaranteeing structural support and protecting the well's internal production structure and the surrounding groundwater from each other. During the deactivation and abandonment of a production well, it is necessary to evaluate the hydraulic isolation of the cement layer, as well as identify possible defects.

The propagation of guided waves in a structure is usually multi-modal and of dispersive characteristic. The latter means that the propagating waves' phase velocity is dependent on the frequency, translating into a non-linear relationship between wavenumber and frequency. This dispersion relation contains information about the propagating medium, such as elastic constants and dimensions, and can be represented as curves in the frequency-wavenumber (f-k) plane. Different methods are currently being explored for obtaining the dispersion relation from time-domain signals acquired by ultrasonic sensors in different spatial positions.

This work explored three different methods for the extraction of the dispersion curves, that is, obtaining the f-k points associated with the modes of propagation, from a dataset composed of space-time signals. The first algorithm is based on a pre-existing technique that uses the bidimensional Fourier Transform (2-D FT) over the matrix containing the space-time signals from the ultrasonic sensors, generating an f-k matrix whose local maximas correspond to points belonging to dispersions curves. The representation of

the matrix as an f-k image shows the dispersion curves as contiguous groups of pixels with elevated brightness. A new algorithm is proposed, based on morphological operations from image-processing, to identify the pixels relative to the f-k points of the dispersion curves in the image, after pre-processing is performed. The second technique consists of pre-processing the same f-k image, obtained from the 2-D FT, and the use of an existing algorithm for the detection of curvilinear structures in images to identify the points corresponding to the f-k curves. The third method proposes the adaptation of an existing method of estimation of the wavenumbers associated with the dispersion curves for different frequencies, using a matrix Pencil. This work also proposes an original algorithm to separate the f-k points, retrieved by the three techniques, in different curves associated with each mode of propagation.

The algorithms used here for the estimation of the dispersion curves are evaluated over three distinct datasets of finite elements simulation: a thin aluminum plate under different values of axial traction parallel to the direction of propagation of the waves; a multilayer wellbore without tubing, with different types of cement defects—channeling, low cement quality, internal and external decoupling—, and without defect; a multilayer wellbore with tubing with the same cement defects and with no defect. Finally, a comparison is drawn over the capacity of the extraction algorithms of providing information regarding changes in the material qualities of the simulated objects. The work also evaluates the precision and computational performance of the aforementioned algorithms.

Keywords

Extraction of dispersion curves; Ultrasonic guided waves; Borehole logging; Bidimensional Fourier transform; Morphological operations;.

Sumário

1	Introdução	19
1.1	Integridade de poços na indústria de óleo e gás	20
1.2	Técnicas de obtenção das curvas de dispersão	22
1.3	Objetivo	26
1.4	Contribuição da dissertação	26
2	Fundamento Teórico	27
2.1	Ondas ultrassônicas guiadas	27
2.2	Transformada de Fourier bidimensional	31
2.3	Determinação das curvas de dispersão a partir de 2-D FT	32
3	Métodos de extração e separação das curvas de dispersão	37
3.1	Extração de curvas de dispersão por 2-D FT e processamento de imagem	37
3.2	Extração de curvas de dispersão por algoritmo Matriz Pencil Modificado	52
3.3	Algoritmo de rastreamento e separação das curvas	59
4	Estudos de caso	63
4.1	Dados simulados de placa de alumínio	63
4.2	Dados simulados de poço multicamada	64
5	Resultados	71
5.1	Placa de alumínio	71
5.2	Poço multicamada	93
6	Conclusão	146
6.1	Trabalhos futuros	149
	Referências bibliográficas	150

Lista de figuras

Figura 1.1	a) Poço simplificado com apenas casing e cimentação. b) Poço simplificado contendo <i>tubing</i> .	21
Figura 2.1	a) Inspeção por ondas volumétricas com excitação por feixe normal. b) Inspeção por ondas guiadas com excitação por feixe angulado. Adaptado de (4).	28
Figura 2.2	Curvas de dispersão teóricas de uma placa de alumínio com espessura $3mm$ e velocidade transversal $c_T = 3133$.	30
Figura 2.3	Curvas de dispersão de Lamb teóricas de uma placa de alumínio com espessura $3mm$ e velocidade transversal $c_T = 3133$ representadas no domínio slowness \times frequência.	31
Figura 2.4	Sinais capturados por receptores ultrassônicos simulados ao longo do tempo.	34
Figura 2.5	Matriz de sinais tempo-espaço visualizada como imagem.	35
Figura 2.6	Figura f-k gerada a partir da 2-D FT em escala decimal demonstrando as curvas de dispersão associadas à placa de alumínio. As curvas são difíceis de se identificar.	35
Figura 2.7	Figura f-k gerada a partir da 2-D FT na escala logarítmica demonstrando as curvas de dispersão associadas à placa de alumínio. As curvas de dispersão são visíveis e mais artefatos são percebidos ao fundo da imagem.	36
Figura 3.1	Espectro da imagem de entrada com intensidades em escala logarítmica e posteriormente normalizadas para melhor visualização.	38
Figura 3.2	Espectro do filtro utilizado para remover artefatos da imagem.	39
Figura 3.3	Ilustração do erro de wraparound causado pelo uso da FT discreta, onde as linhas sólidas representam pontos amostrados ou calculado pela FT, e as linhas pontilhadas são as repetições geradas pela FT discreta. a) Sinal amostrado $f(m)$ de 200 amostras; b) Sinal amostrado $h(m)$ de m amostras; c) Sinal $h(m)$ invertido para operação de convolução; d) Convolução com erro de wraparound. Adaptado de (78).	40
Figura 3.4	a) Imagem original das curvas de dispersão obtida pela 2-D FT. b) Imagem resultante do pré-processamento.	41
Figura 3.5	Máscara de pixels obtida pela aplicação do algoritmo de Ridge sobre as curvas de dispersão da placa de alumínio descrita na seção 2.3.	43
Figura 3.6	Ilustração das operações fundamentais de morfologia matemática: a) Conjuntos de entrada. b) União. c) Interseção. d) Complemento. e) Diferença. f) Reflexão. g) Translação. Adaptado de (78).	45
Figura 3.7	a) Objetos representados como conjuntos; b) Objetos e elementos estruturais inseridos em um plano de fundo, representando uma imagem; c) Objetos e plano de fundo digitalizados. Adaptado de (78).	46
Figura 3.8	Representação da dilatação de um conjunto A com relação a um elemento estruturante B . Adaptado de (78).	47
Figura 3.9	Representação da erosão de um conjunto A com relação a um elemento estruturante B . Adaptado de (78).	47

Figura 3.10	a) Imagem composta pelo conjunto A . b) Elemento estruturante B . c) Translações de B que não sobrepõem A . d) Fechamento de A por B . Adaptado de (78).	48
Figura 3.11	Exemplos de Threshold de Otsu em uma imagem em escala de cinza. Imagem obtida da biblioteca de python scikit-image. CC0 pelo fotógrafo Lav Varshney (85).	50
Figura 3.12	Fluxograma exibindo as técnicas usadas para gerar a máscara que delinea as curvas de dispersão.	50
Figura 3.13	a) Imagem f-k original. b) Resultado parcial do algoritmo após aumento de contraste iterativo da etapa 2. c) Resultado parcial do algoritmo após operação de fechamento da etapa 5. d) Resultado final do algoritmo.	52
Figura 3.14	Fluxograma das etapas do algoritmo Pencil.	57
Figura 3.15	Pontos f-k obtidos pelo algoritmo Pencil para a placa de alumínio da seção 2.3, utilizando o pareamento proposto por Ekstrom, assim como o pareamento proposto neste trabalho.	58
Figura 3.16	Fluxograma resumindo o funcionamento do algoritmo de rastreamento e separação das curvas.	60
Figura 3.17	Pontos identificados, projetados e interpolados encontrados pelo algoritmo para a máscara de entrada obtida por Ridge na seção 3.1.2, assim como as curvas separadas a partir dos pontos.	61
Figura 4.1	Diagrama simplificado da simulação de propagação em placa de alumínio por FEM.	64
Figura 4.2	Diagrama da seção do poço multicamadas simulado a partir do centro.	65
Figura 4.3	Resposta simulada por FEM em tempo-espaco no placa do poço multicamada sem <i>tubing</i> .	66
Figura 4.4	Diagrama da seção do poço multicamadas simulado a partir do centro.	67
Figura 4.5	Resposta simulada por FEM em tempo-espaco no placa do poço multicamada com <i>tubing</i> .	68
Figura 4.6	Vista da secção transversal do poço com defeito de Channeling.	69
Figura 4.7	Vista da secção transversal do poço com qualidade de cimentação reduzida.	69
Figura 4.8	Vista da secção transversal do poço com descolamento interno.	70
Figura 4.9	Vista da secção transversal do poço com descolamento externo.	70
Figura 5.1	Curvas de dispersão extraídas por operações morfológicas a partir da placa simulada com sensores no sentido x.	72
Figura 5.2	Curvas de dispersão extraídas por operações morfológicas a partir da placa simulada com sensores no sentido y.	73
Figura 5.3	Comparação das curvas extraídas por 2-D FT com operações morfológicas para diferentes tensões em placa com sensores medidos na direção x.	74

Figura 5.4	Comparação das curvas extraídas por 2-D FT com operações morfológicas para diferentes tensões em placa com sensores medidos na direção y.	75
Figura 5.5	Curvas de dispersão extraídas por Ridge a partir da placa simulada com sensores no sentido x.	76
Figura 5.6	Curvas de dispersão extraídas por Ridge a partir da placa simulada com sensores no sentido y.	76
Figura 5.7	Comparação de máscaras de pixels feitas com Ridge e operações morfológicas, identificando as curvas para placa de alumínio, medidas em x.	77
Figura 5.8	Comparação das curvas extraídas por 2-D FT com Ridge para diferentes tensões em placa com sensores medidos na direção x.	78
Figura 5.9	Comparação das curvas extraídas por 2-D FT com Ridge para diferentes tensões em placa com sensores medidos na direção y.	79
Figura 5.10	Curvas de dispersão extraídas por Pencil a partir da placa simulada com sensores no sentido x.	80
Figura 5.11	Curvas de dispersão extraídas por Pencil a partir da placa simulada com sensores no sentido y.	80
Figura 5.12	Comparação das curvas extraídas por Pencil para diferentes tensões em placa com sensores medidos na direção x.	81
Figura 5.13	Comparação das curvas extraídas por Pencil para diferentes tensões em placa com sensores medidos na direção y.	81
Figura 5.14	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para placa de alumínio com sensores no sentido x: a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	87
Figura 5.15	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para placa de alumínio com sensores no sentido y: a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	88
Figura 5.16	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A0 e S0, em x.	89
Figura 5.17	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A1 e S1, em x.	90
Figura 5.18	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A2 e S2, em x.	90
Figura 5.19	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A0 e S0, em y.	91
Figura 5.20	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A1 e S1, em y.	91
Figura 5.21	Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A2 e S2, em y.	92

Figura 5.22	Curvas obtidas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> e sem defeito (ND).	94
Figura 5.23	Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito de Channeling (CH).	95
Figura 5.24	Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito de Channeling (CH).	96
Figura 5.25	Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito CQ.	97
Figura 5.26	Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito CQ.	97
Figura 5.27	Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito SC.	98
Figura 5.28	Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito SC.	98
Figura 5.29	Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito CR.	99
Figura 5.30	Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem <i>tubing</i> com defeito CR.	99
Figura 5.31	Curvas obtidas por 2-D FT com Ridge de poço sem <i>tubing</i> e sem defeito (ND).	100
Figura 5.32	Curvas de slowness extraídas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CH.	101
Figura 5.33	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CH.	102
Figura 5.34	Curvas de slowness extraídas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CQ.	103
Figura 5.35	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CQ.	103
Figura 5.36	Curvas de slowness extraídas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito SC.	104
Figura 5.37	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito SC.	104
Figura 5.38	Curvas de slowness extraídas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CR.	105
Figura 5.39	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem <i>tubing</i> com defeito CR.	105
Figura 5.40	Curvas obtidas por Pencil de poço sem <i>tubing</i> e sem defeito (ND).	106
Figura 5.41	Curvas de slowness extraídas por Pencil de poço sem <i>tubing</i> com defeito CH.	107
Figura 5.42	Vista aproximada das curvas de slowness obtidas por Pencil de poço sem <i>tubing</i> com defeito CH.	108
Figura 5.43	Curvas de slowness extraídas por Pencil de poço sem <i>tubing</i> com defeito CQ.	109
Figura 5.44	Vista aproximada das curvas de slowness obtidas por Pencil de poço sem <i>tubing</i> com defeito CQ.	109

Figura 5.45	Curvas de slowness extraídas por Pencil de poço sem <i>tubing</i> com defeito SC.	110
Figura 5.46	Vista aproximada das curvas de slowness obtidas por Pencil de poço sem <i>tubing</i> com defeito SC.	110
Figura 5.47	Curvas de slowness extraídas por Pencil de poço sem <i>tubing</i> com defeito CR.	111
Figura 5.48	Vista aproximada das curvas de slowness obtidas por Pencil de poço sem <i>tubing</i> com defeito CR.	111
Figura 5.49	Curvas de slowness sobrepostas de poço multicamada sem <i>tubing</i> e sem defeito extraídas com os três algoritmos.	113
Figura 5.50	Vista aproximada das curvas de slowness sobrepostas de poço multicamada sem <i>tubing</i> e sem defeito extraídas com os três algoritmos.	114
Figura 5.51	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem <i>tubing</i> com defeito de Channeling (CH): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	115
Figura 5.52	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem <i>tubing</i> com qualidade de cimentação baixa (CQ): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	116
Figura 5.53	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem <i>tubing</i> com descolamento interno (SC): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	117
Figura 5.54	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem <i>tubing</i> com descolamento externo (CR): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	118
Figura 5.55	Curvas obtidas por 2-D FT com operação morfológicas de poço com <i>tubing</i> e sem defeito (ND).	119
Figura 5.56	Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CH.	120
Figura 5.57	Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CH.	121
Figura 5.58	Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CQ.	122
Figura 5.59	Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CQ.	122
Figura 5.60	Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito SC.	123
Figura 5.61	Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito SC.	123
Figura 5.62	Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CR.	124
Figura 5.63	Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com <i>tubing</i> com defeito CR.	124
Figura 5.64	Curvas obtidas por 2-D FT com Ridge de poço com <i>tubing</i> e sem defeito (ND).	125

Figura 5.65	Curvas de slowness extraídas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CH.	126
Figura 5.66	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CH.	127
Figura 5.67	Curvas de slowness extraídas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CQ.	128
Figura 5.68	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CQ.	129
Figura 5.69	Curvas de slowness extraídas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito SC.	129
Figura 5.70	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito SC.	130
Figura 5.71	Curvas de slowness extraídas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CR.	130
Figura 5.72	Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com <i>tubing</i> com defeito CR.	131
Figura 5.73	Imagem obtida a partir da matriz f-k gerada pela 2-D FT do conjunto de dados com <i>tubing</i> ND.	131
Figura 5.74	Curvas obtidas por Pencil de poço com <i>tubing</i> e sem defeito (ND).	133
Figura 5.75	Curvas de slowness extraídas por Pencil de poço com <i>tubing</i> com defeito CH.	133
Figura 5.76	Vista aproximada das curvas de slowness obtidas por Pencil de poço com <i>tubing</i> com defeito CH.	134
Figura 5.77	Curvas de slowness extraídas por Pencil de poço com <i>tubing</i> com defeito CQ.	135
Figura 5.78	Vista aproximada das curvas de slowness obtidas por Pencil de poço com <i>tubing</i> com defeito CQ.	136
Figura 5.79	Curvas de slowness extraídas por Pencil de poço com <i>tubing</i> com defeito SC.	136
Figura 5.80	Vista aproximada das curvas de slowness obtidas por Pencil de poço com <i>tubing</i> com defeito SC.	137
Figura 5.81	Curvas de slowness extraídas por Pencil de poço com <i>tubing</i> com defeito CR.	137
Figura 5.82	Vista aproximada das curvas de slowness obtidas por Pencil de poço com <i>tubing</i> com defeito CR.	138
Figura 5.83	Curvas de slowness sobrepostas de poço multicamada com <i>tubing</i> e sem defeito extraídas com os três algoritmos.	140
Figura 5.84	Vista aproximada das curvas de slowness sobrepostas de poço multicamada com <i>tubing</i> e sem defeito extraídas com os três algoritmos.	141
Figura 5.85	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com <i>tubing</i> com defeito de Channeling (CH): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	142
Figura 5.86	Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com <i>tubing</i> com qualidade de cimentação baixa (CQ): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.	143

Figura 5.87 Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com descolamento interno (SC): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos. 144

Figura 5.88 Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com descolamento externo (CR): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos. 145

Lista de tabelas

Tabela 3.1	Parâmetros do algoritmo Pencil usados com os dados de entrada da placa de alumínio descrita na seção 2.3.	58
Tabela 4.1	Características materiais de placas de alumínio simulada.	63
Tabela 4.2	Características materiais do poço multicamada simulado.	66
Tabela 5.1	Parâmetros do algoritmo Pencil usados com os dados de entrada da placa de alumínio.	79
Tabela 5.2	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com operações morfológicas de dados simulados no sentido x.	82
Tabela 5.3	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com operações morfológicas de dados simulados no sentido y.	83
Tabela 5.4	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com Ridge de dados simulados no sentido x.	83
Tabela 5.5	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com Ridge de dados simulados no sentido y.	84
Tabela 5.6	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por algoritmo Pencil de dados simulados no sentido x.	85
Tabela 5.7	Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por algoritmo Pencil de dados simulados no sentido y.	85
Tabela 5.8	Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados da placa de alumínio nos sentidos x e y com diferentes trações axiais aplicadas.	93
Tabela 5.9	Parâmetros do algoritmo Pencil usados com os dados de entrada da poço multímacada sem <i>tubing</i> .	106
Tabela 5.10	Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados de poço multicamada sem <i>tubing</i> .	113
Tabela 5.11	Parâmetros do algoritmo Pencil usados com os dados de entrada da poço multímacada com <i>tubing</i> .	132
Tabela 5.12	Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados de poço multicamada com <i>tubing</i> .	141
Tabela 6.1	Comparação simplificada do desempenho dos algoritmos de extração abordados nesse trabalho.	148

Lista de Abreviaturas

END – Ensaios não-destrutivos

SHM – Monitoramento de integridade estrutural (*Structural Health Monitoring*)

SNR – Relação sinal-ruído 2-D FT – Transformada de Fourier bidimensional

FFT – Fast Fourier Transform

ND – Poço sem defeito de cimentação

CH – Defeito de cimentação do tipo Channeling

CQ – Defeito por qualidade de cimentação

SC – Defeito de cimentação por descolamento interno

CR – Defeito de cimentação por descolamento externo

1

Introdução

Ondas ultrassônicas são ondas que operam em faixas de frequência acima do limite audível por seres humanos, ocupando o espectro acima de 20 kHz (1). Elas podem se propagar em meio sólido, líquido ou gasoso (2). Por serem capazes de propagar-se em estruturas de diferentes materiais e ter suas características de propagação influenciada pelas propriedades do meio, esses tipos de onda encontram aplicação em diversas áreas da engenharia relacionadas a avaliação de corpos e estruturas (3).

Um subgrupo das ondas ultrassônicas são as ondas guiadas, que permitem que estruturas inteiras possam ser avaliadas a partir de apenas um transmissor, com propagação a longas distâncias sob atenuação moderada (4). A partir da avaliação das características de propagação das ondas indicadas por sensores ultrassônicos, é possível identificar falhas e defeitos em uma estrutura, assim como caracterizar seus materiais (5).

As ondas guiadas se propagam em um meio através de diferentes modos de propagação, que podem ser caracterizados por seu perfil de deslocamento ao longo da espessura e pela dependência da velocidade de fase com relação à frequência. Se esta relação for não-constante, há o fenômeno da dispersão, que se traduz em uma relação não linear entre número de onda e frequência (6). De acordo com as características materiais e volumétricas de uma estrutura, os modos de propagação das ondas variam em quantidade e características de frequência-número de onda (7). As curvas de dispersão apresentam os modos de propagação como relações de frequência com número de onda e a partir dessa relação é possível inferir características do meio de propagação, tal como constantes elásticas e dimensões da geometria (8). A informação de dispersão pode ser extraída das respostas no domínio do tempo dos receptores ultrassônicos.

Uma área em que as ondas ultrassônicas guiadas são amplamente utilizadas é a de ensaios não-destrutivos (END) (9). Seu objetivo é a identificação de aspectos indesejáveis em estruturas sem que haja qualquer tipo de dano ao espécime sendo testado. Além do reconhecimento de possíveis falhas em estruturas, cuja integridade é essencial à segurança de indivíduos ou de uma cadeia produtiva, também é possível aferir a qualidade de produtos industrializados de forma a garantir que estes estejam dentro de parâmetros de confiabilidade específicos, o que é essencial a distintas indústrias, como aeroespacial (10), óleo e gás (11), e médica (4).

O uso de ondas guiadas também possui grande relevância no campo de monitoramento de integridade estrutural, do inglês *Structural Health Monitoring (SHM)* (12). Esta área compreende a observação e estudo de um sistema ao longo do tempo por meio de aferições periódicas de suas características, de forma a registrar mudanças nas qualidades materiais ou geométricas de estruturas, como pontes e edifícios (13).

Na indústria de óleo e gás, ondas guiadas podem ser utilizadas na avaliação da integridade de poços e na caracterização do isolamento hidráulico (14). Em poços abandonados, esse teste é de especial importância para garantir a qualidade da vedação hidráulica que deve evitar vazamentos de forma permanente (11).

1.1

Integridade de poços na indústria de óleo e gás

A extração de petróleo e gás natural abaixo da superfície terrestre é feita através de poços perfurados na terra (15). Para alinhar, conferir integridade estrutural ao poço e proteger as camadas de solo e lençóis freáticos de contaminação, uma estrutura anular de aço, denominado *casing*, é inserida em seu interior, usualmente com uma parede de cimentação entre a camada rochosa de terra e o aço (15), que fixa o *casing* em posição. Uma outra estrutura anular de aço, denominada de *tubing*, é inserida dentro do *casing* e utilizada para controlar o transporte de óleo e gás para a superfície (16).

Ao fim da vida útil de um poço de petróleo, o mesmo é abandonado, em operações conhecidas como Plug & Abandonment (P&A) (17). Para que isso seja possível, é necessário que o poço seja tampado através da imposição de uma série de barreiras em sua estrutura e que se garanta a vedação hidráulica, de forma a impedir que o conteúdo remanescente dos reservatórios abaixo da superfície possa vazar (17).

O revestimento de cimento em torno do *casing* é integral na prevenção de fluxo de fluidos entre a formação rochosa e a região interna do poço (18), e a avaliação da qualidade de seu isolamento hidráulico e integridade é parte importante desse processo. Algumas técnicas para a inferência do perfil de cimentação de um poço são: monitoramento por temperatura (19), *logging* de radioatividade do poço (19) e inspeção por ondas sônicas (20) e ultrassônicas (11).

A avaliação do cimento por meio de ondas acústicas é complexa devido ao número de variáveis envolvidas e depende diretamente da configuração de camadas do poço (21). Atualmente, a verificação da cimentação de um poço para abandono depende da remoção da coluna de produção para que se obtenha

maior grau de confiança com respeito às informações sobre a qualidade do isolamento. No entanto, a remoção da coluna de produção, o *tubing*, durante a etapa de abandono apresenta um custo adicional não desejável. Dessa forma, avanços nas técnicas de inspeção da qualidade do cimento através da coluna, *through-tubing*, são de grande importância e serão explorados nesse trabalho. A figura 1.1 ilustra a seção de um poço simplificado com e sem *tubing*.

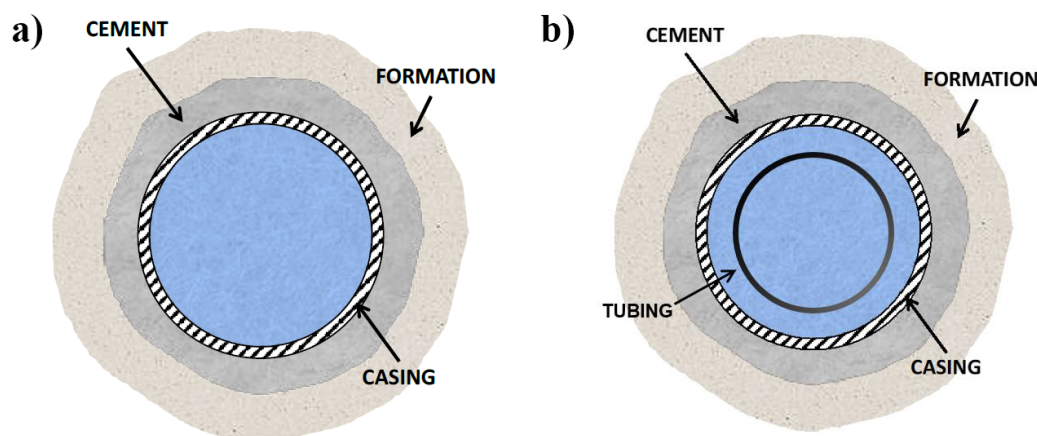


Figura 1.1: a) Poço simplificado com apenas casing e cimentação. b) Poço simplificado contendo *tubing*.

O uso da técnica de pulse-echo é bastante comum na indústria de óleo e gás para a perfilagem da cimentação de poços (22) e utiliza ondas volumétricas. O processo consiste de um único transdutor que emite e capta a resposta de um sinal acústico após ele atravessar as camadas do meio e ser refletido de volta (22).

A técnica de ondas ultrassônica guiadas aplicada à indústria de óleo e gás é conhecida como pitch-catch e consiste no uso de uma ferramenta com um ou mais emissores acústicos que geram um sinal angulado com relação às paredes das camadas de materiais componentes do poço (23). Devido à trajetória axial, as ondas acústicas se propagam através de distintos modos, que são captados por sensores distribuídos pela ferramenta. As diferentes propriedades da ligação entre as camadas de cimento, aço e formação rochosa influenciam no perfil de propagação das ondas, se traduzindo em maior sensibilidade da resposta captada pelos sensores que o método pulse-echo (24). Além disso, parâmetros de excitação de ondas guiadas podem ser escolhidos de forma a inspecionar tipos de defeito específicos (25).

A perfilagem por ondas guiadas pode ser utilizada para obter informações sobre as condições materiais do cimento, assim como indicar a presença de defeitos em sua formação (26), tal como cimento com baixa qualidade (27); *channeling*, que se caracteriza pela presença de fluídos na camada de

cimento, fazendo que o *casing* não esteja plenamente coberto de cimento (22); descolamento entre o cimento e a formação rochosa ou descolamento entre o cimento e o *casing*.

1.2

Técnicas de obtenção das curvas de dispersão

Para a extração de informações relevantes dos modos que compõem as ondas guiadas, tal como velocidade, atenuação e amplitude, é preciso lidar com a característica dispersiva desses modos, assim como a possibilidade de múltiplos modos estarem associados ao mesmo número de onda e frequência (4). Diferentes métodos foram desenvolvidos para a identificação das curvas de dispersão a partir de um conjunto de dados compostos de respostas de sensores igualmente espaçados a um estímulo ultrassônico.

Hora & Cervena (28) e Alleyne & Cawley (29) utilizam a 2-D FT para converter a resposta captada em uma matriz de amplitudes no domínio discreto frequência-número de onda (f - k), identificando os pontos das curvas de dispersão como os pontos de máximo locais para valores fixos de frequência ou número de onda. Hora & Cervena exploraram o uso desta técnica em uma placa de aço com condições de contorno livres, simulada pelo método de elementos finitos, e comparam com as curvas analíticas obtidas através das equações de Lamb (30). Alleyne & Cawley exploraram a técnica da 2-D FT em dados numéricos de elementos finitos e experimentais de placas de aço de espessuras de 0.5, 2.0 e 3mm. Os resultados são comparados com o modelo analítico deduzido pelas equações de Lamb, encontrando no máximo 1% de diferença de número de onda entre as curvas obtidas numérica e experimentalmente e a referência analítica.

Xu et al. (31) exploraram o uso da técnica de 2-D FT em conjunto com uma técnica de *Singular Vector Decomposition (SVD)* (32) esparsa em conjuntos de dados sintéticos e experimentais em ossos humanos *ex-vivo* e objetos simuladores de ossos. O uso de SVD demonstrou uma melhora na relação sinal-ruído (SNR) (33), aprimorando a detecção de sinais de modos de propagação com menor amplitude. O uso de regularização esparsa (32) permitiu a extração das curvas de dispersão com alta resolução no domínio de número de onda, obstáculo frequente no uso da técnica 2-D FT, devido ao número baixo de amostras espaciais usualmente visto em dados experimentais, que pode atrapalhar a identificação de curvas de dispersão que se cruzam (31).

Kulesh et al. (34) propuseram um modelo matemático para correlacionar a transformada Wavelet contínua (35) de um sinal e sua versão propagada. Assim, Kulesh et al. encontraram um operador de transformação (propagador

wavelet) para prever os sinais propagados em um meio dispersivo e atenuante, possibilitando a estimativa das velocidades de grupo e de fase. Holschneider et al (36) propuseram um método para estimativa de velocidade de grupo e velocidade de fase de ondas de superfície com base no mesmo princípio. No domínio de wavelet, o sinal da onda propagado captado por distintas estações é comparado com base na hipótese de que as diferenças entre eles se deve apenas à dispersão e atenuação características do meio associado. A partir da solução de um problema de minimização de uma função de custo associada, são encontrados os parâmetros de propagação. Nesse trabalho, o modelo proposto é avaliado em dois conjuntos de dados, a saber, sintéticos e de levantamento sísmico de campo. Ambos os trabalhos tem a limitação de estimarem apenas as características das ondas para um modo único de propagação.

Xu et al. (37) propuseram um algoritmo *crazy-climber* para separar representações em tempo-frequência (TFR) (38) de sinais ultrassônicos multimodais de ondas guiadas em ossos longos do corpo humano. Nas TFRs, os cumes, ou regiões de pico locais, indicam as seções de maior concentração de energia do sinal no plano tempo-frequência. O algoritmo *crazy-climber* é utilizado para encontrar o conjunto de pontos relativos a máximos locais no plano tempo-frequência, que são os cumes de interesse. Posteriormente, os sinais relativos a cada modo de dispersão são reconstruídos separadamente a partir das regiões de pico das TFRs e os resultados são comparados. Sinais simulados, com e sem ruído, são utilizados para validação do algoritmo, que se mostra capaz de separar corretamente os sinais no tempo relativos a cada modo de dispersão com base nos cumes correspondentes. Os resultados também comprovam a robustez do algoritmo quando utilizados dados experimentais originados de um osso de tíbia bovino.

Niethammer et al. (39) compararam a eficácia de quatro formas distintas de TFRs de ondas de Lamb geradas por um laser e detectadas por um interferômetro. O uso de TFR se demonstrou prático para a identificação dos tempos de chegada dos diferentes modos de um sinal multimodo. Niethammer et al. concluíram que o método de espectograma redesignado é o mais apropriado para a representação de ondas de Lamb, sendo capaz de localizar múltiplos modos de Lamb próximos entre si em ambos os domínios de frequência e tempo.

Askari et al. (40) propuseram um modelo matemático baseado na S-Transform generalizada (41), que é uma representação do sinal no domínio frequência-tempo que preserva o espectro de fase. Essa transformada é utilizada para estimar parâmetros de propagação para um conjunto de dados sísmicos ruidosos e relativos a ondas com alto grau de dispersão. Nesse trabalho, Askari et al. se utilizam de uma função de custo no domínio S para estimar o valor

ótimo para um fator de escala na S-Transform e também para melhorar o desempenho do algoritmo para conjuntos de dados com SNR baixa. O algoritmo é avaliado com base em seu desempenho em dados sísmicos sintéticos e reais. Em outro trabalho, Askari et al. (42) utilizaram um método de deslocamento de fase no domínio de Fourier e uma S-Transform generalizada com *slant-stacking* (43) para estimar parâmetros de propagação de dados sísmicos.

Serdyukov et al. (44) propuseram uma análise a partir de *slant-stacking* da representação no domínio frequência-tempo obtido pela S-Transform (45) a partir de uma transformada de Fourier no domínio do espaço. Constrói-se uma imagem no domínio f-k por meio da análise do espectro espacial para diferentes velocidades de grupo. A robustez do algoritmo é validada com dados experimentais e sintéticos.

Lang et al. (46). utilizaram-se de uma extensão do método de Prony (47) para modelar a propagação espacial com base apenas em números de onda com valor real, que permite a extração de informação de frequência, amplitude e fase dos sinais de dados ultrassônicos obtidos em um poço preenchido com líquido. Através dessa extensão, que é o preditor linear Forward-Backward (48), e de um modelo da dependência espacial do resultado da Fourier do sinal do tempo de cada sensor como uma soma de exponenciais, são obtidos os valores reais dos números de onda associados. O algoritmo é utilizado com dados de entrada sintéticos, de laboratório e de um poço de teste em campo, sendo capaz de extrair informação de dispersão para os diferentes conjuntos de dados explorados.

Ekstrom (49) estima os modos de propagação de sinais originados de medidas em poços utilizando uma transformada de Fourier no domínio do tempo sobre os sinais individuais dos sensores. Esses sinais de frequência são aproximados por um modelo de soma de exponenciais. Os números de onda são estimados através de um método do tipo Matriz Pencil (50), a partir da estimativa das exponenciais complexas associadas. Essa estimativa é feita por meio da descoberta dos números redutores de posto de duas matrizes geradas através da resposta em frequência dos sinais obtidos pela FT.

Em alguns dos trabalhos supracitados, a representação gráfica f-k obtida das curvas de dispersão ainda carece de uma forma consistente para a obtenção dos pontos associados, sobretudo em casos de propagação de ondas multimodais onde há cruzamento entre as curvas dos modos. Além disso, a literatura apresenta poucos trabalhos que comparam diferentes métodos de estimativa das curvas de dispersão. Neste trabalho, serão abordadas e comparadas as técnicas da Transformada de Fourier em 2 dimensões (2-D FT) (28) e matriz

Pencil modificada (49).

Na técnica 2-D FT, a transformada de Fourier bidimensional é usada sobre uma matriz de sinais no domínio tempo-espço (t-s) obtida pela resposta de um array de sensores a um estímulo ultrassônico. O resultado dessa transformada é uma matriz no domínio frequência-número de onda (f-k) em que as curvas de dispersão podem ser identificadas a partir dos máximos locais de amplitude para cada frequência (28). A matriz f-k pode ser representada como uma imagem, onde é possível observar as curvas de dispersão (29). Devido à presença de artefatos visuais nas proximidades das curvas, assim como cruzamentos entre elas, não existe uma maneira direta de obter os pontos f-k que denotam as curvas a partir da figura gerada com a 2-D FT.

Nesse trabalho, propõe-se o uso de algoritmos de processamento de imagem para delinear essas curvas, observadas através da representação por imagem da matriz f-k obtida como saída da 2-D FT, num bitmap monocromático. Para isso foram utilizadas duas rotinas de processamento de imagem distintas: a primeira foi desenvolvida nesse trabalho e se utiliza de técnicas de morfologia matemática e segmentação, a segunda utiliza-se do algoritmo Ridge Detection proposto por Steger (51) aliado a um pré-processamento.

O algoritmo de matriz Pencil modificado proposto por Ekstrom (49) é baseado no trabalho de Hua e Sarkar (50). Uma matriz de pencil é definida como o conjunto de matrizes na forma $A - \lambda B$, onde $\lambda \in \mathbb{C}$, \mathbb{C} representa o conjunto de números complexos e A e B são matrizes $n \times n$ (32). Essa técnica utiliza a transformada de Fourier no tempo sobre a resposta de alguns receptores ultrassônicos e obtém o número de onda dos modos de propagação partir de uma matriz Pencil modificada, a qual estima as constantes de propagação complexas associados a cada modo de onda guiada.

Nas técnicas acima, os pontos f-k obtidos não estão correlacionados entre si e, apesar de quando plotados em conjunto ser possível identificar visualmente as curvas de dispersão, não existe nenhuma informação sobre a qual delas cada ponto pertence, ou seja, os pontos f-k obtidos não estão inerentemente agrupados em alguma estrutura de dados conveniente. Além disso, as curvas podem cruzar entre si e é possível haver pontos espúrios identificados incorretamente pelos algoritmos das técnicas citadas. A fim de solucionar esse inconveniente, propõe-se aqui um algoritmo para o reconhecimento e separação das curvas de dispersão a partir de uma varredura horizontal a ser utilizado em conjunto com os algoritmos de extração dos pontos f-k.

Nesse trabalho os algoritmos são aplicados em diferentes estudos de caso, a saber, sinais simulados de placa retangular fina, sinais simulados de poços multicamadas com diferentes estruturas internas.

1.3

Objetivo

Nesse trabalho deseja-se desenvolver, implementar e comparar diferentes algoritmos de extração de curvas de dispersão em dados de distintos estudos de caso e compará-los. Um dos algoritmos é uma extensão algoritmo de 2-D FT com base em processamento de imagem, outro é uma alteração no algoritmo de matriz Pencil modificado para melhor identificação dos números de onda com base em duas matrizes de redução de posto utilizadas. Também se propõe um algoritmo para reconhecimento e separação das curvas que é utilizado sobre a saída das técnicas de extração citadas.

1.4

Contribuição da dissertação

Essa dissertação fornece as seguintes contribuições à literatura existente:

- Adição de técnicas de processamento de imagem para extração dos máximos locais de amplitude na matriz f-k que representam as curvas de dispersão;
- Alteração ao algoritmo de matriz Pencil proposto por Ekstrom (49) para melhor correlacionar os números de onda obtidos pelas duas matrizes de redução de posto, permitindo identificar com maior certeza pontos f-k pertencentes às curvas de dispersão;
- Avaliação da influência dos parâmetros de entrada na saída dos algoritmos utilizados;
- Comparação qualitativa das respostas de diferentes algoritmos de extração de curvas de dispersão com base em dados de entrada de diferentes origens.

2

Fundamento Teórico

2.1

Ondas ultrassônicas guiadas

Os conceitos desse trabalho estão fundamentados na propagação de ondas ultrassônicas em meio elástico, que pode ser ilustrada como o efeito de uma perturbação localizada sobre um objeto que é transmitida para outras regiões dele (52). O fenômeno de propagação de ondas aparece em diferentes circunstâncias, tal como a propagação de som pelo ar, a transmissão de ondas eletromagnéticas e ondas observadas na superfície da água em resposta a um distúrbio (53). A avaliação da qualidade material de uma estrutura pode utilizar-se de características de propagação de ondas em sólidos e líquidos (5).

Uma onda que se propaga em um meio elástico pode ser caracterizada por sua frequência f , número de onda k , amplitude A e velocidade de fase c_p (4).

A velocidade de fase indica a velocidade que a fase da onda se propaga pelo meio. Ela se relaciona com a frequência e número de onda através da equação

$$c_p = \frac{\omega}{k} \quad , \quad (2-1)$$

onde $\omega = 2\pi f$ é a frequência angular. Ondas que se propagam em meios sólidos sem fronteiras possuem dois modos distintos. O modo longitudinal, de velocidade c_L , está associada ao movimento de partículas paralelamente à direção de propagação da onda por meio de tensão e compressão, e ela também é encontrada na propagação em fluidos. O outro modo, de velocidade c_T , é transversal e se caracteriza por se propagar em direção perpendicular ao movimento da onda (2). Fluidos não apresentam característica de propagação transversal. A impedância acústica W pode ser descrita como a razão entre a pressão acústica pelo fluxo de volume acústico em um meio (54). Ela se relaciona com a velocidade longitudinal c_L e densidade ρ através de

$$W = \rho c_L \quad , \quad (2-2)$$

e é uma propriedade característica de um material (4).

As ondas abordadas aqui são guiadas, que se diferem das ondas volumétricas por se propagarem em um meio confinado entre bordas (55). Elas podem se propagar em estruturas simples, como uma chapa fina (30), ou mais complexas, como um cilindro multicamada (56). As mesmas possuem a característica de cobrir grande porção de uma estrutura, ao contrário de ondas

volumétricas que atendem a uma região localizada (4). Essa característica de ondas volumétricas obriga que um transdutor deva de ser movido ao longo da superfície para que se possa fazer uma análise apropriada, ao passo que com ondas guiadas essa inspeção pode se dar com transmissão a partir de apenas uma posição (4), como é ilustrado na figura 2.1. Além de maior alcance, ondas guiadas também costumam fornecer maior sensibilidade a pequenas variações nas características de um material, o que permite uma melhor análise da integridade estrutural dos corpos sob inspeção (4).




Figura 2.1: a) Inspeção por ondas volumétricas com excitação por feixe normal. b) Inspeção por ondas guiadas com excitação por feixe angulado. Adaptado de (4).

Uma diferença importante entre os dois tipos de ondas citados é que as ondas guiadas apresentam característica dispersiva (4). Isso significa que a velocidade de fase das ondas propagadas varia em função da frequência, enquanto no caso das ondas volumétricas esses valores são constantes em um meio linear homogêneo e isotrópico com baixas perdas (2). Tipicamente, existem múltiplos modos de onda guiada que podem propagar em um meio, cada um com uma relação entre frequência e número de onda ou frequência e velocidade de fase própria, que é a relação de dispersão. A propagação de uma

onda multimodal pode ser descrita por

$$u(x, t) = \sum_{n=1}^q A_n e^{j(k_n x - \omega t)} \quad , \quad (2-3)$$

onde $u(x, t)$ é o deslocamento da onda na posição, x , e tempo, t . Os termos A_n e k_n são, respectivamente, amplitude e número de ondas associados ao modo de propagação n , ω é a frequência angular e q é o número de modos de propagação da onda guiada.

Quando o sinal de resposta a um estímulo ultrassônico é recebido por um grupo de sensores, as informações dos diversos modos de uma onda podem estar sobrepostas tanto no domínio do tempo quanto no domínio de frequência (4). Dessa forma, são necessárias técnicas de processamento de sinal que permitem separar essas características de dispersão dos modos distintos, tal como o uso de representação dos sinais no domínio tempo-frequência (TFR) (37)(39), a visualização dos sinais no domínio f-k a partir de 2-D FT (28) e a estimativa dos números de onda associados às frequências dos modos propagados por meio do método de Pencil (49)(50).

A relação de dispersão de uma onda varia de acordo com a geometria e em função das condições de contorno do meio de propagação e das características do material, como a velocidade transversal da onda, c_T , a velocidade longitudinal, c_L , e a densidade, ρ (57). Isso permite que se caracterize a estrutura analisada quanto à sua geometria e material a partir das curvas de dispersão derivadas do processamento de sinais capturados por receptores ultrassônicos (58).

2.1.1

Ondas de Lamb e efeito acustoelástico

Ondas de Lamb são ondas guiadas que se propagam ao longo de duas superfícies paralelas que se alongam de forma análoga a infinita em um meio homogêneo e isotrópico, como ao longo de uma placa fina (59)(60). Elas são marcadas pelas interferências entre múltiplas reflexões de ondas transversais e longitudinais (61). As ondas de Lamb são compostas por modos de propagação simétricos (S0, S1, S2...) e anti-simétricos (A0, A1, A2...) (4). As curvas de Lamb téóricas para uma placa de alumínio com espessura 3mm e material homogêneo de velocidade transversal $c_T = 3133$ são mostradas na figura 2.2.

Nesse trabalho as curvas de dispersão são representadas nos domínios frequência-número de onda e frequência-slowness. Slowness (s), também chamada de tempo de percurso ou vagarosidade, é uma unidade recíproca à velocidade de fase, como mostra a equação 2-4 (4). A mesma é frequentemente utilizada para caracterizar a propagação de ondas sísmicas (62), onde a slow-




Figura 2.2: Curvas de dispersão teóricas de uma placa de alumínio com espessura 3mm e velocidade transversal $c_T = 3133$.

ness é linearmente associada ao tempo de percurso de uma onda ao longo de distintas camadas de um sistema (63). A slowness pode ser obtida através dos valores de frequência, f , e número de onda, k , a partir da equação 2-4. A figura 2.3 apresenta as curvas de dispersão teóricas para a mesma placa abordada na figura 2.2 no domínio slowness \times frequência.

$$s = \frac{1}{c_p} = \frac{k}{\omega} \quad (2-4)$$

A introdução de tensão mecânica em um sólido causa alteração na velocidade de propagação das ondas ultrassônicas, caracterizando o fenômeno acustoelástico, que é resultado de um comportamento elástico não-linear (64). A partir da avaliação das diferenças de tempo de propagação observadas em sinais captados de ondas acústicas com relação a medidas de referência em estruturas análogas em estado natural, sem estresse, é possível avaliar o estresse a qual essas estruturas estão submetidas (65). Essas características fazem com que a acustoelasticidade encontre uso nas áreas de END e SHM, uma vez que tensão mecânica está diretamente relacionado à fadiga estrutural (66), em indústrias como a de engenharia civil (67), aeroespacial (10) e geomateriais (64).

Em ondas ultrassônicas guiadas que se propagam em um corpo sob tensão, as alterações resultantes são mais complexas, devido ao caráter dispersivo e multimodal dessas ondas (68) e a variação de velocidade observada também




Figura 2.3: Curvas de dispersão de Lamb teóricas de uma placa de alumínio com espessura 3mm e velocidade transversal $c_T = 3133$ representadas no domínio slowness \times frequência.

é associada à frequência (66). Distintos modos de propagação são afetados diferentemente pela introdução de tensão (69), o que faz com que seja comum o uso de excitação de modos específicos para o monitoramento da tensão, escolhendo-se aqueles que apresentam alterações perceptíveis de velocidade com estresse (66). Essa característica também é observada nos modos de propagação de ondas de Lamb se propagando em placas finas (70).

2.2

Transformada de Fourier bidimensional

A transformada de Fourier permite alterar a representação de um sinal no domínio do tempo ou espaço para o domínio de frequência ou número de onda, respectivamente (71). Esta transformada é uma generalização da série de Fourier complexa, que expande uma função periódica em termos de senos e cossenos (72). A saída da FT de uma função contínua, $f(x)$, é uma função de valor complexo, $F(u)$, em que, a grosso modo, a magnitude indica a influência da frequência ω na função original, e a fase é referente ao deslocamento de fase da senoide com esta frequência (33).

A equação da transformada de Fourier, $F(u)$, de uma função contínua no domínio do tempo, $f(x)$, é apresentada na equação

$$F(u) = \mathcal{F}\{f(x)\} = \int_{-\infty}^{\infty} f(x)e^{-j2\pi ux} dx \quad , \quad (2-5)$$

onde $j = \sqrt{-1}$ é a unidade imaginária (33). Para que se reverta ao domínio do tempo ou espaço, utiliza-se a transformada inversa de Fourier, que resulta $f(x)$ a partir de $F(u)$, através da equação (33)

$$f(x) = \mathcal{F}^{-1}\{F(u)\} = \int_{-\infty}^{\infty} F(u)e^{j2\pi ux} du \quad . \quad (2-6)$$

É possível executar essa operação sobre duas variáveis a partir da transformada de Fourier bidimensional (2-D FT). Dessa forma, pode-se obter a função $F(u, v)$ como resultado da transformada sobre a função contínua $f(x, y)$ (73). A equação da 2-D FT é apresentada em 2-7, e sua inversa em 2-8.

$$F(u, v) = \mathcal{F}\{f(x, y)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y)e^{-j2\pi(ux+vy)} dx dy \quad (2-7)$$

$$f(x, y) = \mathcal{F}^{-1}\{F(u, v)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v)e^{j2\pi(ux+vy)} dx dy \quad (2-8)$$

A partir da 2-D FT, é possível obter a representação $U(\omega, k)$ no domínio frequência-número de onda (f-k) a partir do sinal de uma onda $u(x, t)$ no tempo-espaço (t-s), tal como representado na equação 2-3.

Os sinais obtidos pelos sensores ultrassônicos são discretizados, e, dessa forma, é preciso utilizar a forma discreta da transformada para processá-los. A Transformada Discreta de Fourier de uma sequência $x[n]$ com N elementos é (74)

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j(2\pi kn/N)} \quad . \quad (2-9)$$

A implementação computacional mais comum da Transforma de Fourier para tratar uma sequência de dados discreta é a Fast Fourier Transform (FFT), que se baseia na decomposição das operações da Transformada Discreta de Fourier em produtos por fatores nulos (71). A mesma tem uma complexidade computacional de notação $O(N \log N)$, onde N é o tamanho do array de dados (71). Nesse trabalho são utilizadas implementações dessas transformadas discretas fornecidas pelo software Matlab®.

2.3

Determinação das curvas de dispersão a partir de 2-D FT

Os sinais ultrassônicos captados pela propagação das ondas guiadas são compostos por senoides tanto no domínio do tempo quanto no espaço (28). Para um conjunto de dados obtidos por sensores igualmente espaçados a um estímulo ultrassônico, pode-se fazer a transferência da matriz de dados no domínio t-s para o domínio f-k a partir da 2-D FT, resultando numa matriz de amplitudes em frequências e números de onda discretos (28).

A FT possui natureza periódica e as componentes de frequência de um sinal aparecem repetidas periodicamente no espectro obtido pela transformada, com as componentes repetidas distantes entre si por uma frequência f_s , que corresponde à frequência de amostragem do sinal original (71). Quando um sinal é amostrado numa frequência insuficiente para a captura da sua resposta em frequência sem que haja overlap entre as componentes repetidas resultantes da FT, ocorre o fenômeno de aliasing (74). Para evitar sua ocorrência ao se utilizar a 2-D FT, é necessário que se garanta uma frequência de amostragem em ambos domínios, tempo e espaço, que respeite o teorema de amostragem de Nyquist, como indica a equação 2-10. Nesta, $f_s^{(i)}$ é a frequência de amostragem no domínio i , e $f_{max}^{(i)}$ é a mais alta frequência que compõe o sinal amostrado no domínio i . Quando o domínio representado é o espacial, a frequência é denominada de número de onda.

$$f_s^{(i)} \geq 2f_{max}^{(i)} \quad (2-10)$$

O *padding* de zeros sobre a matriz de dados original no domínio t-s é uma técnica utilizada nos algoritmos desse projeto e consiste no acréscimo de uma sequência de zeros ao final das linhas e colunas da matriz, de forma que seus números de elementos alcancem um valor específico. Com isso, é possível melhorar a eficiência computacional da rotina de FFT a partir do aumento da quantidade de amostras até que se alcance a potência de 2 mais próxima. Esta técnica possui também a característica de suavizar as curvas das amostras em frequência ou número de onda do sinal transformado (72). Um contraponto ao uso desta técnica é um possível aumento de consumo de memória utilizada pelo algoritmo.

A figura 2.4 apresenta a resposta simulada por Elementos Finitos a um estímulo de um transdutor ultrassônico captada por múltiplos sensores posicionados sobre a superfície de uma placa de alumínio plana, com densidade $2700kg/m^3$, espessura $3mm$ e comprimento $800mm$. O transdutor aplica um sinal do tipo sinc com componente de frequência até $2.5MHz$, que é recebido pelos sensores, linearmente espaçados de $0.1mm$, a uma frequência de $40MHz$. O tempo é medido a partir do disparo do sinal do emissor acústico, enquanto a distância dos sensores é medida com relação a esse mesmo emissor. Na figura, é possível observar o atraso do sinal de onda correlacionado ao afastamento com relação à origem da excitação, assim como diferentes envelopes de onda em cada sinal, associados aos modos de propagação.

A partir dos sinais obtidos, monta-se uma matriz em que cada coluna corresponde ao vetor de resposta no tempo de um sensor, que é apresentada como imagem na figura 2.5.




Figura 2.4: Sinais capturados por receptores ultrassônicos simulados ao longo do tempo.

Aplica-se 2-D FT sobre a matriz composta por esses sinais e obtém-se a matriz de amplitudes correlacionadas a pontos f-k, que pode ser representada como uma imagem, que é vista na figura 2.6. Na imagem, a amplitude relativa aos pontos f-k é visualizada por tons distintos de cinza e os tons mais claros indicam maior amplitude. Pela imagem, é possível perceber que existem indícios das curvas, mas a visualização é difícil. A mudança de representação das amplitudes para a escala logarítmica permite a visualização clara das curvas e é mostrada na figura 2.7. As curvas são geradas pelas conjunções dos máximos locais de cada frequência e são facilmente identificáveis na nova imagem. Essa mudança, no entanto, introduz bastantes artefatos à figura nas regiões que anteriormente eram mais escuras e não possuíam curvas. Nesse trabalho utiliza-se imagens f-k resultantes da 2-D FT na escala logarítmica, para maximizar a quantidade de informação disponível sobre as curvas. Este trabalho explora a 2-D FT em conjunto com dois algoritmos de processamento de imagem para se obter diretamente os pontos f-k das curvas de dispersão a partir de uma entrada como a figura 2.7, a saber, uma técnica proposta neste trabalho baseada em operações morfológicas e um algoritmo de identificação de estruturas curvilíneas proposto por Steger (51).




Figura 2.5: Matriz de sinais tempo-espaco visualizada como imagem.




Figura 2.6: Figura f-k gerada a partir da 2-D FT em escala decimal demonstrando as curvas de dispersão associadas à placa de alumínio. As curvas são difíceis de se identificar.




Figura 2.7: Figura f-k gerada a partir da 2-D FT na escala logarítmica demonstrando as curvas de dispersão associadas à placa de alumínio. As curvas de dispersão são visíveis e mais artefatos são percebidos ao fundo da imagem.

3

Métodos de extração e separação das curvas de dispersão

Neste capítulo, são abordados os três métodos de extração de curvas de dispersão explorados neste trabalho. Os dois primeiros métodos são baseados na 2-D FT (28) e o último, no algoritmo de matriz Pencil, proposto por Ekstrom (49). Também é proposto um algoritmo para a separação dos pontos f - k extraídos em curvas de dispersão associadas.

3.1

Extração de curvas de dispersão por 2-D FT e processamento de imagem

Apesar das curvas de dispersão serem visíveis nas imagens geradas a partir das matrizes resultantes do algoritmo 2-D FT, a extração automática dos pontos f - k a partir desses dados é não-trivial, uma vez que a imagem resultante pode apresentar muitos artefatos. Como as matrizes f - k podem ser representadas por imagens, técnicas computacionais podem ser utilizadas para identificar os pixels referentes às curvas de dispersão e suas posições traduzidas em pontos f - k . Os algoritmos de imagem utilizados aqui fornecem como resultado uma máscara monocromática de pixels onde os brancos indicam as curvas de dispersão.

Para identificação das curvas, foi proposto a combinação de algoritmos de processamento de imagem de morfologia matemática, que se resumem a técnicas para analisar e processar estruturas geométricas, e segmentação de imagem, utilizada para particionar uma imagem em regiões distintas. As operações morfológicas utilizadas no algoritmo de extração de curva são: dilatação (75), fechamento (75) e skeleton (76), estes são explicados na seção 3.1.3. A operação de segmentação utilizada é a de Thresholding Otsu (77) local; abordada na seção 3.1.3.6. Outra abordagem por imagem para extração das curvas também foi utilizada neste trabalho, baseada no algoritmo Ridge Detection proposto por Steger (51). Em ambas as técnicas indicadas acima, foi necessária a aplicação de um pré-processamento na imagem f - k de entrada em determinados casos. Isto foi feito com o objetivo de reduzir os artefatos presentes nas imagens geradas pela 2-D FT.

3.1.1

Pré-processamento

Para que artefatos presentes nas imagens de entrada dos algoritmos tenham um peso menor sobre a identificação das curvas, foi utilizado um filtro,

escolhido a partir da análise das componentes espectrais da imagem.

A partir de uma imagem f-k na escala de cinza, como a da figura 2.7, mostrada na seção 2.3, é possível gerar a representação espectral da figura 3.1 com uma aplicação da 2-D FT, onde maiores luminosidades indicam amplitudes mais elevadas. Essa segunda aplicação da 2-D FT é diferente da primeira, que tem um sentido físico de mudança do domínio tempo-espço para frequência-número de onda. Aqui, o domínio espacial x-y de uma imagem é transformado em domínio espectral u-v, que correlaciona as componentes de frequência verticais e horizontais da imagem.




Figura 3.1: Espectro da imagem de entrada com intensidades em escala logarítmica e posteriormente normalizadas para melhor visualização.

Na figura 3.1, é possível perceber maiores amplitudes nas retas $u = 0$ e $v = 0$, assim como a presença de informação espectral até as frequências mais elevadas. Com objetivo de reduzir artefatos associados a mudanças de cores bruscas, é proposto um filtro passa-faixas gaussiano (78) com composição espectral da figura 3.2. Esse tipo de filtro tem característica de possuir duas frequências de corte, uma superior e outra inferior, com baixa atenuação das componentes do sinal de entrada apenas na região de frequência compreendida entre as mesmas. Aqui, as frequências de corte do sinal foram calculadas automaticamente pelo programa ImageJ®, com base nos parâmetros de entrada de suavizar estruturas menores que 3 pixels e maiores que 40 pixels. O filtro escolhido também possui uma linha preta em $u = 0$ de espessura de um pixel, para filtrar as componentes horizontais da imagem. Os pixels brancos indicam total permissividade do filtro quanto às frequências associadas. A permissividade é

proporcional à luminosidade dos pixels, o que se traduz em uma rejeição total das frequências associadas a pixels pretos.




Figura 3.2: Espectro do filtro utilizado para remover artefatos da imagem.

A filtragem é feita a partir da multiplicação ponto a ponto da figura espectral da imagem original com o espectro do filtro, o que corresponde a uma convolução no domínio x-y (73). A convolução é definida pela equação 3-1 (78), onde $f(x, y)$ é uma função que indica a intensidade do pixel na linha, x , e coluna, y , de uma imagem de dimensões $M \times N$ e $h(x, y)$, é um filtro que pode ser representado como imagem. A convolução é obtida no domínio da frequência de acordo com a equação 3-2 (79).

$$f(x, y) * h(x, y) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f(m, n)h(x - m, y - n) \quad (3-1)$$

$$f(x, y) * h(x, y) \Leftrightarrow F(u, v)H(u, v) \quad , \text{ onde } F(u, v) = \mathcal{F}\{f(x, y)\} \quad (3-2)$$

Devido à natureza circular da FT discreta, a mesma causa uma repetição periódica de uma imagem e de sua transformada (79). Por isso, é necessário o uso de padding de zeros durante a computação da 2-D FT da imagem, de forma a impedir que haja erro de *wraparound*, que ocorre devido à multiplicação envolvendo os termos repetidos dos sinais amostrados que estão sendo convolucionados. Este fenômeno é ilustrado na figura 3.3 (79). Dada uma imagem original com dimensões $A \times B$ e um filtro com dimensões $C \times D$, cada uma delas deve ser completada com zeros (pixels pretos) de forma a alcançar as dimensões $P \times Q$, onde

$$P \geq A + C - 1 \quad , \quad (3-3)$$

$$Q \geq B + D - 1 \quad . \quad (3-4)$$

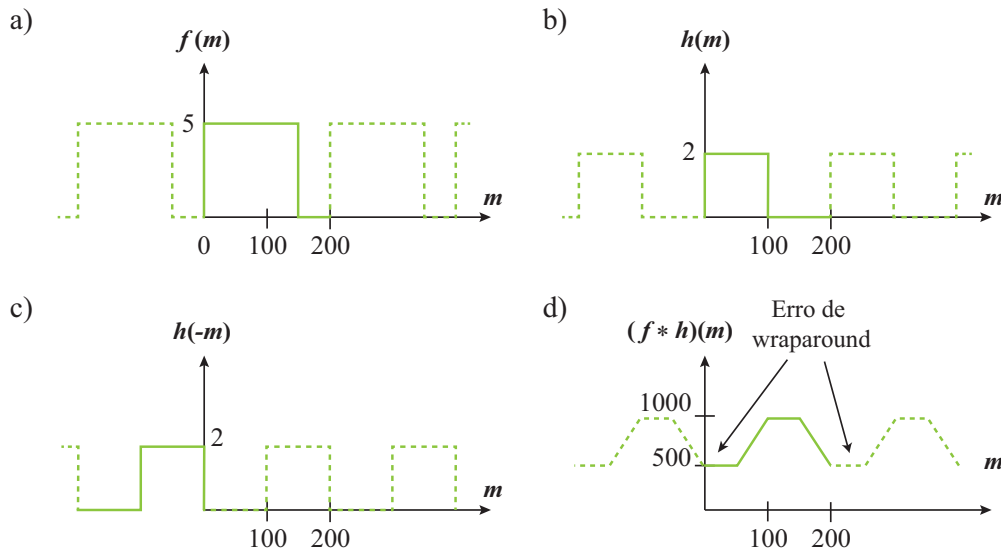


Figura 3.3: Ilustração do erro de wraparound causado pelo uso da FT discreta, onde as linhas sólidas representam pontos amostrados ou calculado pela FT, e as linhas pontilhadas são as repetições geradas pela FT discreta. a) Sinal amostrado $f(m)$ de 200 amostras; b) Sinal amostrado $h(m)$ de m amostras; c) Sinal $h(m)$ invertido para operação de convolução; d) Convolução com erro de wraparound. Adaptado de (78).

Após a multiplicação, no domínio $u-v$, das imagens redimensionadas e da aplicação da FT inversa para o retorno ao domínio $x-y$, utiliza-se apenas os primeiros $A \times B$ pixels da matriz resultante para obter o resultado filtrado (79).

Após a filtragem da figura $f-k$ original, aplica-se uma conversão para o sistema de cores YUV, de onde usa-se apenas a componente de luminância como saída. Isso confere maior intensidade de branco aos pixels relativos às curvas, o que facilitará seu reconhecimento por parte dos algoritmos de processamento.

Na figura 3.4 compara-se a figura resultante do pré-processamento com a original. É possível perceber que ruído de fundo ainda é observável nas figuras, porém a maior uniformidade de intensidade de luminosidade de pixels conferida é suficiente para possibilitar melhores extrações por partes dos algoritmos baseados em imagem.

3.1.2

Extração de curvas de dispersão por 2-D FT com Ridge Detection

Esse algoritmo, proposto por Steger (51), se baseia na detecção de estruturas curvilíneas por meio da criação de um modelo matemático que pode representar linhas no espaço da imagem. Inicialmente, modela-se linhas




Figura 3.4: a) Imagem original das curvas de dispersão obtida pela 2-D FT. b) Imagem resultante do pré-processamento.

em imagens considerando a característica de uma seção unidimensional (1-D) perpendicular a sua direção, uma vez que esse perfil é apresentado ao longo de todos os pontos da linha (80). Em 1-D, uma linha com o perfil denominado *bar-shaped*, de espessura $2w$, pode ser descrita pela equação

$$f_a(x) = \begin{cases} 0, & x < -w \\ 1, & |x| \leq w \\ a, & x > w \end{cases}, \quad (3-5)$$

onde $f_a(x)$ representa o valor de intensidade do sub-pixel em algum campo (escala de cinza, nas imagens em que trabalharemos), $a \in [0, 1]$ é um termo usado para levar em conta a diferença de contraste entre os dois lados da linha, $x = 0$ denota a posição real da linha a ser detectada e linhas de intensidade h podem ser generalizadas por $hf_a(x)$ (51). Steger supõe, também, uma outra modelagem 1-d da seção da linha, com caráter parabólico, de acordo com a equação (81)

$$f_p(x) = \begin{cases} h(1 - (x/w)^2), & |x| \leq w \\ 0, & |x| > w \end{cases}, \quad (3-6)$$

onde h indica a intensidade máxima da linha.

Pode-se observar que para encontrar a verdadeira posição da linha no caso de uma imagem 1-D, $z(x)$, no caso descrito pela equação 3-6, basta encontrar o ponto onde a derivada $z'(x)$ é nula, utilizando o módulo de sua segunda derivada $z''(x)$ como critério para identificação de linhas protuberantes (51). Steger propõe a convolução da imagem por um kernel Gaussiano de equação 3-7, de desvio padrão, σ , para suavização, de forma a melhorar o comportamento

de suas derivadas. A aplicação desse kernel também faz com que linhas do tipo *bar-shaped* descritas pela equação 3-5, que originalmente não podem ter sua posição real encontrada apenas pela derivada $z'(x)$, possam ser identificadas por $z'(x)$ e ter um mínimo em sua posição para $z''(x)$ se for assegurada a relação de desvio padrão descrita pela equação 3-8 em seu kernel gaussiano.

$$g_\sigma = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (3-7)$$

$$\sigma \geq \frac{w}{\sqrt{3}} \quad (3-8)$$

Objetivando a computação da convolução discreta para a suavização da imagem, é necessário o uso kernels Gaussinos integrados (82). A imagem discreta $z[n]$ se relaciona a $z(x)$ pela equação

$$z(x) = z[n] \quad \text{para} \quad x \in (n - 1/2, +1/2]. \quad (3-9)$$

Além disso, para a obtenção da posição das linhas com precisão sub-pixel no caso discreta, a imagem discreta $z[n]$ é aproximada por uma Transformada de Taylor após ser convoluída com o kernel Gaussiano. Sendo r , r' e r'' , as estimativas das derivadas locais no ponto n da imagem convoluída, o polinômio de Taylor é igual a (51)

$$p(x) = r + r'x + \frac{1}{2}r''x^2 \quad . \quad (3-10)$$

A posição da linha, nesse caso, é o ponto onde a derivada do polinômio, $p'(x)$, é nula, ou seja

$$x = -\frac{r'}{r''} \quad . \quad (3-11)$$

O ponto n é considerado um ponto pertencente a uma linha se ele estiver entre $x \in [-1/2, 1/2]$ e tiver a segunda derivada acima de um valor definido pelo usuário.

Considerando a imagem bidimensional (2-D), as estruturas curvilíneas podem ser modeladas como curvas $s(t)$ com o perfil observado em 1-D similar aos perfis parabólico ou *bar-shaped* na direção perpendicular à linha, denotada aqui como $n(t)$. Nesse caso, uma linha é identificada quando a $n'(t)$ é nula e $n''(t)$ tem módulo suficientemente grande (51).

Com a convolução da imagem 2-D com kernels Gaussianos bidimensionais, as derivadas parciais r_x , r_y , r_{xx} , r_{xy} e r_{yy} são estimadas. A direção em que a segunda derivada de $z(x, y)$ alcança o valor máximo é usada como direção $n(t)$, e é obtida através do cálculo dos autovalores e autovetores (83) da matriz Hessiana

$$\mathbf{H}(x, y) = \begin{bmatrix} r_{xx} & r_{xy} \\ r_{xy} & r_{yy} \end{bmatrix} . \quad (3-12)$$

O autovetor que corresponde ao maior autovalor encontrado é a direção perpendicular à linha, (n_x, n_y) . Assim como no caso 1-D, uma aproximação polinomial quadrática é usada, verificando-se caso sua derivada chegue a zero no pixel em questão, que sinaliza que esse pixel pertence a uma linha. O valor da segunda derivada de (n_x, n_y) é usado como parâmetro para a definição de linha suficientemente protuberante, de acordo com um valor selecionado pelo usuário (51).

Utilizou-se a implementação do algoritmo fornecida pelo programa ImageJ®. Nesse, os parâmetros dados ao usuário para a detecção das ridges são:

- Espessura da linha, que é seu diâmetro expresso em pixels;
- Contraste alto, que é o valor mais elevado em escala de cinza que pixels de linhas detectadas devem possuir (0 a 255);
- Contraste baixo, que é o mais baixo valor na escala de cinza que os pixels das linhas detectadas podem ter.

Para a identificação das curvas através das imagens 2-D FT, utilizou-se 22 para espessura da linha, 230 para contraste alto e 50 para contraste baixo como parâmetros para o algoritmo Ridge. O resultado obtido pelo processamento de Ridge do exemplo da placa de alumínio da seção 2.3 é mostrado na figura 3.5.




Figura 3.5: Máscara de pixels obtida pela aplicação do algoritmo de Ridge sobre as curvas de dispersão da placa de alumínio descrita na seção 2.3.

3.1.3

Conceitos básicos de morfologia matemática

Na morfologia matemática, objetos da imagem são representados como conjuntos (84). Em uma imagem digital na escala de cinza, os conjuntos pertencem a \mathbb{Z}^3 , que é o espaço tridimensional formado por números inteiros, onde cada elemento é uma tripla, (x, y, f) , com coordenadas horizontal, x , vertical, y , e nível de cinza discreto, f , de cada pixel. Para simplificação, os conceitos a seguir tratarão de imagens monocromáticas pertencentes a \mathbb{Z}^2 , cujas duplas, (x, y) , representam as coordenadas dos pixels brancos ou pretos.

Dado um conjunto A em \mathbb{Z}^2 , se $a = (a_1, a_2)$ é um elemento de A , pode-se escrever (78)

$$a \in A \quad . \quad (3-13)$$

Caso todos os elementos de um conjunto A pertençam a um conjunto B , pode-se escrever (78)

$$A \subseteq B \quad , \quad (3-14)$$

A união de dois conjuntos A e B é denotada como (78)

$$C = A \cup B \quad (3-15)$$

e a interseção por (78)

$$C = A \cap B \quad . \quad (3-16)$$

O complemento de um conjunto A é o conjunto de elementos não contidos em A , como mostra a equação (78)

$$A^c = \{w \mid w \notin A\} \quad . \quad (3-17)$$

A diferença de dois conjuntos A e B é o conjunto de elemento de A não pertencentes a B (78):

$$A - B = \{w \mid w \in A, w \notin B\} = A \cap B^c \quad . \quad (3-18)$$

A reflexão de um conjunto A é escrita como \hat{A} , como definido na equação (78)

$$\hat{A} = \{w \mid w = -a \forall a \in A\} \quad , \quad (3-19)$$

onde $-a$ representa que as coordenadas de um ponto $a = (a_1, a_2)$ estão substituídas por $(-a_1, -a_2)$. A equação 3-20 mostra a translação de um ponto A por um ponto $z = (z_1, z_2)$, descrita como $(A)_z$ (78).

$$(A)_z = \{w \mid w = a + z \forall a \in A\}, \quad (3-20)$$

onde a soma dos pontos a e z é representada por $a + z = (a_1 + z_1, a_2 + z_2)$. Estes conceitos estão ilustrados na figura 3.6.

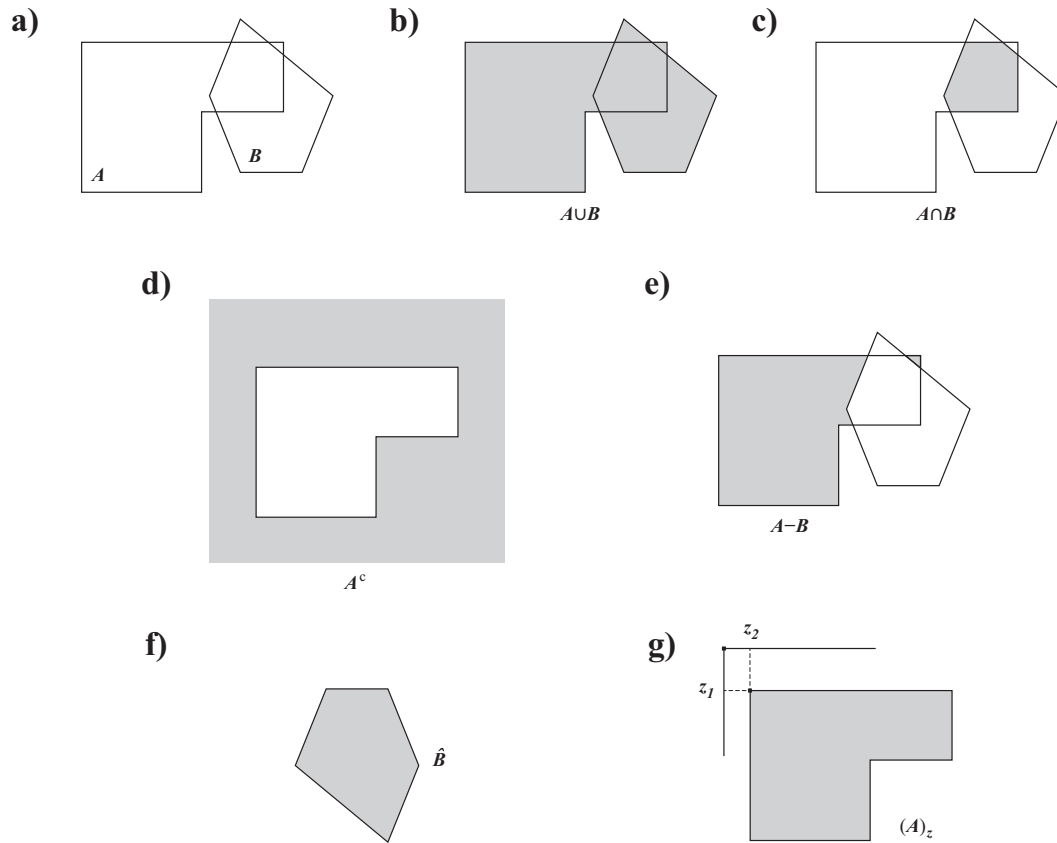


Figura 3.6: Ilustração das operações fundamentais de morfologia matemática: a) Conjuntos de entrada. b) União. c) Interseção. d) Complemento. e) Diferença. f) Reflexão. g) Translação. Adaptado de (78).

3.1.3.1 Dilatação

Expressões morfológicas são escritas em termos de um elemento estruturante e um conjunto, A , de pixels em primeiro plano, no caso de imagens monocromáticas (84). Na figura 3.7 são representadas as diferenças entre conjuntos, imagem gráfica e imagem digital. As imagens usadas neste trabalho são digitais e, portanto, são representadas como matrizes retangulares, fazendo com que os conjuntos utilizados e os elementos estruturantes também tenham que estar embutidos em uma matriz retangular.

Aqui, considerou-se A como o conjunto de pixels brancos de uma imagem, e o mesmo vale para o elemento estruturante, B . O elemento estruturante também pode possuir pixels "não importa", significando que o valor desses pixels durante o cálculo do algoritmo podem ser ignorados ou serem utilizados para se obter algum resultado particular desejado.

A equação 3-21 (78) descreve a operação de dilatação com respeito a A e B . A mesma consiste em refletir B com relação a sua própria origem e transladar essa reflexão com respeito a w . O resultado da dilatação de A por

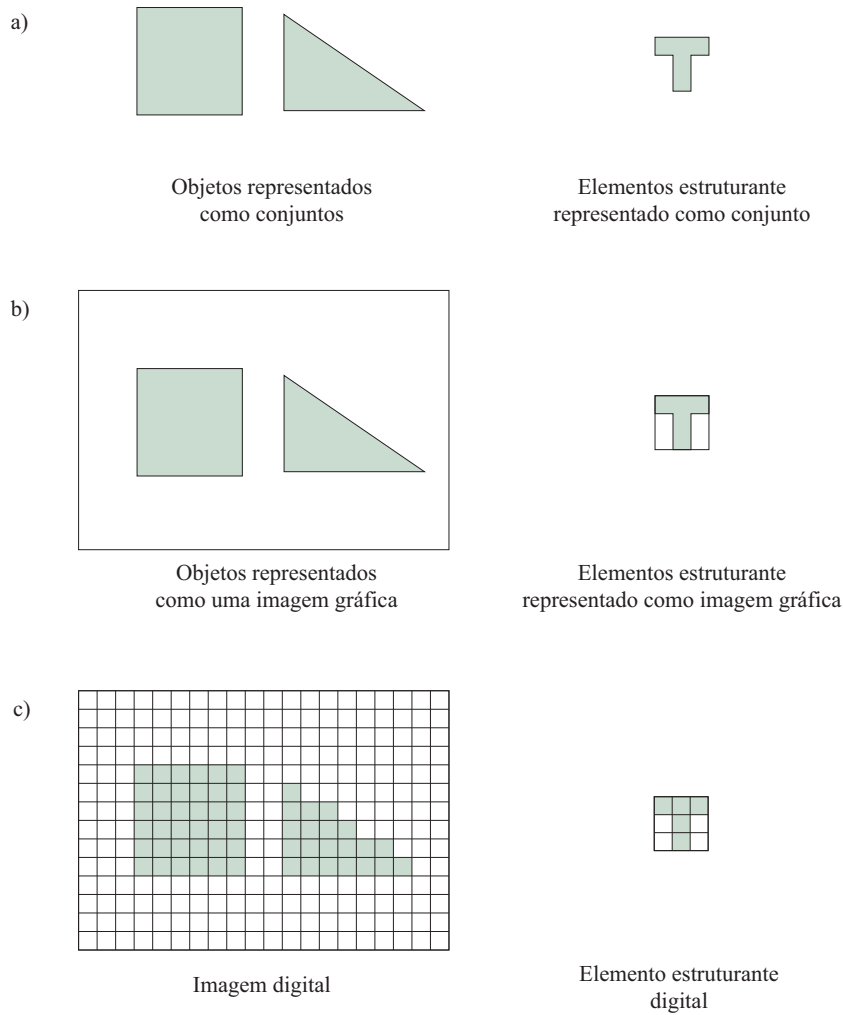


Figura 3.7: a) Objetos representados como conjuntos; b) Objetos e elementos estruturais inseridos em um plano de fundo, representando uma imagem; c) Objetos e plano de fundo digitalizados. Adaptado de (78).

B é o conjunto de todos os deslocamentos w em que os elementos de primeiro plano da reflexão, \hat{B} , sobrepõem ao menos um elemento de A .

$$A \oplus B = \{w \mid (\hat{B})_w \cap A \neq \emptyset\} \quad (3-21)$$

Uma ilustração da operação de dilatação é apresentada na figura 3.8. Os círculos em A e B representam a origem das duas imagens. Observa-se que a operação de dilatação tem a característica de aumentar a área dos elementos de uma imagem e essa característica varia de acordo com tamanho e formato do elemento estruturante. Na figura, o elemento estruturante, B , é uma linha horizontal com dois pixels de comprimento, o que explica a expansão das estruturas de A na direção horizontal e sentido da direita, este último ditado pela posição da origem do elemento estruturante.




Figura 3.8: Representação da dilatação de um conjunto A com relação a um elemento estruturante B . Adaptado de (78).

3.1.3.2 Erosão

Essa operação morfológica também se baseia em um conjunto de pixels de primeiro plano, A , de uma imagem e em um elemento estruturante, B . A erosão pode ser definida pela equação 3-22 (78), que indica que a erosão de A por B é o conjunto de pontos, w , em que B , quando transladado de w , está contido em A .

$$A \ominus B = \{w \mid (B)_w \subseteq A\} \quad (3-22)$$

Na figura 3.9, um exemplo de erosão é demonstrado. Esta operação tem a característica de contrair elementos de uma imagem, em alguns casos até fazendo com que estes desapareçam. A extensão e sentido da contração variam de acordo com o elemento estruturante utilizado.




Figura 3.9: Representação da erosão de um conjunto A com relação a um elemento estruturante B . Adaptado de (78).

3.1.3.3

Fechamento

Esta operação morfológica depende de um conjunto, A , de pixels de primeiro plano de uma imagem e de um elemento estruturante, B . Ela consiste em uma operação de dilatação de A por B , seguida por uma erosão, como demonstra a equação 3-23 (78). A operação pode ser interpretada como o complemento da união de todas as translações de B de forma que este não sobreponha A em nenhum pixel. O conceito é ilustrado na figura 3.10.

$$A \bullet B = (A \oplus B) \ominus B \quad (3-23)$$

O fechamento tem como características a tendência de suavizar contornos, juntar seções muito próximas e preencher buracos pequenos juntos ao contorno dos objetos da imagem.

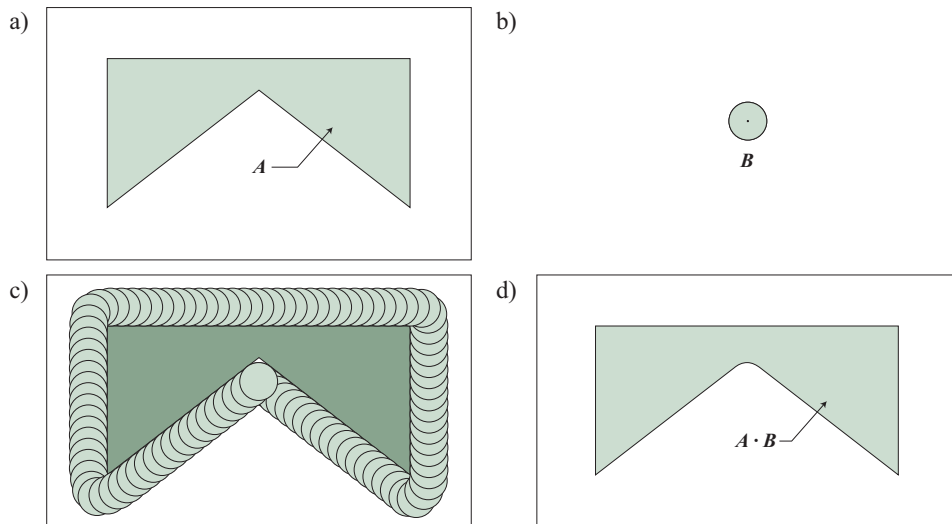


Figura 3.10: a) Imagem composta pelo conjunto A . b) Elemento estruturante B . c) Translações de B que não sobrepoem A . d) Fechamento de A por B . Adaptado de (78).

3.1.3.4

Abertura

Operação morfológica análoga ao fechamento. Consiste na erosão de um conjunto, A , por um elemento estruturante, B , representado na equação 3-24 (78). O resultado pode ser entendido como a união das translações de B que ficam contidas em A . Tem característica de suavizar os cantos dos objetos e remover pequenos elementos e protusões.

$$A \circ B = (A \ominus B) \oplus B \quad (3-24)$$

3.1.3.5 Skeleton

Este algoritmo morfológico tem a característica de gerar esqueletos, de apenas um pixel de largura, dos objetos da imagem de entrada. O esqueleto $S(A)$ de um conjunto, A , pode ser expresso em termo de operações de erosão e abertura por um elemento estruturante, B , como

$$S(A) = \bigcup_{k=0}^K S_k(A) \quad , \text{ dado} \quad (3-25)$$

$$S_k(A) = (A \ominus kB) - (A \ominus kB) \circ B \quad , \quad (3-26)$$

onde $(A \ominus kB)$ indica k operações de erosões seguidas sobre A . O total de iterações K na equação 3-25 é o total de erosões sucessivas possíveis em A sem que o resultado seja um conjunto vazio (nenhum pixel branco restante, no caso deste trabalho). K assume o valor

$$K = \max\{k \mid (A \ominus kB) \neq \emptyset\} \quad . \quad (3-27)$$

O software Matlab®, utilizado aqui, possui também um algoritmo chamado de Spur (78), que é utilizado como complemento ao Skeleton para remover pixels espúrios resultantes da aplicação do último.

3.1.3.6 Thresholding de Otsu local

A técnica de Thresholding é utilizada para segmentação de imagem, ou seja, separá-la em regiões com base na similaridade dos elementos presentes (78). As regiões de fronteira são escolhidas automaticamente pelo algoritmo de forma a atender a algum parâmetro de interesse. Para algum atributo da imagem, como intensidade de vermelho, saturação e brilho, o threshold é um grupo de valores pré escolhidos que são usados como limiares que definem as diferentes regiões.

Nesse trabalho, utiliza-se imagens em escala de cinza a serem subdivididas em duas regiões e o atributo para o threshold é a intensidade de luminosidade dos pixels. Os pixels com intensidade abaixo do valor determinado serão categorizados como pretos, e os demais serão brancos.

A determinação do valor de threshold pode ser vista na maioria dos casos como objetivando minimizar o erro médio resultante de se subclassificar os pixels em um número reduzido de regiões. O algoritmo de Thresholding de Otsu é uma alternativa para segmentação de imagens em duas regiões que é caracterizada por escolher o valor de threshold que minimiza a variância dentro de cada uma delas (77). O algoritmo usa o histograma da imagem como

referência, que é um array de uma dimensão em que cada elemento representa o número de pixels contendo uma determinada intensidade de luminosidade. A figura 3.11 mostra um exemplo da aplicação de Threshold de Otsu.



Figura 3.11: Exemplos de Threshold de Otsu em uma imagem em escala de cinza. Imagem obtida da biblioteca de python scikit-image. CC0 pelo fotógrafo Lav Varshney (85).

O Threshold local utilizado nesse trabalho consiste em obter o valor de threshold, através do algoritmo de Otsu, para cada pixel da imagem com base apenas na aplicação do algoritmo sobre uma janela pequena em torno do pixel em questão, ao invés de usar a imagem inteira.

3.1.4

Extração de curvas de dispersão por 2-D FT com operações morfológicas

Como abordado na seção 2.3, o objetivo do algoritmo é identificar os pontos f-k relacionados às curvas de dispersão com base em uma figura resultante da 2-D FT de uma array de resposta de sensores ultrassônicos. Aqui, transformaremos a imagem f-k em uma máscara em que os pixels brancos representam os pontos das curvas de dispersão. O fluxograma representando os passos percorridos pelo algoritmo do processamento de imagem sobre a figura gerada pela 2-D FT é exibido na figura 3.12.




Figura 3.12: Fluxograma exibindo as técnicas usadas para gerar a máscara que delinea as curvas de dispersão.

O processo detalhado consiste em:

1. A imagem original da 2-D FT em escala de cinza, onde a intensidade de luminosidade dos pixels está correlacionada à amplitude dos pontos f-k, é convertida para o espaço de cores HSV. A matriz bidimensional

correspondente ao campo de brilho é extraída e passa a ser a nova imagem sobre a qual o algoritmo trabalhará;

2. A matriz dos valores da imagem em escala de cinza é normalizada com valores entre 0 e 1. Dessa forma, o contraste da figura é aumentado fazendo multiplicações sucessivas da matriz por si mesma, elemento por elemento, até que a intensidade média dos pixels fique abaixo do valor 0.25, escolhido empiricamente;
3. Utiliza-se a operação de dilatação sobre a imagem com um elemento estruturante, \mathbf{B} , escolhido como um disco de raio 1 pixel, expresso matricialmente como

$$\mathbf{B} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix} . \quad (3-28)$$

Essa operação tem como objetivo juntar pontos pertencentes a uma mesma curva que possam ter se separado devido à operação anterior, acentuar os pixels mais claros e reduzir a quantidade de ruído pertencente visível na figura;

4. Aumenta-se o contraste, mais uma vez, através da multiplicação da matriz da figura por si mesma, objetivando, novamente, acentuar os pixels mais claros que representam as curvas;
5. Utiliza-se da operação de fechamento com o mesmo elemento estruturante \mathbf{B} , para novamente conectar pontos das curvas que tenham se separado;
6. Threshold de Otsu local, com uma janela de tamanho $30 \times 30 \text{ pixel}^2$, é utilizado para gerar uma máscara de pixels brancos correspondentes às curvas sobre fundo preto. Esse algoritmo de Threshold local foi alterado nesse trabalho para considerar os pixels como brancos apenas se estivessem acima do threshold de Otsu somado a um offset. Essa alteração objetiva evitar que pixels fossem identificados como brancos em áreas da imagem de tons escuros uniformes. Quanto mais alto o valor de offset, maior a tendência do algoritmo a perder pontos da curva, ao mesmo tempo que menos pixels espúrios relacionados a ruído são captados. Aqui utilizou-se 0.015 de valor de offset para todas as extrações (intensidade de luminosidade do pixel definida como valor de 0 a 1, sendo 1 branco);
7. Operação de Skeleton é usada para fazer que as curvas tenham apenas um pixel de largura. Em conjunto, utiliza-se a operação Spur para remover pixels espúrios.

Ao fim do algoritmo, os pixels brancos da imagem são traduzidos para pontos f - k baseados na escala da figura original.

Na figura 3.13 são mostradas algumas etapas do processo do algoritmo no tratamento da imagem gerada a partir do sinal da figura 2.4 mostrada na seção 2.3. Pelo resultado, é possível observar que existem algumas porções ausentes nas curvas e alguns pixels brancos indesejados. Essas deficiências do algoritmo serão tratadas pelo algoritmo de rastreo e separação de curvas proposto na seção 3.3.




Figura 3.13: a) Imagem f - k original. b) Resultado parcial do algoritmo após aumento de contraste iterativo da etapa 2. c) Resultado parcial do algoritmo após operação de fechamento da etapa 5. d) Resultado final do algoritmo.

3.2

Extração de curvas de dispersão por algoritmo Matriz Pencil Modificado

Este é um algoritmo proposto inicialmente por Ekstrom (49). No trabalho original, o mesmo é utilizado para estimar as curvas de dispersão com base em medições acústicas de poços de petróleo. Este algoritmo é um estimador espectral híbrido baseado em uma extensão de uma matriz Pencil unidimensional. Para duas matrizes complexas $n \times n$, A e B , chama-se de matriz Pencil

o polinômio de primeiro grau $A - \lambda B$, onde $\lambda \in \mathbb{C}$ e \mathbb{C} representa o conjunto de números complexos (32). Os dados de entrada esperados são uma matriz tempo-espaco com um número alto de amostras temporais e relativamente poucas medições espaciais.

Os dados de entrada podem ser descritos como $u(x, t)$, onde x representa a posição linear do receptor ultrassônico com relação ao transdutor que gera a onda e t é o tempo decorrido a partir do momento da transmissão. Uma transformada de Fourier temporal é aplicada sobre a resposta de cada um dos sensores, resultando em $U(x, \omega)$, onde $\omega = 2\pi f$, como demonstra a equação 3-29. Os números de onda em cada frequência podem ser estimados com base na hipótese de que para uma dada frequência, ω_o , o sinal, $U(x, \omega_o)$, obtido pela série de Fourier temporal, pode ser aproximado pela soma de q exponenciais complexas, ou números de onda, através da equação 3-30, onde k_i são os números de onda.

$$U(x, \omega) = \mathcal{F}_t\{u(x, t)\} = \int_{-\infty}^{\infty} u(x, t)e^{-j\omega t} dt \quad (3-29)$$

$$U(x, \omega_o) \approx \sum_{i=1}^q a_i e^{-jk_i x} \quad (3-30)$$

A sequência resultante da série de Fourier temporal sobre a resposta de um receptor em um conjunto de m posições espaciais é indicada como:

$$\mathbf{u}[n] = U(x_n, \omega_o) \text{ , onde } n = 1, 2, \dots, m \text{ ,} \quad (3-31)$$

sendo n o índice da amostra espacial, e m o número total de sensores ultrassônicos. Para a obtenção de melhores resultados, p , o número de modos estimados pelo algoritmo, é recomendado por Ekstrom a ser superior ao número real de modos das ondas guiadas, q , e inferior a $m - q$ (49):

$$q < p < m - q \quad (3-32)$$

A partir de uma dada sequência $\mathbf{u}[n]$, uma matriz de Hankel \mathbf{H} é gerada. Uma matriz de Hankel possui a característica de ser uma matriz quadrada em que os valores ao longo de cada anti-diagonal são constantes (86). Uma matriz Hankel, \mathbf{A} , tem cada elemento, $\mathbf{A}_{i,j}$, na linha, i , e coluna, j , de valor governado pela equação

$$A_{i,j} = a_{i+j-2} \quad (3-33)$$

para uma dada sequência $a_0, a_1, \dots, a_{2n-1}, a_{2n}$ (87). A matriz \mathbf{H} , usada para o algoritmo Pencil, possui $m - p$ pontos na primeira coluna e a última linha contém os últimos $p + 1$ pontos de $u[n]$. A matriz $\mathbf{H0}$ é formada a partir da remoção da primeira coluna de \mathbf{H} , e a matriz $\mathbf{H1}$ a partir da remoção da última coluna de \mathbf{H} :

$$\mathbf{H0} = \begin{bmatrix} \mathbf{u}[2] & \mathbf{u}[3] & \cdot & \mathbf{u}[p+1] \\ \mathbf{u}[3] & \mathbf{u}[4] & \cdot & \mathbf{u}[p+2] \\ \cdot & \cdot & \cdot & \cdot \\ \mathbf{u}[m-p+1] & \cdot & \cdot & \mathbf{u}[m] \end{bmatrix}, \quad (3-34)$$

$$\mathbf{H1} = \begin{bmatrix} \mathbf{u}[1] & \mathbf{u}[2] & \cdot & \mathbf{u}[p] \\ \mathbf{u}[2] & \mathbf{u}[3] & \cdot & \mathbf{u}[p+1] \\ \cdot & \cdot & \cdot & \cdot \\ \mathbf{u}[m-p] & \cdot & \cdot & \mathbf{u}[m-1] \end{bmatrix}. \quad (3-35)$$

De acordo com Hua e Sarkar (88), os autovalores generalizados das matrizes $\mathbf{H0}$ e $\mathbf{H1}$ são os termos exponenciais de uma sequência expressa pela soma de exponenciais complexas.

A estimativa de p exponenciais pode ser obtida a partir da solução do problema de autovalor associado às seguintes equações Backward e Forward, respectivamente:

$$[\mathbf{H1}]^+ \mathbf{H0} - \lambda \mathbf{I} = 0, \quad (3-36)$$

$$[\mathbf{H0}]^+ \mathbf{H1} - \lambda \mathbf{I} = 0, \quad (3-37)$$

onde $[\]^+$ indica a matriz inversa generalizada de Moore-Penrose, também chamada de pseudo-inversa (89). Este tipo de matriz é indicado para computar algoritmos de mínimos quadrados para equações lineares, que é o caso presente. Seja \mathbf{A} uma matriz complexa não-quadrada qualquer, existe uma pseudo-inversa $[\mathbf{A}]^+$ que satisfaz:

- As colunas de $[\mathbf{A}]^+$ são combinações lineares dos conjugados das linhas de \mathbf{A} ;
- As linhas de $[\mathbf{A}]^+$ são combinações lineares dos conjugados das linhas de \mathbf{A} ;
- $\mathbf{A}[\mathbf{A}]^+ \mathbf{A} = \mathbf{A}$.

Além disso a relação das matrizes $[\mathbf{A}]^+$ e \mathbf{A} é recíproca com respeito aos itens acima (89).

Uma vez que os autovalores λ podem ser igualados aos termos exponenciais do somatório da equação 3-30, é possível estimar os números de onda k_i por

$$k = -\Im \{ \log (1/\lambda) / \Delta x \}, \quad (3-38)$$

onde Δx é o período espacial, \log é o logaritmo natural (90) e \Im é o operador que retorna a parte imaginária da entrada, o uso deste faz com que sejam descartados os termos imaginários dos números de onda estimados.

Após a obtenção dos números de onda a partir dos dois métodos, é preciso encontrar os valores nos arrays Forward, \mathbf{F} , e Backward, \mathbf{B} , que correspondem

a um mesmo número de onda. O trabalho original de Ekstrom propõe que os arrays fossem ordenados individualmente de forma crescente e que valores de mesma posição de ordenação fossem comparados, sendo excluídos aqueles que apresentassem uma diferença acima de um valor de tolerância pré determinado. A equação 3-39 mostra o critério de aceitação de um par de valores de número de onda de índice i nos arrays ordenados Forward, \mathbf{F}_{ord} , e Backward, \mathbf{B}_{ord} , com base em uma tolerância σ . Os arrays resultantes ao fim do processo de exclusão são denotados aqui como Backward, $\hat{\mathbf{B}}_{\text{ord}}$, e Forward, $\hat{\mathbf{F}}_{\text{ord}}$.

$$|\mathbf{F}_{\text{ord}}(i) - \mathbf{B}_{\text{ord}}(i)| \leq \sigma \quad , \text{ onde } i = 1, \dots, p \quad (3-39)$$

Dos r valores remanescentes, é feita uma média daqueles de mesmo índice, de forma a obter um valor único como mostrado na equação 3-40. O array resultante \mathbf{N} é o conjunto de valores de números de onda associados à frequência utilizada.

$$\mathbf{N}(i) = \frac{\hat{\mathbf{F}}_{\text{ord}}(i) + \hat{\mathbf{B}}_{\text{ord}}(i)}{2} \quad , \text{ onde } i = 1, \dots, r \quad (3-40)$$

Aqui, propõe-se o uso de um algoritmo para comparar e parear as exponenciais dos dois arrays com base na menor diferença. Isso é alcançado por meio da geração de uma matriz de diferença \mathbf{D} onde o elemento da linha i e coluna k obedece a equação

$$\mathbf{D}(i, j) = |\mathbf{F}(i) - \mathbf{B}(j)| \quad . \quad (3-41)$$

Essa matriz representa a combinação de diferenças de cada par de valores de número de onda pertencentes aos arrays de Forward e Backward. Para encontrar a melhor correspondência de números de onda dos arrays, ou seja, a combinação de pares com a menor diferença, utiliza-se um algoritmo de resolução de problema de atribuição linear (91). Este é um tipo de problema onde objetiva-se atribuir uma linha a cada coluna de forma a minimizar a soma dos elementos escolhidos. Nesse caso, a meta é encontrar o conjunto de pares com a menor soma de diferenças entre valores Forward e Backward. Das duplas encontradas, avalia-se se o módulo da diferença está abaixo de um valor de tolerância pré-definido, σ , de acordo com

$$|\mathbf{F}(i) - \mathbf{B}(j)| \leq \sigma \quad , \quad (3-42)$$

e o par é excluído caso não. Por fim, uma média de cada par remanescente é calculada, resultando no array de números de onda final.

A execução dessa técnica para todos os valores de frequência da matriz $U(x, \omega)$ resulta nos valores f-k que representam as curvas de dispersão. Apesar disso, não é claramente definido quais pontos f-k pertencem à curva correspon-

dente a cada modo de dispersão, já que os valores de uma curva específica não necessariamente ocupam uma mesma linha da matriz para todas as frequências. Este é um problema similar ao encontrado nos algoritmos da seção 3.1, isto é, quando a máscara das curvas é gerada, os pontos f-k relativos às curvas são identificados, mas não se tem a informação sobre a qual curva pertencem.

Para fornecer resultados satisfatórios com diferentes conjuntos de dados de entrada, alguns parâmetros de entrada para o algoritmo foram tornados ajustáveis:

- *mg* - Margem de módulo da diferença aceitável para o pareamento dos valores de número de onda calculados Backward e Forward;
- *p* - Número de modos esperados a serem buscados pelo algoritmo de Pencil;
- *sStep* - Razão do undersampling introduzido nos dados de entrada com respeito às posições espaciais dos sensores;
- *sInit* - Primeira posição espacial dos dados de entrada a ser utilizada. É dada como uma razão de 0 a 1 entre a primeira e última posição disponíveis;
- *sSamp* - Número de posições espaciais, *m*, dos dados de entrada que são utilizados para o algoritmo. As amostras espaciais, portanto, começam em *sInit*, estão espaçadas entre si com relação aos dados de entrada de acordo com *sStep* e totalizam em *sSamp*;
- *tStep* - Razão do undersampling introduzido nos dados de entrada com respeito ao tempo.

Na figura 3.14 é apresentado um fluxograma simplificado das etapas do algoritmo descrito nesta seção.

A aplicação do algoritmo para o caso da placa de alumínio descrito na seção 2.3 com os parâmetros de Pencil vistos na tabela 3.1 resultou na extração vista na figura 3.15. Na mesma, são expostos resultados relativos a dois métodos de pareamento dos números de onda estimados Forward e Backward, a saber, o pareamento originalmente proposto por Ekstrom (49) e o pareamento proposto nesse trabalho. Os pontos f-k foram plotados como círculos descontínuos, para que os pontos encontrados fora das curvas não gerassem traçados indesejáveis no plot. Comparando os dois pareamentos, é possível observar que o pareamento proposto neste trabalho extrai um número consideravelmente maior de pontos f-k relativos às curvas, resultando em menos lacunas ao longo das curvas de dispersão. Apesar do pareamento proposto identificar mais pontos espúrios, estes estão isolados em sua maioria,

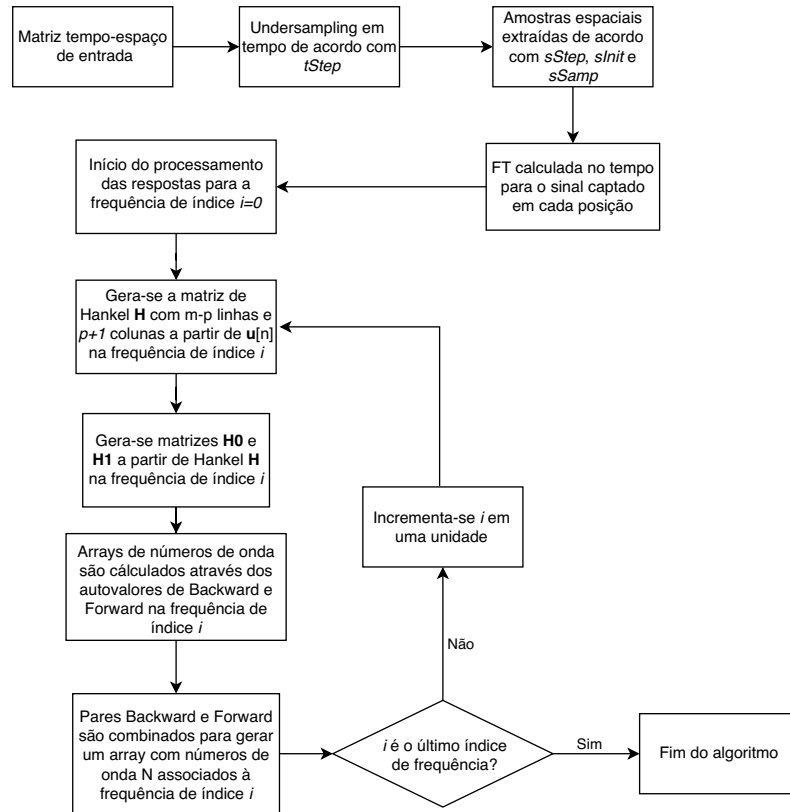


Figura 3.14: Fluxograma das etapas do algoritmo Pencil.

e são excluídos durante a aplicação do algoritmo de separação das curvas, visto na seção 3.3. A diferença na quantidade de pontos encontrados com os dois pareamentos é ainda maior quando se aumenta o número de modos de propagação, p , a serem estimados pelo algoritmo, destacando a relevância do algoritmo de pareamento proposto neste trabalho. Seria possível reduzir o número de pontos espúrios diminuindo o valor da margem de pareamento, mg , mas isso também resultaria em menos pontos extraídos pelo algoritmo Pencil.

É importante notar que, na figura 3.15, cada curva de dispersão é formada por pontos f-k de cores diversas. As cores dos pontos f-k estão relacionadas à ordem em que os números de onda correspondentes aparecem no array estimado, indicando que o resultado obtido pelo algoritmo de Pencil não possui nenhuma organização inerente dos valores de número de onda associados aos modos obtidos para cada frequência e que é necessário um pós-processamento para a separação desses pontos f-k em curvas de dispersão distintas. Essa separação é efetuada através do algoritmo proposto na seção 3.3. Com o uso do mesmo, é possível separar os pontos f-k pertencentes as curvas distintas de cada modo de dispersão e ao mesmo tempo retirar os pontos espúrios, que não pertencem a nenhuma delas.

Parâmetro	Valor
mg	0.1
p	100
$sStep$	1:5
$sInit$	0.464
$sSamp$	120
$tStep$	1:1

Tabela 3.1: Parâmetros do algoritmo Pencil usados com os dados de entrada da placa de alumínio descrita na seção 2.3.

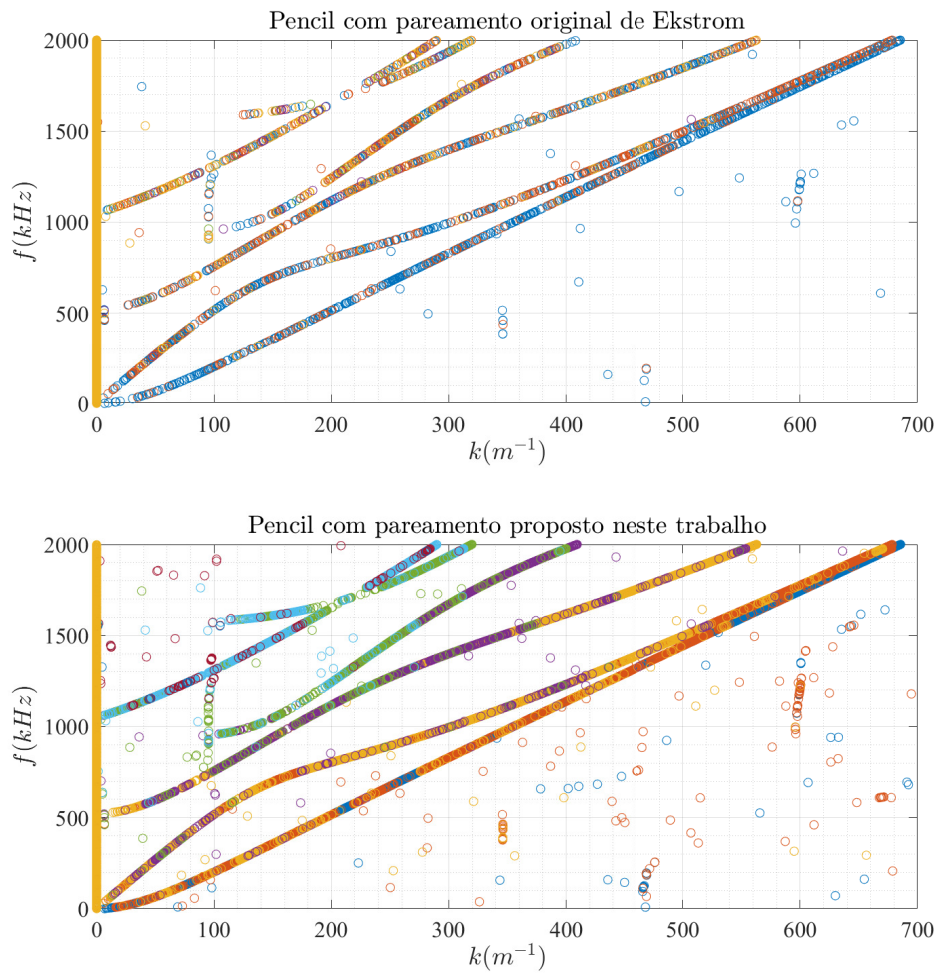


Figura 3.15: Pontos f-k obtidos pelo algoritmo Pencil para a placa de alumínio da seção 2.3, utilizando o pareamento proposto por Ekstrom, assim como o pareamento proposto neste trabalho.

3.3

Algoritmo de rastreamento e separação das curvas

Como visto nas seções 3.1 e 3.2, após a identificação dos pontos f-k, ainda é preciso atribuir a qual das curvas de dispersão cada ponto pertence, o que é uma tarefa não-trivial, sobretudo quando há sobreposição entre elas. Além disso, é possível que haja ausências de pontos em determinados trechos das curvas identificadas pelos algoritmos, ou pontos que não parecem pertencer a nenhuma das curvas encontradas. Nesta seção apresenta-se o algoritmo proposto para lidar com essas deficiências dos algoritmos de extração abordados.

A entrada desse algoritmo pode ser a máscara resultante da aplicação do algoritmo 2-D FT ou uma matriz de pontos f-k gerada pelo algoritmo matriz pencil. Em ambos os casos, é feita uma varredura horizontal da entrada em busca de pontos f-k encontrados pelos algoritmos. No caso da entrada ser a matriz da imagem contendo a máscara que delinea as curvas, os pixels brancos são interpretados como possíveis pontos f-k pertencentes às curvas. Nesse caso, a imagem também pode ter seus eixos trocados para que as colunas sejam varridas como frequência ou como número de onda. Caso a entrada seja uma matriz resultante do algoritmo de pencil, mostrado na seção 3.2, só é possível usar as colunas como frequências, uma vez que os valores de número de onda são resultados do algoritmo, e não possuem espaçamento constante.

O princípio básico do funcionamento do algoritmo está expresso no fluxograma da figura 3.16. O kernel mostrado é executado para cada uma das colunas da matriz de dados de entrada, da esquerda pra direita. Para cada ponto f-k encontrado, o algoritmo calcula sua distância para os pontos projetados das curvas existentes para a mesma coluna. O ponto é adicionado à curva com a menor distância calculada caso esse valor seja inferior a um limiar. Caso o limiar seja excedido, cria-se uma nova curva em que esse ponto é o primeiro elemento. O valor limite adotado é relevante principalmente em dados que contenham curvas muito próximas ou algumas seções ausentes. Caso o limite seja muito baixo, as chances do algoritmo subdividir uma mesma curva aumenta, mas caso seja alto demais, é possível que curvas distintas sejam unidas de forma errada.

Ao fim da verificação de uma coluna, são feitas projeções das curvas existentes para a coluna seguinte, por meio de uma aproximação linear com base nos últimos n pontos (variável ajustável para lidar com diferentes dados de entrada). Para resultados com Pencil, é usado $n = 50$, enquanto que para dados advindos dos algoritmos baseados em 2-D FT utiliza-se $n = 30$. As projeções também são relevantes em trechos dos dados de entrada em que haja lacunas nas curvas. Nesses casos, as projeções podem se estender até ligar

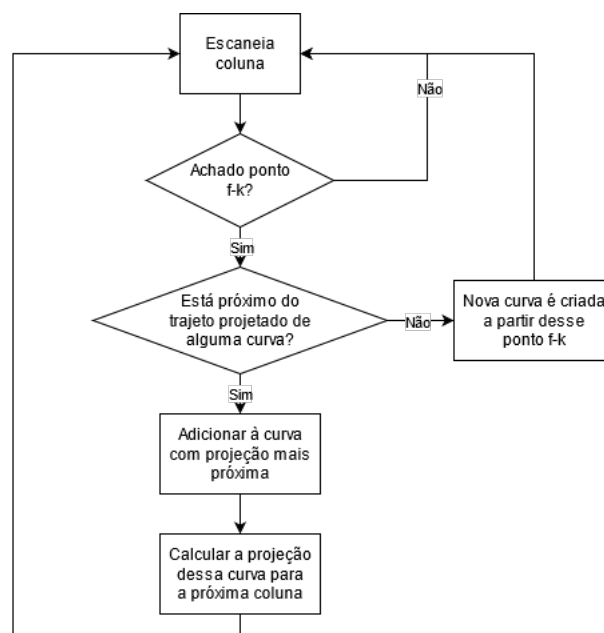


Figura 3.16: Fluxograma resumindo o funcionamento do algoritmo de rastreamento e separação das curvas.

as duas partes, e após isso os pontos $f-k$ projetados são substituídos por valores interpolados a partir dos pontos nas bordas dessas lacunas. Se o número de pontos de uma projeção sobre um trecho de ausência de curva ultrapassar um valor limite, p_{max} , considera-se que a curva finalizou no último ponto válido e projeções novas não são feitas.

Após toda a matriz de entrada ter sido escaneada, o algoritmo verifica ainda para cada curva as seguintes condições:

- O número total de elementos de uma curva deve ser superior a um valor pré-definido como argumento da função que executa o algoritmo. Esse valor deve ser escolhido levando em conta a amostragem da variável que representa as colunas, assim como o tamanho total das curvas esperadas. Esse argumento ajuda o algoritmo a excluir artefatos maiores que podem ser identificados como curvas de outra forma. Para os resultados expostos no capítulo 5, utilizou-se o valor de 300 para processar dados de Pencil e 100 elementos no mínimo para dados baseados em 2-D FT;
- Para uma dada curva, a relação entre o número de pontos encontrados e o número de pontos resultantes de projeções e interpolações deve estar acima de um valor pré-definido por um argumento de entrada do algoritmo. Isso evita que o algoritmo forme curvas pela junção de artefatos não desejados que tenham proximidade entre si, mas não formam uma curva de fato. Para dados extraídos por Pencil, utilizou-

se a relação com valor 0.7, enquanto para dados baseados em 2-D FT utilizou-se 0.4.

- Curvas que possuem um *range*, ou seja, diferença entre valor máximo e mínimo, de frequência ou número de onda abaixo de 5% do range total da matriz de entrada são removidas. Isso é utilizado para remover artefatos horizontais (frequência nos plots f-k) que ocorrem sobretudo nos algoritmos baseados em 2-D FT, e verticais (número de onda nos plots f-k), que ocorrem em Pencil.

Um exemplo do uso do algoritmo aparece na figura 3.17, em que foi utilizada a máscara obtida pelo algoritmo Ridge mostrada na figura 3.5 de entrada. Os pontos verdes são aqueles identificados como curvas, os azuis indicam pontos de um trajeto projetado sobre uma região em que há ausência de curvas, e os amarelos são os que ligam as lacunas por interpolação. Aqui, a figura da máscara, originalmente demarcando curvas brancas sobre fundo preto, teve suas cores invertidas para fornecer maior visibilidade. No plot das curvas extraídas da figura 3.17, cada curva foi mostrada com uma cor distinta, ressaltando a característica do algoritmo de separar as curvas relativas aos diferentes modos de propagação de onda.




Figura 3.17: Pontos identificados, projetados e interpolados encontrados pelo algoritmo para a máscara de entrada obtida por Ridge na seção 3.1.2, assim como as curvas separadas a partir dos pontos.

É importante ressaltar que o passo utilizado para passar de uma coluna para a seguinte ao fim de cada iteração do algoritmo de comparação varia de acordo com a origem dos dados de entrada. Quando o dado de entrada é a máscara monocromática obtida pelas técnicas que usam 2-D FT descritas na seção 3.1, o algoritmo de separação processa as colunas da matriz que representam linhas verticais da imagem e utiliza um passo de 5. Para o

caso dessas técnicas, utilizou-se a matriz formatada de forma que as colunas representassem valores distintos de número de onda, o que forneceu melhores resultados que utilizar as colunas como frequências.

Em dados de entrada obtidos pelo método de Pencil descrito na seção 3.2, a matriz já representa pontos f - k das curvas diretamente, e um elemento dessa matriz, $(M)_{i,j}$, representa o número de onda do modo, i , extraído para uma frequência de índice, j , que tem o valor de frequência, $(F)(j)$, de acordo com um array de entrada, (F) , mono espaçado, escolhido como argumento de entrada do algoritmo. Por isso, o algoritmo de separação usa as colunas para representar as frequências, uma vez que todos pontos de cada coluna representam uma frequência única. O passo utilizado quando o dado de entrada é deste tipo é 1, o que significa que todas as colunas são varridas.

Uma vez que esse algoritmo se utiliza de um escaneamento no sentido de apenas uma das dimensões de uma matriz de dados de entrada, ele só é capaz de identificar perfeitamente curvas que representem função injetoras (92), onde as colunas da matriz representam o contradomínio (92), uma vez que múltiplos pontos de uma curva presentes na mesma coluna seriam identificados como pertencentes a curvas distintas.

4

Estudos de caso

A obtenção das curvas de dispersão pelos algoritmos usados nesse trabalho depende de um matriz tempo-espaço como dado de entrada, que é a resposta no tempo de um grupo de sensores ultrassônicos dispostos em ordem crescente de distância da fonte. Esses dados podem ser obtidos a partir de modelos analíticos associadas à propagação de uma onda, técnicas de computação numérica, como simulação por elementos finitos (93) ou através de experimentos. Neste trabalho utilizou-se dados de simulações por elementos finitos.

4.1

Dados simulados de placa de alumínio

A propagação de ondas guiadas em uma estrutura depende de condições de contorno e as equações analíticas associadas são de difícil resolução e em alguns casos não é possível resolver. O caso de propagação de ondas em uma placa, homogênea e isotrópica é conhecido como ondas de Lamb (94).

Utilizando um software comercial de método de elementos finitos (FEM), foi simulada a propagação de uma onda guiada em uma placa de alumínio com as características materiais mostradas na tabela 4.1, onde h indica a espessura da placa e l seu comprimento. Os dados foram fornecidos por terceiros.

Propriedade	Valor
$c_T(m/s)$	3133
$c_L(m/s)$	6322
$\rho(kg/m^3)$	2700
$h(mm)$	3
$l(mm)$	800

Tabela 4.1: Características materiais de placas de alumínio simulada.

A simulação numérica foi executada com software comercial Ansys®12.1, com 30 elementos por espessura e elementos do tipo plane182 (95). Foi imposto um sinal tipo sinc aplicado como uma deformação fora do plano com frequência de corte $2.5MHz$. Absorvedores foram incluídos nas duas extremidades da placa para emular uma largura infinita (96). Os receptores ultrassônicos foram linearmente espaçados de $0.1mm$, totalizando 7501, e a frequência de amostragem temporal foi de $40MHz$, com um total de 37964 amostras. Nessa simulação os receptores receberam o sinal ultrassônico em

duas direções distintas: a direção x de propagação da onda e a direção y perpendicular ao plano na superfície da placa. Além disso, foram simulados também casos em que a placa era tracionada em suas bordas na direção x com valores de tração uniaxial, paralela à direção de propagação, de 0, 30, 60, 90 e 120 MPa . Assim, para cada um dos casos de tração foram gerados duas matrizes de dados tempo-espaço, uma no eixo x e outra no y . Um diagrama simplificado da simulação é visto na figura 4.1.

Como visto na seção 2.1.1, espera-se que com a adição de estresse sobre a placa, se observe alteração na velocidade de fase dos modos de propagação. Nas curvas de dispersão, isso deveria ser observado como uma alteração de número de onda, sendo essa alteração distinta para cada modo e variando de acordo com a frequência (66).




Figura 4.1: Diagrama simplificado da simulação de propagação em placa de alumínio por FEM.

Na figura 2.4, apresentada na seção 2.3, é mostrada a resposta de alguns sensores no tempo para a simulação em que não há aplicação de tensão, com medições feitas no eixo x de propagação da onda. A distância é medida com relação ao emissor ultrassônico.

4.2

Dados simulados de poço multicamada

Na simulação de poços de petróleo, utilizou-se de uma estrutura com múltiplas camadas cilíndricas concêntricas, com características mecânicas— c_T , c_L e ρ —correspondentes aos materiais que formam as diferentes camadas. Foram utilizadas configurações com e sem a camada de aço de *tubing* e também se simulou estruturas com distintos tipos de defeito de cimentação. Essas simulações foram realizadas pelo Laboratório de Sensores de Fibra Óptica (LSFO), na PUC-RIO.

4.2.1
Poço sem *tubing*

Nessa configuração, foi utilizada uma estrutura modelada por cilíndricos concêntricos de altura $2.133m$. As camadas são formadas por materiais distintos, estes são, partindo do centro, água, aço (*casing*), cimento e formação rochosa, respectivamente. Um diagrama da estrutura, assim como os raios de cada uma das camadas, está representada na figura 4.2

As características de cada material que formam o poço estão descritas na tabela 4.2. Como aço, cimento e rocha são modelados como materiais elásticos e isotrópicos, a velocidade da onda transversal é c_T e a longitudinal, c_L (2). Na água, que é um fluido, a velocidade da onda é longitudinal, c_L (97).




Figura 4.2: Diagrama da seção do poço multicamadas simulado a partir do centro.


Na simulação, o emissor e os receptores ultrassônicos estão posicionados no centro dos cilindros. O emissor se encontra localizado a uma distância h_t

Propriedade	Água	Aço	Cimento	Rocha
$c_T(m/s)$	-	3200	1730	2650
$c_L(m/s)$	1500	5880	3000	4500
$\rho(kg/m^3)$	1000	7800	1800	2300

Tabela 4.2: Características materiais do poço multicamada simulado.

da base dos cilindros e possui a forma de um semi-círculo. Os sensores estão verticalmente espaçados de h_s , com o primeiro posicionado a essa mesma distância do emissor ultrassônico. O número total de sensores é 1830 e essa quantidade foi escolhida com objetivo de fornecer alta resolução para a imagem formada pela matriz da 2-D FT das curvas de dispersão. A excitação imposta foi de um sinal tipo sinc com frequência de corte de $40kHz$, que foi aplicada de forma omnidirecional no centro do modelo, onde o material é a água. A frequência de amostragem temporal é $14.921MHz$, totalizando em 89523 amostras.

O sinal tempo-espaço captado pelos sensores da simulação são mostrados na figura 4.3, onde a distância é medida a partir do emissor e o número de sensores mostrados foi reduzido para aumentar a legibilidade dos sinais. Nela, observa-se que os sinais são captados com mais atraso para sensores em posições mais distantes do emissor, assim como a característica multimodal de propagação.

Figura 4.3: Resposta simulada por FEM em tempo-espaço no placa do poço multicamada sem *tubing*.

4.2.2

Poço com *tubing*

Esta configuração de simulação se diferencia da vista na seção 4.2.1 pela presença da camada de *tubing* dentro da coluna de água. Aqui as camadas

do poço são formadas por, partindo do centro, água, aço (*tubing*), água, aço (*casing*), cimento e formação rochosa, respectivamente. A figura 4.4 ilustra as camadas e documenta as dimensões utilizadas nas simulações.

Como visto na figura 4.4, o posicionamento do emissor e dos sensores obedece a mesma configuração da seção 4.2.1. Novamente, a frequência de amostragem no tempo é de $14.921MHz$, totalizando em 89523 pontos e a excitação por sinal tipo sinc com frequência de corte de $40kHz$ é aplicada omnidirecionalmente. São utilizados 1830 receptores ultrassônicos. As características dos materiais simulados é a mesma do caso sem *tubing* e estão expostas na tabela 4.2.




Figura 4.4: Diagrama da seção do poço multicamadas simulado a partir do centro.

A visualização dos sinais captados no tempo por alguns dos sensores simulados é apresentada na figura 4.5, onde a distância é medida a partir do emissor. Nessa figura também percebe-se a relação da distância dos sensores

com respeito ao transmissor com o atraso para a captação dos sinais. Também se observam pacotes de onda menos definidos e em menor quantidade que no caso sem *tubing*.




Figura 4.5: Resposta simulada por FEM em tempo-espaco no placa do poço multicamada com *tubing*.

4.2.3

Poços com defeito

Os poços descritos nas seções 4.2.1 e 4.2.2 não possuem nenhuma característica dos defeitos que podem acontecer em estruturas reais (18). Como a avaliação da qualidade e integridade da cimentação é uma área de interesse para poços abandonados, novas simulações foram realizadas com diferentes tipos de defeito, de forma que as curvas de dispersão correspondentes pudessem ser comparadas com os casos ideais de qualidade estrutural e de isolamento hidráulico de poços (98), vistas nas seções mencionadas.

4.2.3.1

Defeito de Channeling (CH)

Este tipo de defeito é caracterizado por uma camada de água dentro do anel de cimento (22). Na simulação, é utilizado um cilindro estreito, com impedância acústica igual à da água, dentro da camada de cimento, com espessura determinada de acordo com a simulação. A figura 4.6 ilustra o conjunto.

A espessura da camada de água é identificada como um valor percentual em comparação à espessura do cimento e seus valores variam de 20 a 80% em incrementos de 10%.




Figura 4.6: Vista da seção transversal do poço com defeito de Channeling.

4.2.3.2

Qualidade da cimentação (CQ)

A variação na qualidade do cimento foi modelada como uma mudança em sua impedância acústica de onda longitudinal, que se traduz em uma mudança de densidade (27). Para cada simulação com valores específicos de qualidade, a camada de cimento foi substituída por inteiro pela camada degradada com um valor de impedância acústica constante. A figura 4.7 representa a configuração da simulação. Foram utilizados os valores de impedância acústica de 333, 500, 667, 833, 1000 e 1500 $MRayl$ para uma propagação longitudinal fixa no cimento de $c_L = 3000m/s$.




Figura 4.7: Vista da seção transversal do poço com qualidade de cimentação reduzida.

4.2.3.3

Descolamento interno (SC) e externo (CR)

Estes tipos de defeito ocorrem devido a uma camada de fluido entre o cimento e o *casing* de aço, no caso do descolamento interno (SC), e uma camada de fluido entre o cimento e a formação rochosa, no descolamento externo (CR) (18). Na simulação, utiliza-se um anel cilíndrico concêntrico ao poço junto

à parede interna ou externa da camada de cimento, com propriedades acústicas de fluido iguais às da água. A representação dos descolamentos interno e externo está exposta nas figuras 4.8 e 4.9, respectivamente.




Figura 4.8: Vista da secção transversal do poço com descolamento interno.




Figura 4.9: Vista da secção transversal do poço com descolamento externo.

Para esses dois tipos de defeito, foram feitas simulações distintas, com variação na espessura da camada de fluido introduzida, sendo está indicada como um percentual da espessura da camada de cimento e variando de 20 a 80% em incrementos de 10%.

5

Resultados

Os resultados mostrados nessa seção foram obtidos por meio do processamento dos algoritmos em um computador com os seguintes especificações:

- Processador Intel Core i7 6700K;
- Memória 16 GB DDR4;
- Vídeo NVIDIA GeForce GTX 970.

5.1

Placa de alumínio

Utilizou-se a solução das curvas de dispersão analíticas para ondas de Lamb em uma placa de mesma espessura e material para servir como referência de comparação com as curvas extraídas pelos algoritmos propostos nesse trabalho. Usando as curvas analíticas como referência, o erro RMS (RMSE) normalizado das curvas extraídas foi calculado a partir da diferença entre as frequências, f , com o mesmo número de onda, k . A equação 5-1 descreve o cálculo do erro RMS, e_{RMS} (99), enquanto a equação 5-2 se refere ao erro RMS normalizado, ne_{RMS} (99). O número de pontos comparados entre uma curva analítica e a respectiva curva extraída é representado por N , f_i é a frequência a partir do ponto i extraído da curva, enquanto \hat{f}_i é o i -ésimo ponto da curva analítica.

$$e_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - \hat{f}_i)^2} \quad , \quad (5-1)$$

$$ne_{RMS} = \frac{e_{RMS}}{\bar{f}} \quad , \quad \text{onde} \quad \bar{f} = \frac{1}{N} \sum_{i=1}^N f_i \quad . \quad (5-2)$$

É importante ressaltar que no caso de curvas geradas por Pencil, os termos equiespaçados são os de frequência, então o cálculo do erro se dá por meio da comparação das diferenças dos números de onda k para cada frequência f , através das equações

$$e_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (k_i - \hat{k}_i)^2} \quad , \quad (5-3)$$

$$ne_{RMS} = \frac{e_{RMS}}{\bar{k}} \quad , \quad \text{onde} \quad \bar{k} = \frac{1}{N} \sum_{i=1}^N k_i \quad . \quad (5-4)$$

5.1.1

2-D FT com operações morfológicas

Optou-se por não utilizar o algoritmo de pré-processamento para nenhuma das imagens de entradas. Isso se deve ao fato de que os artefatos observados nelas não serem removidos de forma eficaz pelo pré-processamento, e as modificações introduzidas reduzem a qualidade da extração.

Para a redução do custo computacional de gerar as imagens f-k com a 2-D FT, optou-se por aumentar o período entre as leituras temporais de cada sensor. Dessa forma, reduziu-se o número de amostras por um fator de 10, o que também reduziu a frequência de amostragem efetiva de $40MHz$ para $4MHz$. Esta mudança foi possível porque a maior frequência de interesse a ser observada era de $2MHz$, e, de acordo com o critério de Nyquist (74), a maior componente de frequência f_{max} está correlacionada à frequência de amostragem f_s pela equação

$$f_{max} \leq f_s/2 \quad . \quad (5-5)$$

Os resultados da extração com esse algoritmo para os casos sem tensão sobre a placa de alumínio para sensores com medição no sentido x e y, estão apresentados nas figuras 5.1 e 5.2, respectivamente. As curvas de diferentes cores e identificadas com os nomes dos respectivos modos nas figuras mostram que o algoritmo da seção 3.3 obteve êxito em separar as curvas a partir da máscara de entrada.




Figura 5.1: Curvas de dispersão extraídas por operações morfológicas a partir da placa simulada com sensores no sentido x.

Para as medidas no sentido x, é possível perceber que as curvas extraídas possuem grande acordo com a referência analítica. Em toda a região de frequência e número de onda trabalhada, os pontos foram identificados de acordo com o modelo.




Figura 5.2: Curvas de dispersão extraídas por operações morfológicas a partir da placa simulada com sensores no sentido y.

No caso relativo à simulação com medições no sentido y, alguns trechos do modo assimétrico A2 não foram identificados, assim como parte do modo A1. A porção faltando deste último é grande o suficiente para que o algoritmo de rastreamento considere as duas pontas correspondentes como separadas, causando a identificação errônea de duas curvas distintas. Apesar de ser possível modificar os parâmetros do algoritmo de rastreamento para que ele aceite um trecho maior de ausência de curva pelo aumento do parâmetro $pmax$ descrito na seção 3.3, isto resultaria, em contrapartida, na identificação de trechos espúrios como curvas novas ou partes adicionais das curvas já identificadas, o que não seria desejável.

Para a comparação com os diferentes casos de tensão aplicadas às placas, as curvas extraídas foram plotadas em conjunto, sendo identificadas com base no valor de tensão usado na simulação. Os resultados podem ser vistos nas figuras 5.3 e 5.4, associados às medidas no sentido x e y, respectivamente.

Nos plots contendo as respostas para diferentes valores de tensão sobre a placa, apresenta-se uma visão geral e uma visão aproximada, focando em trechos das curvas A1 e S1, para que seja possível perceber as diferenças entre as curvas que são muito próximas. Nas figuras de x e y, a vista aproximada indica a correlação entre o valor de tensão aplicado à placa e o offset das curvas com relação ao caso sem tensão. Na figura 5.4, que demonstra as respostas em y, percebe-se que os trechos ausentes nas curvas de diferentes tensões são iguais, o que indica que isto pode ser associado a esses trechos possuírem uma resposta muito fraca para ser captada com as configurações de simulação usadas nessa faixa de frequência e número de onda.

Nota-se que a proximidade entre as curvas extraídas é muito alta, o que é dentro do esperado para esse nível de variação tensão sobre a placa. Dessa




Figura 5.3: Comparação das curvas extraídas por 2-D FT com operações morfológicas para diferentes tensões em placa com sensores medidos na direção x.

forma, é preciso usar a equação 5-2 para o cálculo de RMSE normalizado, para que se possa avaliar a variação das curvas em cada caso de tensão, com relação à referência analítica.

Para cada conjunto de dados simulados de sensores de entrada em tempo-espaço, foi calculada, inicialmente, a matriz f - k através da 2-D FT, para a geração da imagem de entrada. Esse processo demorou em média 22s. Para as operações morfológicas e extração das curvas foram necessários 399s em média, com a maior parte desse tempo tomada para a operação de Threshold local. O tempo médio total de processamento foi de 421s. O uso de memória RAM alcançou em torno de 4GB.




Figura 5.4: Comparação das curvas extraídas por 2-D FT com operações morfológicas para diferentes tensões em placa com sensores medidos na direção y.

5.1.2

2-D FT com algoritmo Ridge

Para a execução desse algoritmo, utilizou-se as mesmas imagens f - k de entrada vistas na seção 5.1.1. Isso significa que a frequência de amostragem efetiva novamente é de $4MHz$ e a região no plano f - k onde as curvas serão identificadas é a mesma. Novamente optou-se por não utilizar o algoritmo de pré-processamento de imagem, uma vez que os resultados foram piores na sua presença.

As curvas identificadas e comparadas com o modelo analítico estão expostas nas figuras 5.5 e 5.6, relativas aos sensores captando nos sentidos x e y , respectivamente.

Nota-se aqui que os resultados são inferiores aos obtidos na seção 5.1.1. O algoritmo de Ridge gera máscaras mais limpas, como pode ser visto na figura 5.7, que mostra a máscara dos dados em x , em comparação com o resultado gerado pelas operações morfológicas. Muito menos artefatos são captados a partir do algoritmo Ridge. No entanto, as curvas captadas possuem certas distorções indesejadas e, em algumas seções em que há proximidade entre as curvas de dispersão, elas parecem se unir na máscara detectada, o que gera erros de extração por parte do algoritmo de rastreamento das curvas. Além disso, o algoritmo de rastreamento separa bem os artefatos das curvas desejadas e, mesmo quando identifica artefatos como curvas, estas são identificadas como curvas separadas e podem ser facilmente removidas em pós análise, uma vez que seus pontos estão agrupados em um só objeto. Portanto, a vantagem da redução do número de artefatos na máscara por parte do algoritmo de Ridge




Figura 5.5: Curvas de dispersão extraídas por Ridge a partir da placa simulada com sensores no sentido x.




Figura 5.6: Curvas de dispersão extraídas por Ridge a partir da placa simulada com sensores no sentido y.

não prevalece sobre os problemas de extração apresentados para esses dados de entrada, com relação ao algoritmo de morfologia matemática.

Na figura 5.5, o modo assimétrico A2 foi dividido em duas curvas pelo algoritmo de rastreamento, o que pode ter sido causado pela junção das curvas A2 e S2 por Ridge na seção onde elas se cruzam, que foi observada na máscara obtida por Ridge mostrada na figura 5.7. Também nota-se algumas distorções nas curvas encontradas, como em torno do número de onda $160m^{-1}$ na curva S0, $190m^{-1}$ em S1 e $340m^{-1}$ em A1, e certas ondulações nas frequências mais elevadas dos modos A0 e S0, além de trechos espúrios na ponta de mais alta frequência da maioria das curvas.

O resultado da extração em y, visto na figura 5.6, também apresentou trechos espúrios ao fim das curvas na parte de maior frequência, além de certas ondulações em A0 e S0 nas porções de mais alta frequência. A curva do modo




Figura 5.7: Comparação de máscaras de pixels feitas com Ridge e operações morfológicas, identificando as curvas para placa de alumínio, medidas em x.

de propagação S1 foi rastreada como duas distintas, similarmente ao visto com o algoritmo morfológico, na faixa de número de onda $200m^{-1}$, o que indica que a limitação para extração apropriada está relacionada à geração da imagem por parte da 2-D FT. A curva A2 também foi identificada de forma incompleta, uma vez que durante seu rastreamento foi extraída como duas distintas, e a porção superior foi excluída pelo algoritmo de rastreamento da seção 3.3 por ter um número de pontos muito reduzido.

Comparou-se os casos de diferentes tensões na placa de alumínio para os sensores nas direções x e y, por meio de um plot contendo todas as curvas de cada caso simulado. O resultado está expresso nas figuras 5.8 e 5.9, relativos a x e y, respectivamente.

Os plots com as extrações combinadas demonstrou que os trechos das curvas capturados para valores de tensão distintos foram os mesmos. Na vista aproximada é possível perceber que o desvio entre as curvas é consistente com o visto na seção 5.1.1, e a diferença das curvas com relação ao caso sem tensão está correlacionado ao valor de tensão aplicado sobre a placa. No caso da figura 5.9, que mostra a comparação das curvas extraídas por sensores medindo no sentido y, alguns trechos espúrios foram identificados como parte das curvas de dispersão existentes, ou como novas curvas, em diferentes valores de tensão aplicada à placa.

O resultado obtido por Ridge foi inferior ao utilizando operações morfológicas da seção 5.1.1, por introduzir certas distorções às curvas e identificar mais elementos espúrios como trechos de curvas erroneamente. No entanto, a comparação entre as curvas de diferentes tensões apresentou resultados apropriados para a identificação de mudanças nas características materiais da estrutura




Figura 5.8: Comparação das curvas extraídas por 2-D FT com Ridge para diferentes tensões em placa com sensores medidos na direção x.

simulada.

O tempo computacional médio associado ao processamento de cada caso simulado foi de 22s para o cálculo da 2-D FT, que gera a matriz f-k que é processada como imagem de entrada, e 14s para a identificação das curvas por Ridge em conjunto com o rastreamento das curvas pelo algoritmo proposto nesse trabalho. O tempo médio total foi de 36s. O uso de memória alcançou em torno de 4GB.




Figura 5.9: Comparação das curvas extraídas por 2-D FT com Ridge para diferentes tensões em placa com sensores medidos na direção y.

5.1.3 Método Pencil

Na extração utilizando o algoritmo de Pencil dos dados da placa de alumínio, as mesmas configurações foram utilizadas em todos os dados de entrada das simulações, sendo mantidas independente de variações nas direções x ou y e da tensão sobre a placa. As configurações utilizadas com o algoritmo Pencil estão na tabela 5.1.

Parâmetro	Valor
mg	0.3
p	20
$sStep$	1:5
$sInit$	0.464
$sSamp$	80
$tStep$	1:1

Tabela 5.1: Parâmetros do algoritmo Pencil usados com os dados de entrada da placa de alumínio.

As curvas extraídas para os conjuntos de dados simulados sem tensão em x e y estão expostas nas figuras 5.10 e 5.11, respectivamente. Nelas, também foram incluídas as curvas de referência teóricas.

As curvas identificadas para o conjunto de dados na direção x obedeceram em grande parte o caso analítico, perdendo algumas informações nas regiões que combinam faixas de frequência mais alta e números de onda mais baixos. Para o conjunto de dados com medidas na direção y da placa, uma porção mais significativa da curva, relativa ao modo assimétrico A2, não foi identificada.




Figura 5.10: Curvas de dispersão extraídas por Pencil a partir da placa simulada com sensores no sentido x.




Figura 5.11: Curvas de dispersão extraídas por Pencil a partir da placa simulada com sensores no sentido y.

A comparação entre o resultado da extração para diferentes valores de tensão aplicada à placa de alumínio é demonstrado nas figuras 5.12 e 5.13, tratando-se dos dados obtidos de simulações com sensores com medição nos sentidos x e y, respectivamente.

A comparação das extrações para diferentes valores de tensão indicam que o desempenho do algoritmo é muito similar para todos os caso. Os casos de tensão 90 e 120MPa aplicadas à placa medidas em y da figura 5.13 tiveram a curva do modo simétrico S1 dividida em dois trechos pelo algoritmo de rastreamento em torno de $200m^{-1}$, o que também havia sido observado nos algoritmos baseados em 2-D FT das seções 5.1.1 e 5.1.2, indicando que tais resultados podem estar relacionados a uma resposta com amplitude baixa nessa faixa deste modo de propagação. As diferenças entre as curvas na vista aproximada mostram a relação entre tensão aplicada e desvio das




Figura 5.12: Comparação das curvas extraídas por Pencil para diferentes tensões em placa com sensores medidos na direção x.




Figura 5.13: Comparação das curvas extraídas por Pencil para diferentes tensões em placa com sensores medidos na direção y.

curvas com relação ao caso sem tensão, similar aos outros algoritmos citados, indicando que o algoritmo do Pencil é apropriado para identificar alterações nas características materiais de uma placa de alumínio.

Comparado aos algoritmos que utilizam a 2-D FT, o número de amostras espaciais para o algoritmo Pencil foi significativamente menor, tendo sido reduzido de 7501 para 80. Este algoritmo também demandou muito mais atenção ao ajuste de parâmetros, não só por possuir mais variáveis de entrada, mas também porque a alteração delas muda bastante o perfil de resposta obtido. Ele também se mostrou especialmente sensível à alteração no número de amostras espaciais de entrada, produzindo respostas distintas mesmo para alterações sutis. Também observou-se que uma combinação de um número maior de modos esperados p com uma margem mg mais reduzida implicou em resultados melhores, com menos pontos espúrios e maior número de pontos nas curvas de dispersão esperadas. Para a realização das tarefas computacionais

foi necessário um tempo total médio de 129s e um gasto de memória máximo de 2.3GB.

5.1.4

Comparação dos resultados

De forma a melhor ilustrar as diferenças entre os distintos métodos de extração de curvas, os resultados obtidos por cada um dos algoritmos foram reunidos nas figuras 5.14 e 5.15, para os dados com medidas de sensores nos sentidos x e y, respectivamente.

Para comparar os resultados obtidos pelos três algoritmos de extração, utilizou-se as curvas teóricas correspondentes aos distintos casos de tração uniaxial paralelo à propagação com os mesmos valores de tração que os simulados. As curvas dos modos de propagação de cada algoritmo foram comparadas com as curvas teóricas análogas por meio do cálculo de erro RMS normalizado da equação 5-2, em caso de 2-D FT, e 5-4, no caso de Pencil.

As tabelas 5.2 e 5.3 mostram os erros RMS normalizados obtidos pela comparação das curvas extraídas por 2-D FT com operações morfológicas comparadas às curvas teóricas, em x e y, respectivamente. Nas tabelas, também é mostrado o percentual das curvas teóricas que foram comparadas com os pontos extraídos pelo algoritmo, o que está diretamente ligado à capacidade do algoritmo de identificar pontos da curva dentro do faixa de valores de frequência e número de onda de interesse. Na direção x, observa-se que todas os modos foram comparadas com mais de 98% dos pontos das curvas teóricas, enquanto na direção y os modos S1 e A2 tiveram grande parte de suas porções não identificadas. No caso de S1 na direção y, as curvas do modo para diferentes tração foram identificadas como mais de uma curva, e optou-se por só comparar um dos trechos, o que explica valores tão baixos de percentual comparado. O erros encontrados para x e y foram baixos em geral, sem diferenças significativas entre os erros encontrados em valores de estresse distintos.

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.001649	0.00304	0.001661	0.001721	0.001715	0.982788	0.987973	0.981132	0.982847	0.982877
S0	0.003117	0.003107	0.009042	0.008686	0.008911	0.982669	0.982669	0.980969	0.981002	0.987931
A1	0.002426	0.002432	0.002436	0.002379	0.002383	0.99117	0.991209	0.991209	0.991228	0.991247
S1	0.00627	0.006308	0.004025	0.004021	0.003975	0.986842	0.986885	0.990164	0.990196	0.990228
A2	0.003294	0.003158	0.0032	0.003147	0.003158	0.995074	0.990148	0.990196	0.990244	0.985437
S2	0.004522	0.008724	0.007338	0.004588	0.008717	0.994819	0.989691	0.989744	0.989744	0.989796
Média	0.003546	0.004462	0.004617	0.00409	0.00481	0.988894	0.988096	0.987236	0.987543	0.987919

Tabela 5.2: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com operações morfológicas de dados simulados no sentido x.

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.001617	0.001721	0.001643	0.001747	0.00169	0.987952	0.987973	0.986278	0.987993	0.989726
S0	0.002981	0.002706	0.001457	0.001499	0.005711	0.963605	0.953206	0.956747	0.953368	0.97069
A1	0.002425	0.002441	0.002397	0.002414	0.002379	0.99117	0.991209	0.991209	0.991228	0.991247
S1	0.004074	0.003272	0.004461	0.003491	0.003756	0.325658	0.311475	0.331148	0.333333	0.322476
A2	0.00179	0.001815	0.001785	0.001781	0.001758	0.399015	0.408867	0.406863	0.414634	0.38835
S2	0.00454	0.004577	0.004525	0.004586	0.004558	0.989637	0.989691	0.984615	0.989744	0.989796
Média	0.002904	0.002756	0.002711	0.002586	0.003309	0.776173	0.773737	0.776143	0.778383	0.775381

Tabela 5.3: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com operações morfológicas de dados simulados no sentido y.

Nas tabelas 5.4 e 5.5 são apresentados os erros e percentuais comparados das curvas extraídas através do algoritmo 2-D FT com Ridge com as curvas teóricas, em x e y, respectivamente. Nos casos de dados relativos a simulações com sensores medindo no sentido x, o modo A2 teve um percentual comparado com os pontos teóricos bem abaixo do resto, ficando em torno de 50%, enquanto os outros modos todos ultrapassam 95%, o que se deve ao fato da curva do modo A2 ter sido identificada como duas distintas, tal como se vê na figura 5.6 e aqui foi usado uma rotina que só compara 2 curvas, tendo sido necessário escolher apenas uma das que foi extraída por Ridge. Os erros RMS obtidos no sentido x são muito próximos aos vistos para o caso de extração por 2-D FT com operações morfológicas e até menores para os casos de estresse não-nulo. Nas simulações no sentido y, as porções comparadas dos modos A2 e S1 foram bem abaixo, percentualmente, que as outras, novamente devido ao algoritmo ter identificado essas curvas como duas distintas e usado apenas um dos trechos para comparação. Os erros encontrados no sentido y são, novamente, bem baixos e comparáveis aos encontrados através de operações morfológicas. Para os dados extraídos nos dois sentidos, não foi encontrada muita diferença nos valores de erro entre os diferentes valores de tração.

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.002626	0.003048	0.00272	0.003328	0.00242	0.95525	0.989691	0.951973	0.989708	0.946918
S0	0.002715	0.001968	0.002667	0.001848	0.002704	0.998267	0.979203	0.99827	0.974093	0.996552
A1	0.003081	0.003093	0.003001	0.00312	0.003162	1	1	1	1	1
S1	0.004796	0.004826	0.00479	0.004821	0.004742	1	1	1	1	1
A2	0.003512	0.00367	0.0035	0.003808	0.002813	0.512315	0.53202	0.514706	0.517073	0.490291
S2	0.005583	0.005478	0.005508	0.005371	0.005553	1	1	1	1	1
Média	0.003719	0.00368	0.003698	0.003716	0.003566	0.910972	0.916819	0.910825	0.913479	0.905627

Tabela 5.4: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com Ridge de dados simulados no sentido x.

Os dados de erros RMS normalizados da comparação das extrações por Pencil com as curvas teóricas estão nas tabelas 5.6 e 5.7, em x e y,

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.00277	0.003066	0.002248	0.002987	0.002252	0.994836	0.994845	0.958834	0.994854	0.953767
S0	0.00139	0.001336	0.002404	0.001411	0.002373	0.951473	0.946274	0.967128	0.941278	0.963793
A1	0.003137	0.003307	0.003044	0.003059	0.00324	1	1	1	1	1
S1	0.004217	0.00407	0.010437	0.004229	0.008161	0.552632	0.540984	0.370492	0.555556	0.351792
A2	0.002402	0.002053	0.002202	0.002171	0.001816	0.403941	0.389163	0.382353	0.390244	0.393204
S2	0.005073	0.005042	0.005023	0.004962	0.005105	1	1	1	1	1
Média	0.003165	0.003146	0.004227	0.003137	0.003825	0.817147	0.811878	0.779801	0.813655	0.777093

Tabela 5.5: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por 2-D FT com Ridge de dados simulados no sentido y.

respectivamente. Os erros encontrados nas tabelas de ambos os sentidos são, em média, um pouco maiores que os obtidos pelos outros dois algoritmos. Isso se deve aos valores de erro de A2 e S2 que se destacam com relação aos demais, o que pode estar relacionado ao cruzamento entre as curvas, que pode fazer com que o algoritmo de rastreamento designe pontos de uma curva a outra com base nos dados extraídos de Pencil. No sentido x, as curvas teóricas foram comparadas quase totalmente com as extraídas por Pencil, demonstrando a capacidade do algoritmo em identificação na região f-k de interesse; no sentido y, as curvas A2 e S1, nos casos de 90 e 120 MPa, tiveram grande parte não identificada.

É importante ressaltar que resultados melhores, no sentido de identificação de mais porções das curvas, foram observados para Pencil com algumas mudanças nos parâmetros do algoritmo, sobretudo aumentando a distância entre os índices escolhidos entre as amostras espaciais coletadas *sStep* ou o número total de amostras espaciais *sSamples*, indicando que o desempenho do algoritmo é bastante influenciada por uma maior cobertura da placa, permitindo a obtenção de mais informações sobre o perfil de propagação das ondas guiadas. No entanto, optou-se por usar os valores de parâmetros do algoritmo mencionados na seção 5.1.3, uma vez que aumentar *sStep*, ou seja, reduzir a frequência espacial, reduziria o *range* de número de onda das curvas obtidas. Também optou-se por usar um número reduzido de amostras espaciais para validar essa capacidade do algoritmo, mencionada por Ekstrom (49), que é um diferencial com relação às técnicas com base em 2-D FT exploradas nesse trabalho.

Nas figuras 5.16, 5.17 e 5.18, mostra-se em plots distintos as curvas de cada modo obtidas pelos 3 algoritmos explorados nesse trabalho para o caso da placa de alumínio medida no sentido x, assim como o caso teórico, para os distintos valores de tração uniaxial aplicada. Nos gráficos das figuras, utilizou-se estilos de linha distintos para indicar os diferentes algoritmos e

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.001978	0.00199	0.001996	0.002014	0.002022	1	1	0.998779	1	0.99939
S0	0.002085	0.002101	0.002118	0.002175	0.002599	0.986201	0.987109	0.987423	0.990214	0.991746
A1	0.003819	0.003795	0.003769	0.003745	0.00372	1	1	1	1	1
S1	0.005245	0.005236	0.005217	0.0052	0.005179	0.996503	0.99767	0.995923	0.996508	0.99709
A2	0.010107	0.013003	0.009964	0.009854	0.009379	0.978571	1	0.980142	0.971711	0.322021
S2	0.010143	0.010153	0.010029	0.010108	0.088795	1	1	1	1	1
Média	0.005563	0.006046	0.005515	0.005516	0.018616	0.993546	0.997463	0.993711	0.993072	0.885041

Tabela 5.6: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por algoritmo Pencil de dados simulados no sentido x.

Modos	NRMSE					Percentual Comparado				
	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa	0 MPa	30 MPa	60 MPa	90 MPa	120 MPa
A0	0.002512	0.001982	0.002618	0.00201	0.002022	0.995117	0.998474	0.999695	0.998779	0.99939
S0	0.002072	0.002604	0.002559	0.002746	0.002638	0.944189	0.970534	0.952454	0.965443	0.986243
A1	0.00382	0.003796	0.00377	0.003746	0.003722	1	1	1	1	1
S1	0.00537	0.005312	0.005218	0.004437	0.00318	0.998252	0.997088	0.992429	0.203725	0.210128
A2	0.008436	0.008525	0.008441	0.008446	0.008462	0.52	0.504274	0.540426	0.606789	0.528914
S2	0.010275	0.01015	0.010145	0.010137	0.010124	1	1	1	1	1
Media	0.005414	0.005395	0.005459	0.005254	0.005024	0.909593	0.911728	0.914167	0.79579	0.787446

Tabela 5.7: Tabela comparando erros normalizados e percentual entre curvas teóricas de para diferentes valores de tração e curvas extraídas por algoritmo Pencil de dados simulados no sentido y.

cores diferentes para distinguir valores de tração entre si. Além disso, mostra-se também a vista ampliada em um trecho bem curto para cada caso, de forma a mostrar as distâncias curtas entre as curvas teóricas e extraídas. Nas vistas gerais de cada caso, nota-se que as curvas extraídas e teóricas para um único modo são muito próximas, porém observa-se alguns problemas nos trechos de número de onda mais alto do modo A2 obtidos por Ridge, assim como identificação errada de porção do modo A2 por S2 no caso extraído de Pencil para 120 MPa. A partir das vistas aproximadas, observa-se que as distâncias entre as curvas extraídas por um algoritmo para trações diferentes são análogas às distâncias das curvas teóricas, sobretudo no algoritmo Pencil.

Nas figuras 5.19, 5.20 e 5.21, mostra-se a comparação das curvas extraídas e teóricas de cada modo em plots separados com dados simulados da placa de alumínio com medições no sentido y, para diferentes valores de tração. Aqui, nota-se alguns problemas na extração nos modos A1 e S2, com alguns trechos faltando e partes erradas identificadas por Ridge no modo simétrico S1, para certos valores de tração.

A tabela 5.8 compara o desempenho computacional dos três algoritmos de extração, assim como o número de amostras utilizadas. A partir da tabela, destaca-se:

- O algoritmo 2-D FT morfológico tem um tempo de processamento

consideravelmente mais elevado que os outros dois algoritmos, sendo mais de 11 vezes mais alto que 2-D FT com Ridge e mais de 3 vezes mais elevado que Pencil;

- O tempo para o processamento de Ridge foi 3.5 vezes mais curto que o de Pencil, o segundo melhor algoritmo nesse quesito.
- O consumo de memória dos algoritmos baseados na 2-D FT é quase o dobro do observado por Pencil. O que está associado a uma maior massa de dados sendo necessária na matriz espaço-tempo de entrada para a geração de uma figura f-k a partir da 2-D FT com resolução satisfatória para que a identificação das curvas seja possível;
- O número de amostras espaciais necessário para extrair com Pencil e obter um resultado comparável aos outros dois algoritmos foi quase 100 vezes menor, o que não só poupa memória, como, principalmente, é muito mais adequado a situações de campo. Nas mesmas, o número de amostras espaciais obtidas costuma ser bem reduzido em comparação à amostragem temporal, seja pelo número de sensores fixos ou pelo custo de tempo em se fazer retomada de dados para várias posições (4).

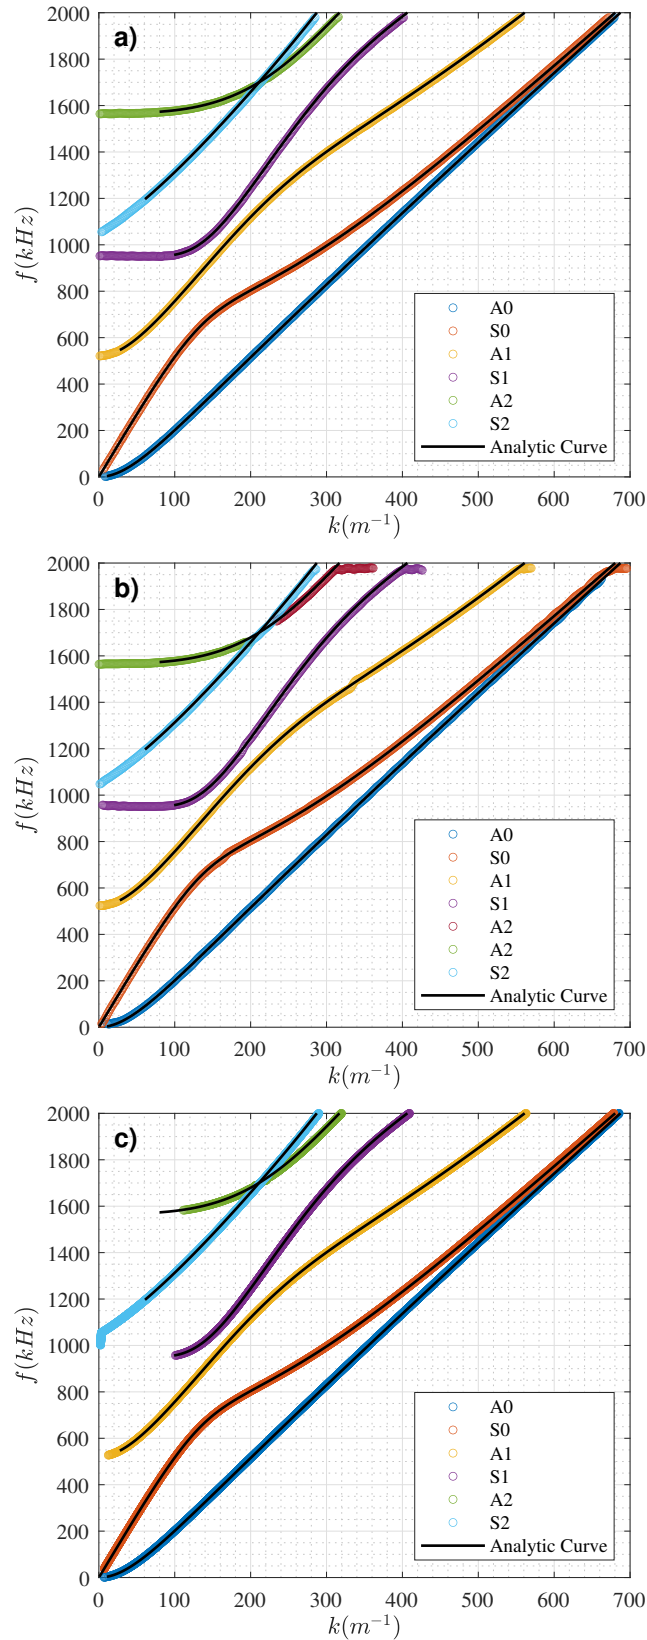


Figura 5.14: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para placa de alumínio com sensores no sentido x: a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

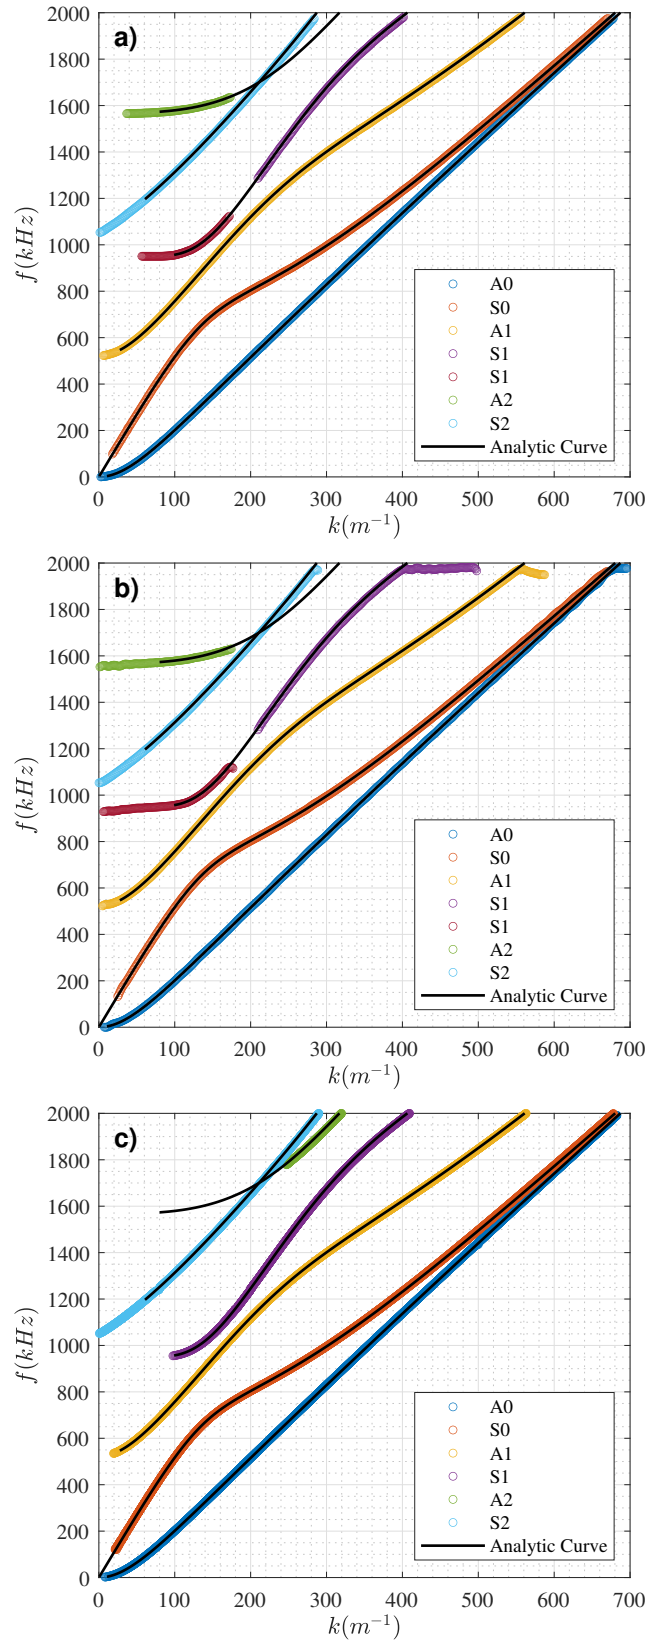


Figura 5.15: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para placa de alumínio com sensores no sentido y: a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

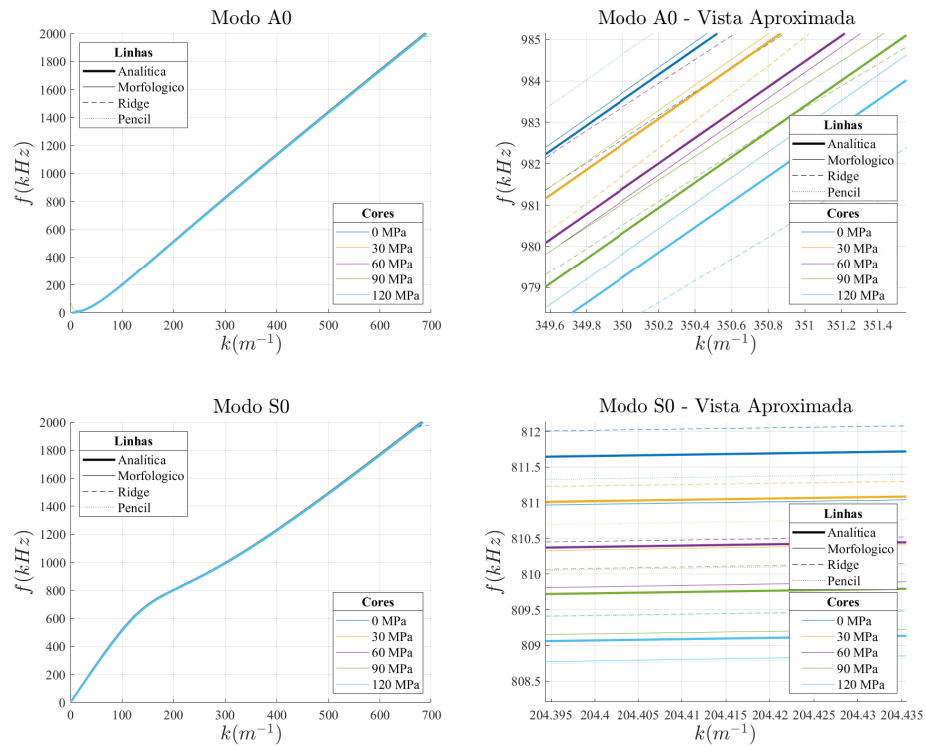


Figura 5.16: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A0 e S0, em x.

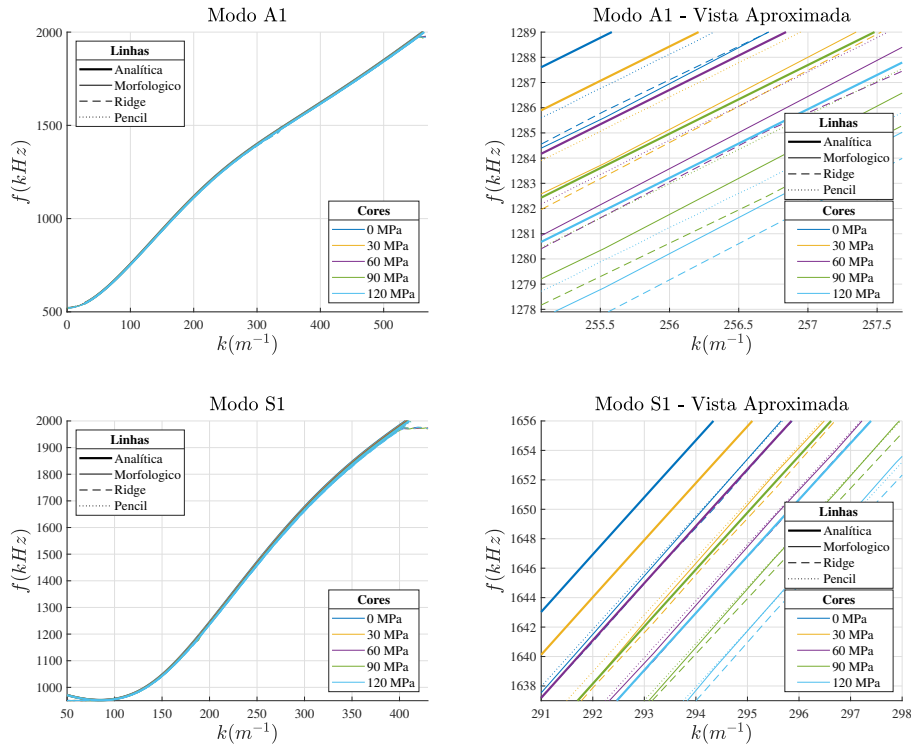


Figura 5.17: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A1 e S1, em x.

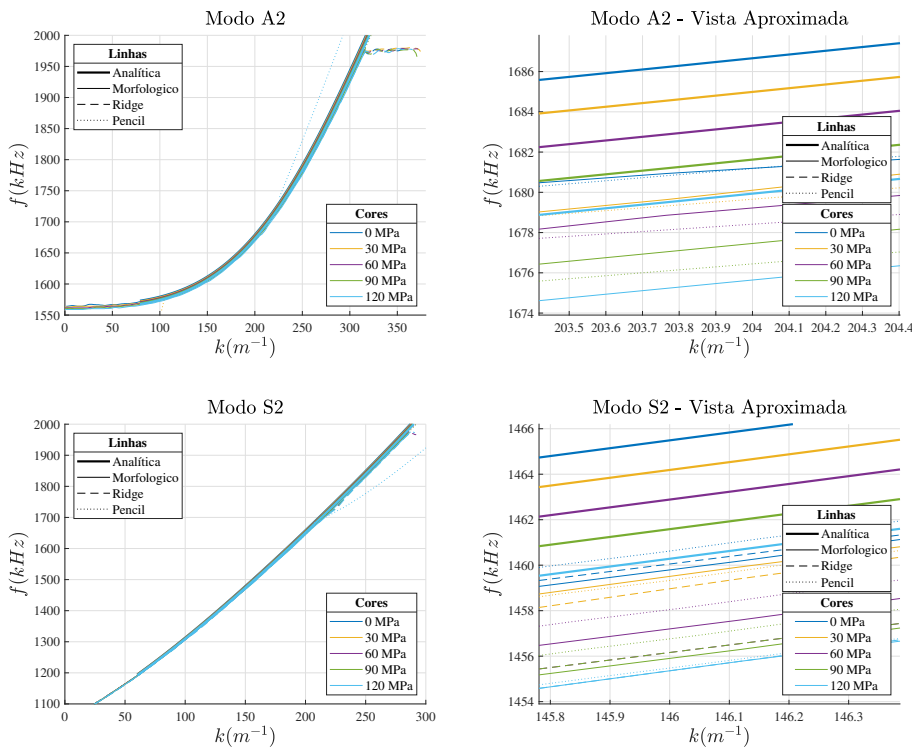


Figura 5.18: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A2 e S2, em x.

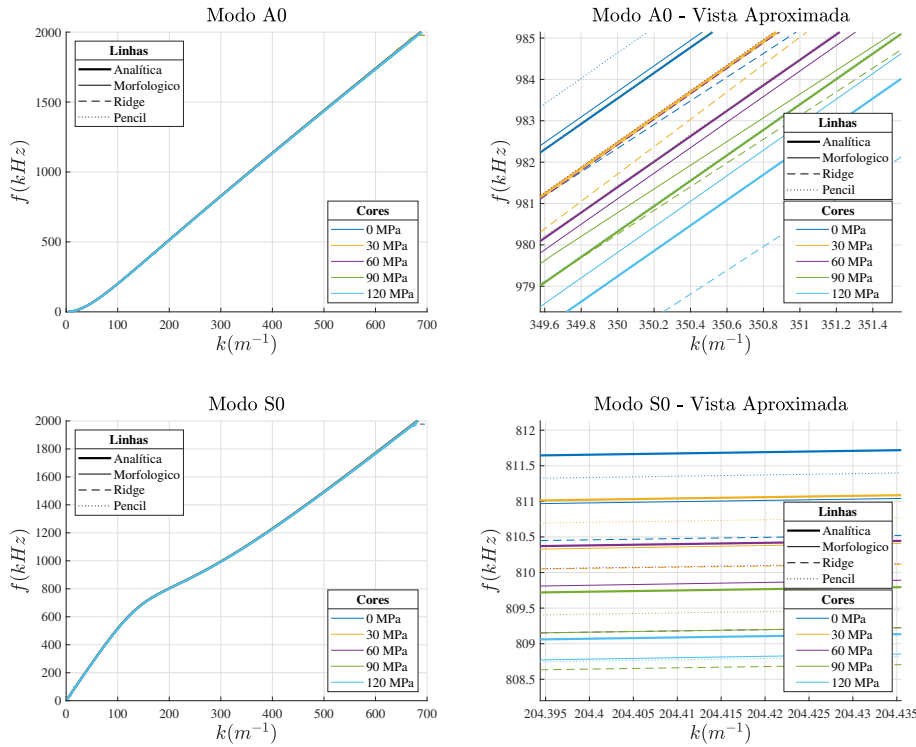


Figura 5.19: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A0 e S0, em y.

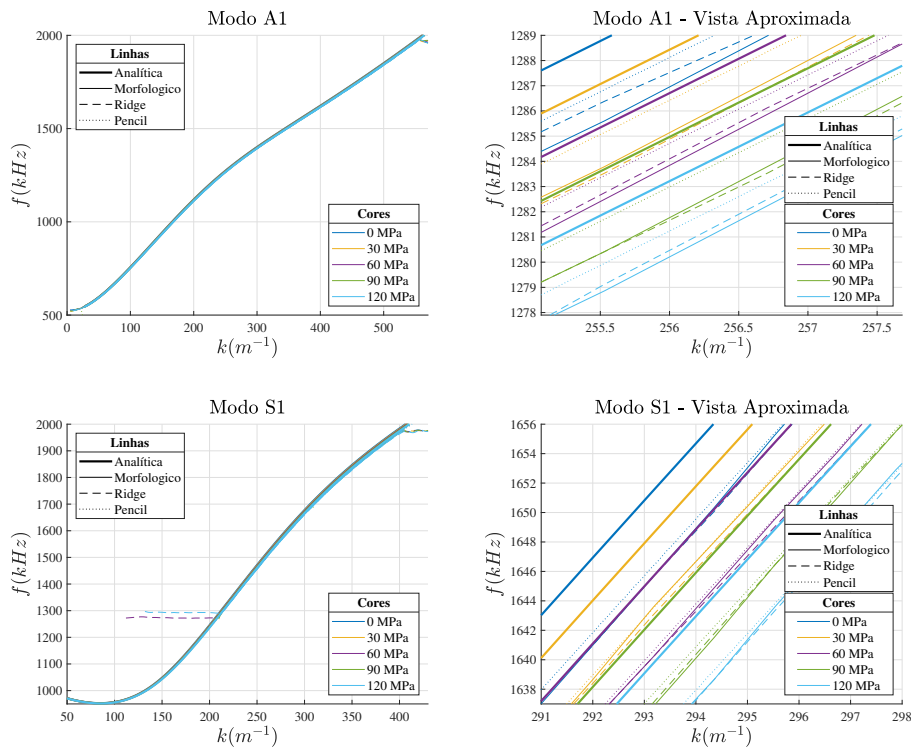


Figura 5.20: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A1 e S1, em y.

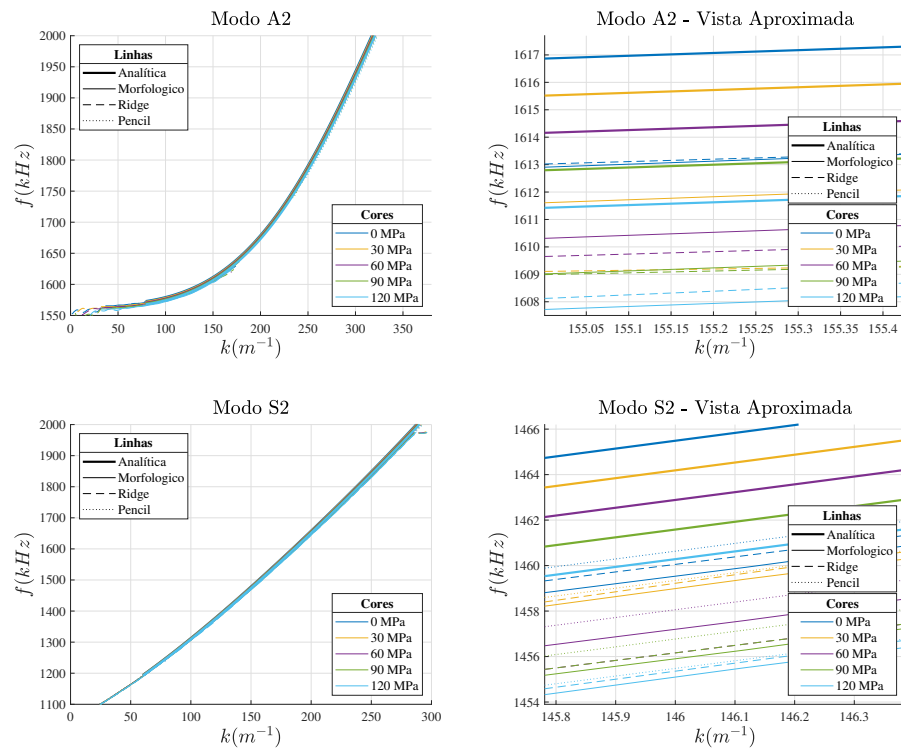


Figura 5.21: Comparação entre os resultados de extração e curvas teóricas para diferentes algoritmos e valores de estresse sobre a placa para os modos A2 e S2, em y.

Algoritmo	Desempenho médio		Número de amostras	
	Tempo (s)	Memória (GB)	Espaço	Tempo
2-D FT Morfológico	421	4.0	7501	3797
2-D FT Ridge	36	4.0	7501	3797
Pencil	129	2.3	80	37964

Tabela 5.8: Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados da placa de alumínio nos sentidos x e y com diferentes trações axiais aplicadas.

5.2

Poço multicamada

As curvas de dispersão associadas à estrutura com as características utilizadas nas simulações de poço multicamada propostos nesse trabalho não têm solução analítica trivial. Dessa forma, não existem curvas de referência geradas por modelo matemático para comparação das curvas extraídas pelos algoritmos aqui utilizados. Optou-se por usar as curvas extraídas por cada um dos algoritmos para o caso sem defeito (referidos como ND) como referência para a comparação com os casos de defeito CH, CQ, SC e CR descritos na seção 4.2.3.

Em alguns, as curvas obtidas com base em dados de entrada de simulações de poços com defeito são bastante próximas às curvas obtidas para o caso ND. Desta forma, optou-se por mostrar as curvas de dispersão no plano *slowness* \times frequência, em que as diferenças são mais perceptíveis.

5.2.1

Poço sem *tubing*

A ausência da camada de aço referente à coluna de produção causa mudanças marcantes nas características das curvas de dispersão extraídas, resultando em um número distinto de modos de propagação, assim como um perfil f-k diferente das curvas. Assim, esse caso será tratado separadamente, e as curvas obtidas através da extração do caso ND sem *tubing* serão usadas como referência apenas para comparação com os defeitos vistos nessa seção.

5.2.1.1

2-D FT com operações morfológicas

Inicialmente, foram extraídas as curvas relativas à simulação do poço sem defeito, com objetivo de usar como referência para comparação das outras simulações. A figura 5.22 mostra o resultado da extração com este algoritmo.

É possível perceber que alguns cruzamentos na região de número de onda $25 - 35 m^{-1}$ possuem bastante ondulação, e um deles deixou de ser identificado. Além disso as curvas em menores frequências parecem não ter sido identificadas por completo, não alcançado números de onda tão altos quanto o esperado. Vale ressaltar também que existe um caráter ondulatório observado nas curvas de forma geral.




Figura 5.22: Curvas obtidas por 2-D FT com operação morfológicas de poço sem *tubing* e sem defeito (ND).

Para as simulações dos diferentes tipos de defeito, foi utilizada a representação na forma slowness \times frequência, que permite uma melhor visualização dos desvios nas curvas de dispersão dos casos com defeito com relação à referência ND. Para o defeito do tipo Channeling (CH), os resultados das curvas extraídas, plotadas em conjunto com a referência, estão representadas na figura 5.23, com foco especial na área de interesse onde as inflexões das curvas acontecem exibido na figura 5.24. É possível observar que as curvas de dispersão para os casos com defeito se distanciam razoavelmente do caso ND. No entanto, por essa forma de extração não é possível correlacionar os desvios das curvas com CH com o tamanho da camada de água das simulações, o que seria desejável. Parte da razão desse problema é a ondulação captada pelo algoritmo de extração, fazendo com que não seja possível observar detalhes nas diferenças entre curvas correlacionadas, que estão bastante próximas. Também é possível observar que para os valores mais baixos de frequência existem bastantes artefatos captados em conjunto com as curvas de interesse.

As curvas obtidas para as simulações com cimento degradado (CQ) estão expostas nas figuras 5.25 e 5.26, a primeira mostrando todo o plano slowness \times frequência, e a seguinte com uma vista aproximada da região das inflexões. Desse resultado, é possível observar que a mudança nas impedâncias acústicas causa desvios graduais nas curvas dos diferentes valores de defeito. Apesar de




Figura 5.23: Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito de Channeling (CH).

certas regiões das curvas capturem também artefatos não relevantes, é possível observar uma tendência entre os desvios das curvas de dispersão dos casos com CQ de acordo com o nível de defeito, sobretudo nos dois conjuntos de curva com maior slowness. É provável que a maior distância entre as curvas de dispersão de defeitos CQ de valores distintos permita que a ondulação captada não atrapalhe na identificação dessa tendência.

Os resultados da extração com dados simulados com defeito de descolamento interno (SC) são mostrados na figura 5.27. Na figura 5.28 é mostrado a região de inflexão com mais detalhe. Pela visão geral fornecida pela figura 5.27, nota-se novamente que existem bastante artefatos e desvios que parecem associados a uma extração insuficiente, mas para a maioria das curvas e de valores de percentual de SC é possível observar estarem próximas ao caso ND. No grupo de curvas de maior valor de slowness é possível observar a correlação dos desvios com relação à referência com o valor percentual de SC por meio da figura 5.28, mas nos outros grupos existe muita ondulação e artefatos para que uma conclusão possa ser tirada.

A saída obtida a partir da extração com dados simulados de poço com descolamento externo (CR) é vista na figura 5.29 e uma aproximação na região de interesse é mostrada na figura 5.30. Aqui é possível observar, novamente, que as curvas relativas aos casos de defeito estão distanciadas da referência ND, porém bastante próximas entre si, sobretudo na região de inflexão. Devido à proximidade das curvas de cada grupo para os casos de defeito, não é possível observar nenhum tipo de correlação entre os desvios e o tamanho percentual




Figura 5.24: Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológica de poço sem *tubing* com defeito de Channeling (CH).

da camada de água que causa o descolamento.

Os resultados mostrados nessa seção indicam que o algoritmo 2-D FT com operações morfológicas se mostra útil para identificar a presença dos tipos de defeito testados, uma vez que o desvio das curvas com relação à referência ND se apresentou como bastante evidente em todos os casos vistos. Porém, apenas para os casos de defeito CQ e SC foi possível relacionar as curvas de dispersão obtidas com os distintos valores de defeito. É possível que uma menor tendência ondulatória nas curvas extraídas por esse método permitisse uma identificação mais precisa das intensidades de defeito, porém isso possivelmente exigiria uma resolução maior nas figuras obtidas pela 2-D FT, o que significa um maior número de amostras espaciais e temporais.

O tempo médio de processamento para o cálculo da 2-D FT foi de 68s, enquanto o processo de identificação da máscara e rastreamento das curvas em conjunto durou 424s. O tempo médio de processamento total foi de 492s. O consumo de memória alcançou 14.9GB.




Figura 5.25: Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito CQ.




Figura 5.26: Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito CQ.




Figura 5.27: Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito SC.




Figura 5.28: Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito SC.




Figura 5.29: Curvas de slowness extraídas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito CR.




Figura 5.30: Vista aproximada das curvas de slowness obtidas por 2-D FT com operação morfológicas de poço sem *tubing* com defeito CR.

5.2.1.2

2-D FT com algoritmo Ridge

Para a extração das curvas relativas ao poço multicamada pelo algoritmo de Ridge, foi utilizado o pré-processamento descrito na seção 3.1.1.

As curvas extraídas para o caso sem defeito, que será usado como referência nessa seção, são mostradas na figura 5.31. Aqui, é possível notar também certa característica de ondulação nas curvas, sobretudo nas transições com inflexão na faixa de número de onda de $25 - 35 m^{-1}$.




Figura 5.31: Curvas obtidas por 2-D FT com Ridge de poço sem *tubing* e sem defeito (ND).

Na figura 5.32, mostra-se o resultado das extrações das curvas de slowness para simulações com defeito do tipo Channeling (CH), enquanto a figura 5.33 destaca a área de interesse onde as diferenças entre as curvas são mais acentuadas. A partir dessas figuras, é possível perceber as ondulações identificadas indevidamente em grande parte das curvas extraídas. Como visto na seção 5.2.1.1, os grupos de curva com defeito são próximos entre si, porém distantes da referência. Apesar das oscilações, em sua maioria as curvas obedecem a relação de variação a ND diretamente associada à intensidade do defeito, como pode ser visto especialmente na figura 5.33. Aqui, nota-se uma diferença significativa com relação aos resultados obtidos pela geração da máscara com as operações morfológicas, na seção 5.2.1.1, onde as ondulações tinham caráter aleatório e dificultavam a identificação de tendência de desvio. Com o algoritmo Ridge, as oscilações parecem possuir fase e frequência similares, e, por isso, pode-se identificar certa relação entre os desvios que as curvas de um mesmo modo de propagação apresentam e os respectivos valores de CH.

A extração das curvas para os casos de diferentes qualidades de cimentação (CQ) resultou na figura 5.34, e a figura 5.35 mostra a área de inflexões. Novamente, nota-se certa ondulação nas curvas, inerente à extração, por Ridge,




Figura 5.32: Curvas de slowness extraídas por 2-D FT com Ridge de poço sem *tubing* com defeito CH.

de curvas em uma imagem de 2-D FT. As distâncias vistas na figura 5.35 entre as curvas de cada valor de erro são maiores que os casos de defeito CH. Apesar da ondulação, percebe-se a relação entre os desvios e o nível de defeito.

As simulações para os casos de descolamento interno (SC) geraram curvas de slowness vistas na figura 5.36, com foco específico na região de inflexão mostrado na figura 5.37. Percebe-se que as curvas para diferentes valores de defeitos estão bem próximas entre si, mesmo na figura 5.37, em que um foco é aplicado na área de interesse. Ainda assim, nota-se que os desvios são proporcionais às porcentagens de SC.

As curvas de slowness extraídas a partir de simulações de casos de camada de água entre rocha e cimento (CR) são mostradas nas figuras 5.38 e 5.39, onde a última destaca a inflexão das curvas. Em algumas áreas, as curvas relativas às distintas intensidades de defeito ficam tão próximas entre si que não é possível identificar claramente quais se distanciam mais do caso ND, mas no foco da figura 5.39 é possível notar essa distância entre elas em alguns trechos e esta se relaciona diretamente com a intensidade do defeito, sobretudo na faixa de frequência 25 – 35 kHz.

Esses resultados indicam que a técnica de 2-D FT aliada ao algoritmo Ridge é capaz de identificar a presença de defeitos e também apontar o nível de intensidade desse defeito. O esforço computacional associado a este algoritmo e esse conjunto de dados foi em média de 68s para o cálculo da 2-D FT e 12s para a geração da máscara e rastreamento combinados, totalizando em 80s. O uso máximo de memória foi de 14.9GB durante a geração da figura f-k a partir




Figura 5.33: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem *tubing* com defeito CH.

da FT bidimensional.




Figura 5.34: Curvas de slowness extraídas por 2-D FT com Ridge de poço sem *tubing* com defeito CQ.




Figura 5.35: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem *tubing* com defeito CQ.




Figura 5.36: Curvas de slowness extraídas por 2-D FT com Ridge de poço sem *tubing* com defeito SC.




Figura 5.37: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem *tubing* com defeito SC.




Figura 5.38: Curvas de slowness extraídas por 2-D FT com Ridge de poço sem *tubing* com defeito CR.




Figura 5.39: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço sem *tubing* com defeito CR.

5.2.1.3 Método Pencil

As curvas extraídas por Pencil mostradas nessa seção foram obtidas utilizando as mesmas configurações do algoritmo em todos os dados de entrada de poço multicamada sem *tubing*. As configurações utilizadas são mostradas na tabela 5.9.

Parâmetro	Valor
mg	0.5
p	60
$sStep$	1:4
$sInit$	0.020
$sSamp$	380
$tStep$	1:10

Tabela 5.9: Parâmetros do algoritmo Pencil usados com os dados de entrada da poço multimacada sem *tubing*.

As curvas de onda referentes ao caso sem defeito extraídas pelo algoritmo são apresentadas na figura 5.40. Observa-se que as curvas obtidas por esse algoritmo são mais suaves que as vistas pelos métodos de imagem. Apesar disso, existem algumas falhas em certas curvas na região de inflexão de frequência 25 – 40 kHz . Aqui, novamente se observa a tendência deste algoritmo de não captar bem porções de curvas em regiões que combinam maior faixa de frequência e menor número de onda, como visto na seção 5.1.3.




Figura 5.40: Curvas obtidas por Pencil de poço sem *tubing* e sem defeito (ND).

O resultado obtido para as simulações do caso de tipo Channeling Defect (CH) está exposto na figura 5.41, com foco específico em certas regiões visto na figura 5.42, com objetivo de evidenciar a diferença no nível de desvio de cada defeito distinto com relação à referência sem defeito (ND). Algum ruído

é identificado nas curvas extraídas, sobretudo na faixa de maior frequência das curvas e nas regiões de inflexão a partir de 40kHz . Apesar disso, é possível identificar a correlação entre a intensidade dos defeitos e o desvio das curvas com relação ao caso ND a partir da figura 5.42. Devido à proximidade das curvas de cada defeito, a influência de certo ruído é notável, porém, ainda assim é possível identificar a tendência de relação de desvio do caso sem defeito em função do percentual de defeito.




Figura 5.41: Curvas de slowness extraídas por Pencil de poço sem *tubing* com defeito CH.

Para o caso das simulações com diferentes qualidades de cimentação (CQ), as curvas de slowness encontradas são mostradas na figura 5.43, com aproximação sobre as inflexões das curvas exposto na figura 5.44. Pela figura 5.44, é possível perceber uma clara relação de desvio com base na qualidade de cimentação, o que se deve, em parte, ao fato de que as curvas se distanciam mais gradualmente do caso ND, sendo consideravelmente espaçadas entre si. É notável também um caráter menos ruidoso nas curvas com relação ao caso de defeito CH, tanto na figura 5.43, tanto quanto no detalhe da figura 5.44.

O caso de defeito por descolamento interno (SC) tem suas curvas extraídas apresentada na figura 5.45, com foco específico mostrado na figura 5.45. Apesar de ainda haver certo ruído nas curvas dos distintos valores de defeito nas regiões de inflexão, evidenciados pela figura 5.45, a distância entre elas é suficiente para deixar claro que a variação com relação à referência ND é crescente de acordo com a porcentagem de SC.

As curvas de slowness relativas às simulações de poço com descolamento




Figura 5.42: Vista aproximada das curvas de slowness obtidas por Pencil de poço sem *tubing* com defeito CH.

externo (CR) obtidas por meio do método Pencil estão nas figuras 5.47 e 5.47, sendo a última a vista aproximada sobre a área de inflexão. A partir da figura 5.47, é possível perceber que novamente as curvas de cada nível de defeito são distantes o suficiente entre si para que certo ruído presente não “embaralhe” as curvas, e a relação entre desvio e a porcentagem de defeito CR pode ser constatada.

As curvas obtidas nessa seção indicam que o método Pencil é especialmente eficaz em identificar variações nas curvas de dispersão ocasionadas pela mudança de intensidade de defeito nas simulações mostradas, além de pode indicar a existência geral de defeitos por mostrar o claro desvio que suas respectivas curvas tem com relação à referência ND.

Novamente foi necessário bastante ajuste para encontrar um conjunto do parâmetros de entrada que fornece extrações boas o suficiente para que fossem comparados os diferentes níveis e casos de falha de cimentação. É preciso ressaltar que apesar desse algoritmo ter se mostrado bastante eficiente para a computação das curvas em casos com relativamente poucas amostras espaciais, os melhores resultados aqui foram obtidos com um número mais elevado de pontos no espaço, apesar de que ainda menor que nos algoritmos com 2-D FT.

Para processar o algoritmo foram necessário 125s em média para cada caso simulado de entrada. O gasto máximo de memória foi de 2.2GB.




Figura 5.43: Curvas de slowness extraídas por Pencil de poço sem *tubing* com defeito CQ.




Figura 5.44: Vista aproximada das curvas de slowness obtidas por Pencil de poço sem *tubing* com defeito CQ.




Figura 5.45: Curvas de slowness extraídas por Pencil de poço sem *tubing* com defeito SC.




Figura 5.46: Vista aproximada das curvas de slowness obtidas por Pencil de poço sem *tubing* com defeito SC.




Figura 5.47: Curvas de slowness extraídas por Pencil de poço sem *tubing* com defeito CR.




Figura 5.48: Vista aproximada das curvas de slowness obtidas por Pencil de poço sem *tubing* com defeito CR.

5.2.1.4

Comparação dos resultados

Os três algoritmos de extração utilizados foram capazes de extrair as curvas de dispersão dentro da faixa de valores de frequência e número de onda inspecionada. Foi observado que os algoritmos conseguem mostrar uma diferença bem clara entre os dados de poço sem defeito e os dados com defeito. Além disso, os algoritmos 2-D FT com Ridge e Pencil são capazes de apontar a correlação entre os valores de defeito e as mudanças observadas nas curvas de dispersão extraídas, algo que só é observado de forma clara pelo algoritmo de 2-D FT com operações morfológicas para os casos de defeito CQ e SC.

A comparação entre as curvas de slowness extraídas para o caso sem *tubing* e sem defeito com os três algoritmos é apresentada nas figuras 5.49 e 5.50, esta última mostrando uma vista aproximada na região de inflexão das curvas de dispersão. Através das imagens é possível observar que os três algoritmos identificam as mesmas curvas. Nas figuras, observa-se a característica ondulatória dos algoritmos com base em 2-D FT, Ridge e morfológico, apresentados na seção 3.1, como já havia sido mencionado, e, em algumas porções, um deles parece desviar bastante da trajetória dos outros dois algoritmos plotados. O algoritmo de Pencil parece apresentar leves ondulações de alta frequência e amplitude baixa em alguns trechos, como na faixa de frequência abaixo de $15kHz$, porém, o efeito é bem sutil, diferentemente do que é visto nos outros algoritmos. Pencil se destaca entre os três algoritmos, mostrando resultados consistentes para a maioria das curvas nos diferentes tipos e valores de defeito, além de permitir uma comparação ponto a ponto mais clara entre as curvas extraídas de dados com defeito e o caso ND, por possuir poucas descontinuidades, ondulações e artefatos na região de inflexão das curvas.

Na figuras 5.51, 5.52, 5.53 e 5.54 são comparadas as curvas extraídas pelos três algoritmos para os defeitos de channeling, qualidade de cimentação, descolamento interno e descolamento externo, respectivamente. A partir das figuras, observa-se como Pencil possui menos artefatos e ondulações que os outros dois algoritmos, além de ser o único a possibilitar a correlação entre as gravidades de defeitos e seus valores para todos os tipos avaliados. Destaca-se também como o algoritmo por operações morfológicas oferece menos informação que os outros, apresentando muitos artefatos.

Na tabela 5.10, é comparada a média de desempenho computacional dos distintos dados de entrada, e mostrado o número de amostras utilizadas por cada um dos algoritmos durante as extrações apresentadas nessa seção. A partir da tabela, destaca-se:

- O tempo de processamento de 2-D FT morfológico foi bastante superior




Figura 5.49: Curvas de slowness sobrepostas de poço multicamada sem *tubing* e sem defeito extraídas com os três algoritmos.

aos outros dois algoritmos, sendo mais de 6 vezes superior ao tempo necessário para Ridge, que obteve o melhor desempenho entre todos;

- Novamente o consumo máximo de memória RAM dos algoritmos baseados em 2-D FT se mostrou muito mais elevado que o visto com Pencil, alcançando em torno de 6.7 vezes o uso máximo em GB observado durante o processamento das curvas por Pencil;
- Pencil precisou de um número consideravelmente menor de amostras espaciais (4.8 vezes menor) e temporais (10 vezes menor) para conseguir resultados similares ou melhores que os algoritmos baseados em imagem. O número de amostras espaciais é o mais relevante para dados de campo, mas aqui foi necessário um número mais elevado do que o visto na seção 5.1.3 para a obtenção de resultados satisfatórios, possivelmente associado à maior complexidade da estrutura considerada, com múltiplas camadas de diferentes características materiais.

Algoritmo	Desempenho médio		Número de amostras	
	Tempo (s)	Memória (GB)	Espaço	Tempo
2-D FT Morfológico	492	14.9	1830	89523
2-D FT Ridge	80	14.9	1830	89523
Pencil	125	2.2	380	8953

Tabela 5.10: Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados de poço multicamada sem *tubing*.




Figura 5.50: Vista aproximada das curvas de slowness sobrepostas de poço multicamada sem *tubing* e sem defeito extraídas com os três algoritmos.

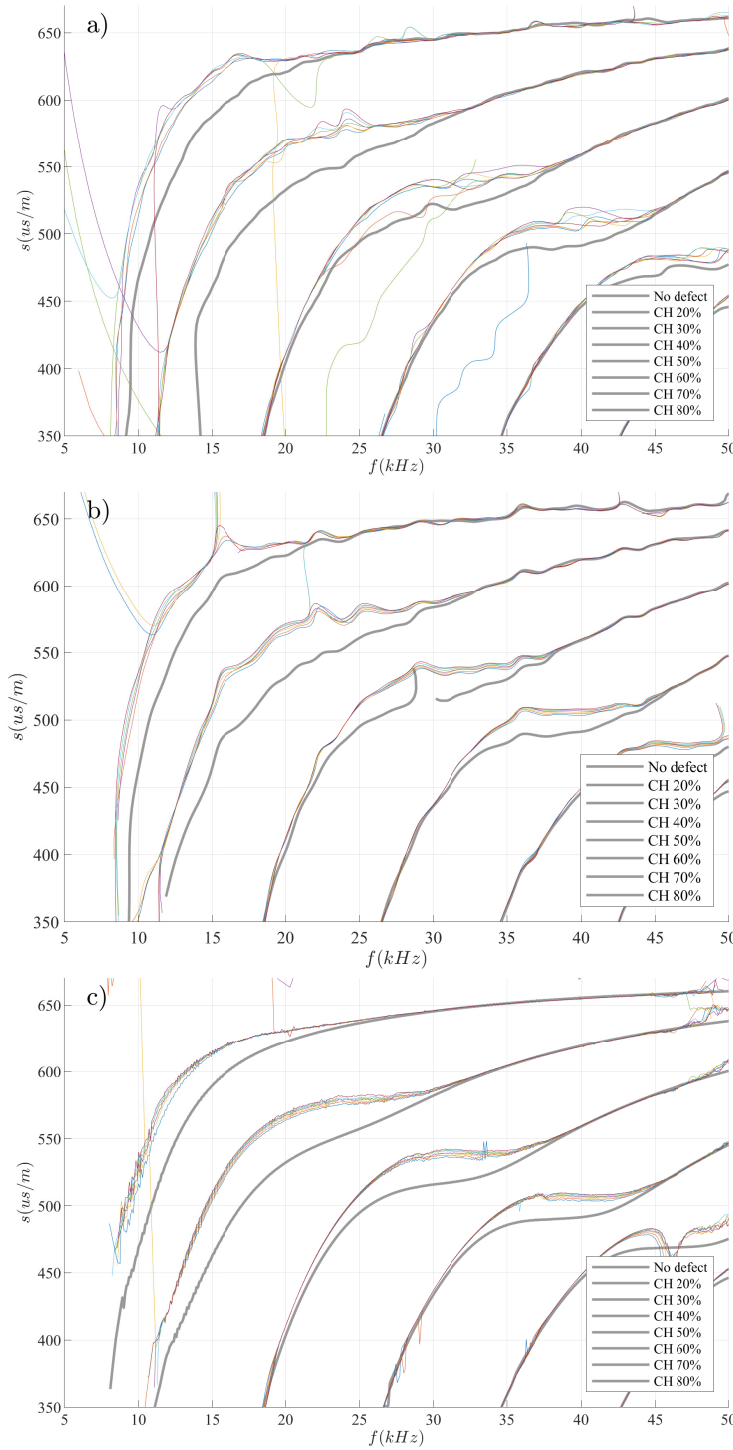


Figura 5.51: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem *tubing* com defeito de Channeling (CH): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

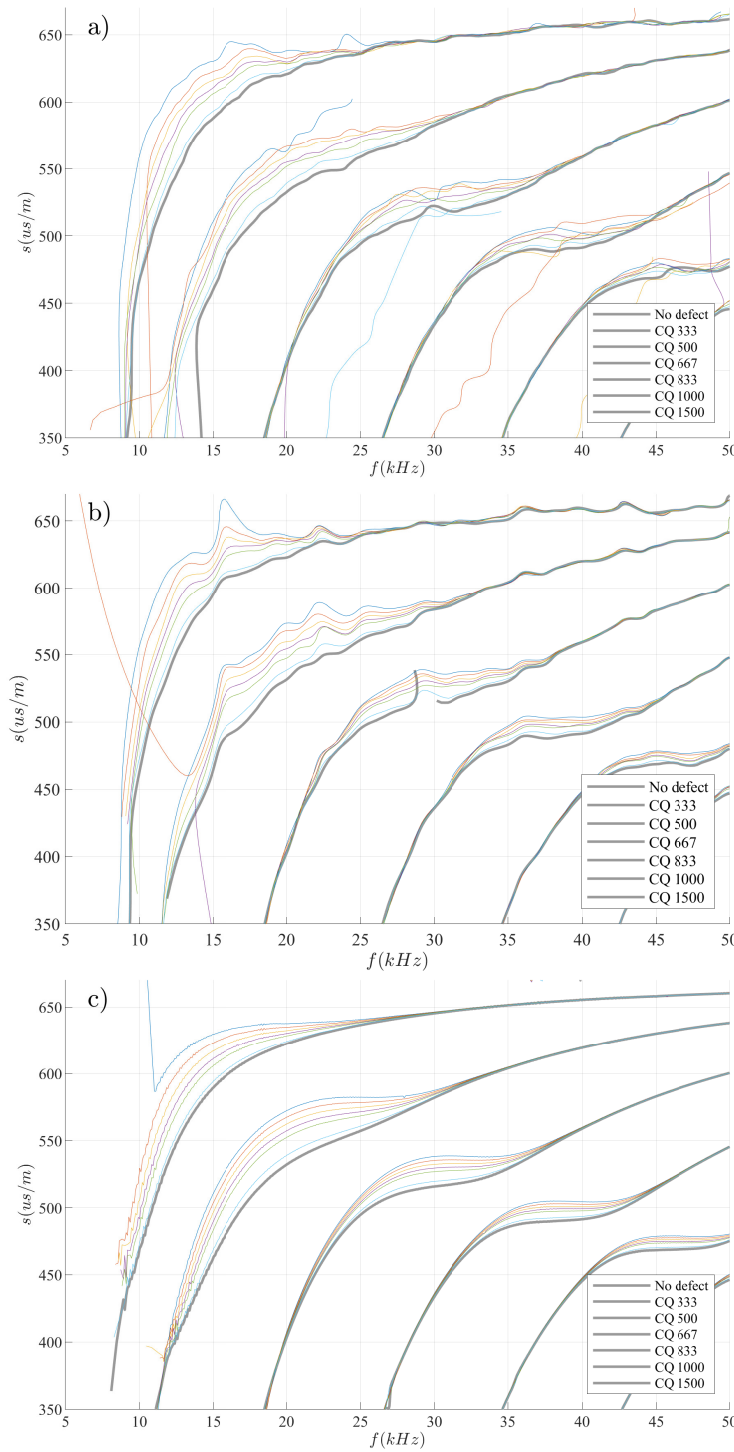


Figura 5.52: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem *tubing* com qualidade de cimentação baixa (CQ): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

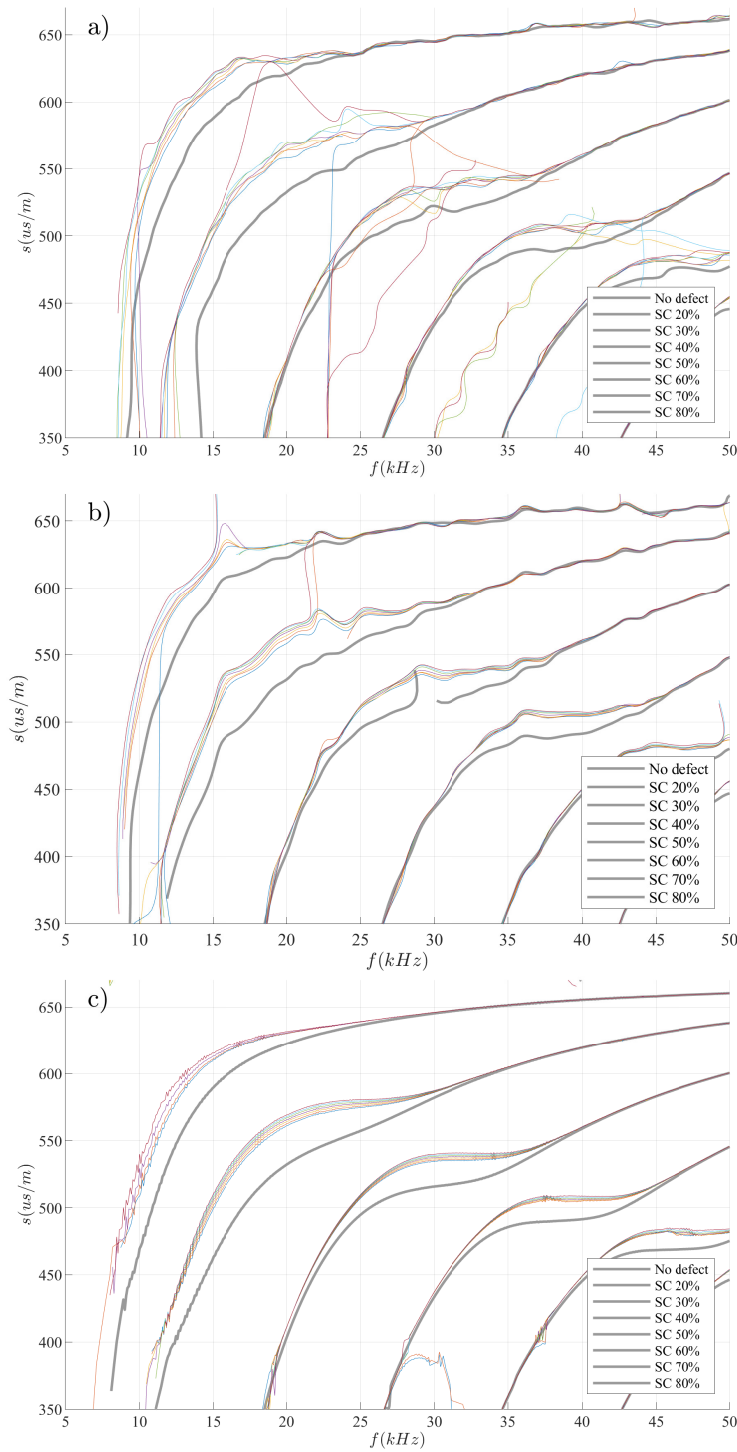


Figura 5.53: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem *tubing* com descolamento interno (SC): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

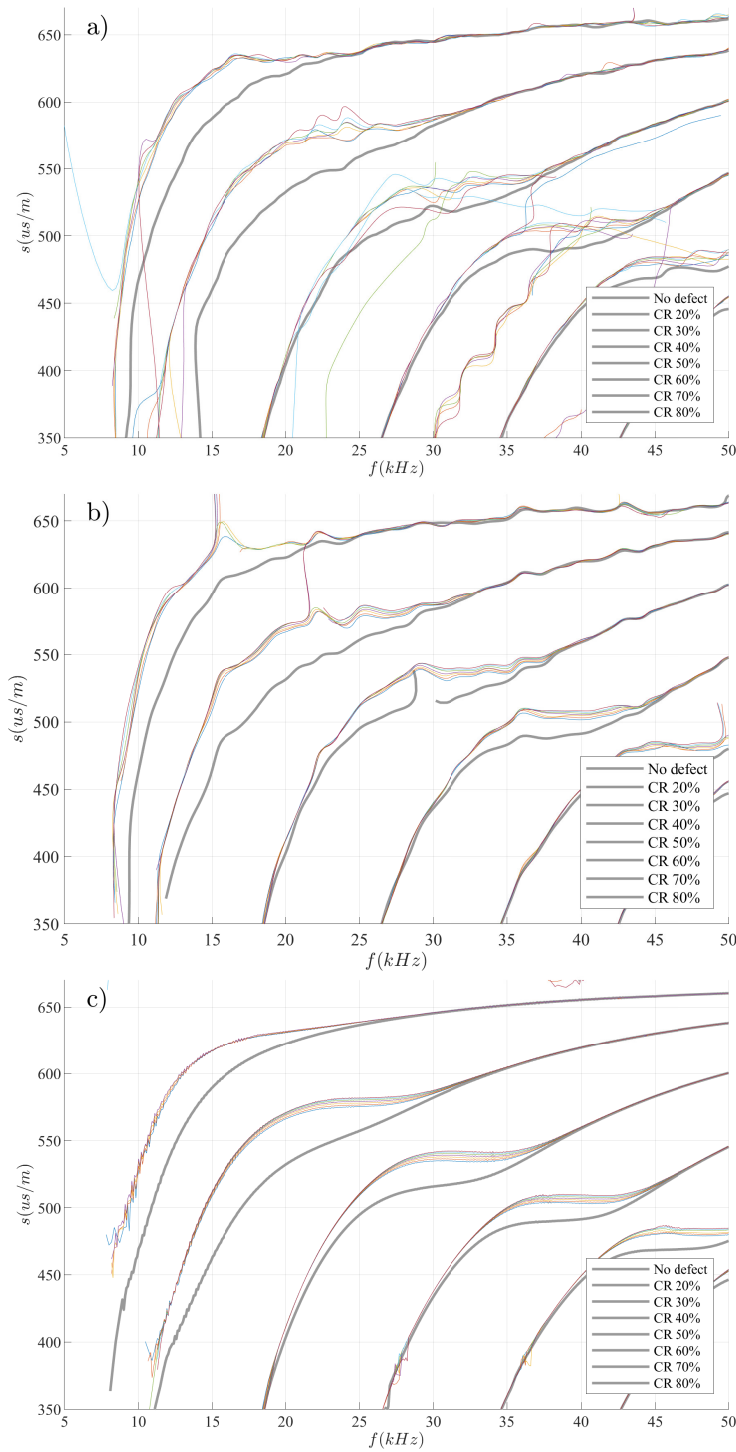


Figura 5.54: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço sem *tubing* com descolamento externo (CR): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

5.2.2

Poço com *tubing*

5.2.2.1

2-D FT com operações morfológicas

As configurações de extração foram mantidas com relação à extração da seção 5.2.1.1 e o pré-processamento descrito na seção 3.1.1 foi utilizado.

As curvas de dispersão identificadas pelo algoritmo para o caso sem defeito (ND) são mostradas na figura 5.55. Este modelo será usado como referência para a comparação das curvas extraídas das simulações de poço com defeito. Na extração do caso sem defeito, é perceptível que as curvas dos modos de propagação estão bem diferente em relação ao caso sem *tubing*: o número total de curvas é inferior e algumas delas são consideravelmente mais curtas. Além disso, não é possível notar a região de inflexão na faixa de frequência 35 – 45kHz, que é onde mais se destacava o desvio dos modos de onda guiada dos dados de poço com defeito no caso sem *tubing*.

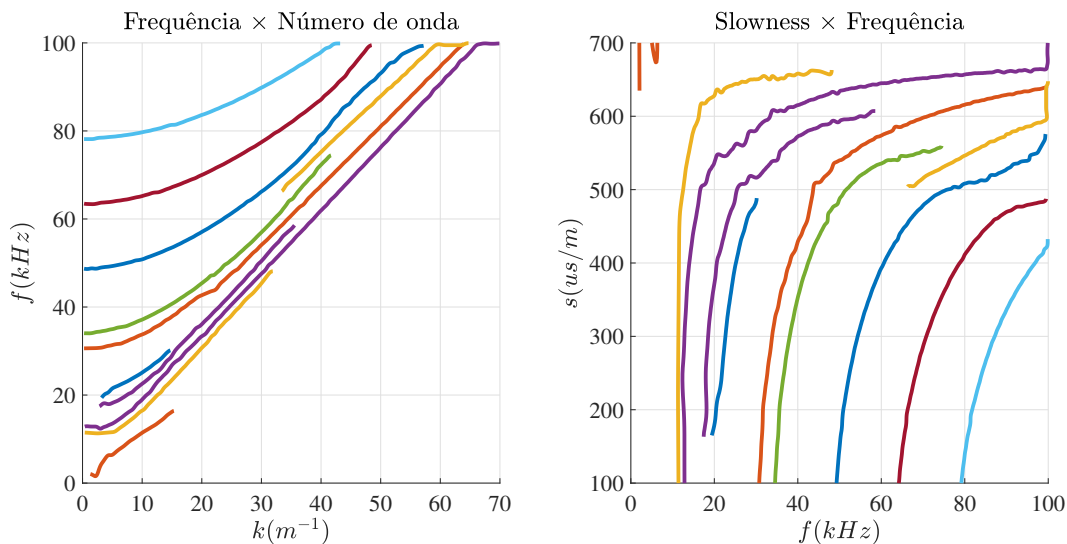


Figura 5.55: Curvas obtidas por 2-D FT com operação morfológicas de poço com *tubing* e sem defeito (ND).

As curvas de slowness obtidas a partir dos dados de poço com defeito do tipo Channeling (CH) são apresentadas na figura 5.56, com foco específico na região de interesse visto na figura 5.57. Novamente pode-se observar ondulações, tais como as vistas na seção 5.2.1.1, e também é possível perceber um número significativo de desvios com relação às curvas de referência. Além disso, mesmo na figura 5.57, é difícil identificar as tendências das curvas de defeito, que se encontram muito espalhadas, e não é possível afirmar que os grupos dos casos CH estão separados das curvas de referência justamente por isso.




Figura 5.56: Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CH.

Para as simulações com qualidade de cimentação degradada (CQ), o resultado da extração é mostrado nas figuras 5.58 e 5.59, sendo a última uma aproximação visual da primeira. Esse tipo de defeito apresenta um espalhamento maior das curvas entre os distintos valores de CQ. Apesar disso, devido a ondulações, embaralhamentos e trechos ausentes de algumas das curvas, é difícil notar muitas tendências nos desvios com relação à referência. A faixa de $15 - 20\text{kHz}$ apresenta alguma correlação entre as diferenças das curvas para o caso ND e os valores de CQ, apesar da ondulação.

O resultado da extração de curvas a partir de dados de poço com descolamento interno (SC) são expostos na figura 5.60 e uma aproximação na figura 5.61. Novamente se observa uma oscilação sobre curvas. Em grande parte, as curvas relativas a SC estão muito próximas da curva ND até para uma avaliação mais rasa sobre a presença de defeito. A partir da figura 5.61, é possível observar um grupo de curvas de SC próximo entre si e distante da referência, na faixa $15 - 20\text{kHz}$. A separação entre as curvas de defeito nesse grupo é suficiente para permitir a observação de uma tendência de desvio associado ao valor percentual de SC.

As curvas extraídas de dados de defeito de descolamento externo (CR) são apresentadas nas figuras 5.62 e 5.63, sendo a última uma vista com foco na região de inflexão das curvas. A partir desses resultados, é difícil de afirmar que o algoritmo demonstra claramente a diferença das curvas de erro CR para a referência. Apenas o grupo de curvas relativos ao modo com segundo maior slowness parece estar suficientemente distante da referência ND na faixa




Figura 5.57: Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CH.

15 – 20kHz de forma constante entre os diferentes valores de CR, porém as curvas estão muito próximas entre si para que se possa diferenciá-las com base no percentual de defeito.

As curvas extraídas com o algoritmo dessa seção podem fornecer informação sobre características de dispersão do poço com *tubing*, porém apenas no caso de defeito por qualidade de cimentação CQ é possível afirmar que houve um desvios claros com relação ao caso sem defeito. Em alguns dos casos é possível observar desvios no grupo de curvas com segundo maior valor de slowness na faixa 15 – 20kHz e correlacioná-los com a intensidade do defeito.

O tempo para a computação da matriz f-k a partir dos dados de entrada de uma simulação foi em média de 105s, enquanto o processo de geração da máscara e rastreo das curvas durou 388s, totalizando em 493s. O uso de memória alcançou 8.9GB.




Figura 5.58: Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CQ.




Figura 5.59: Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CQ.




Figura 5.60: Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com *tubing* com defeito SC.




Figura 5.61: Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com *tubing* com defeito SC.




Figura 5.62: Curvas de slowness extraídas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CR.




Figura 5.63: Vista aproximada das curvas de slowness obtidas por 2-D FT com operações morfológicas de poço com *tubing* com defeito CR.

5.2.2.2

2-D FT com algoritmo Ridge

Durante a geração dos resultados vistos aqui, utilizou-se o conjunto de configurações da seção 5.2.1.2 e o pré-processamento descrito na seção 3.1.1. Inicialmente, extraiu-se as curvas de dispersão para o caso sem defeito, que será usado como parâmetro de comparação para as simulações de poços com defeito. O plot resultante está na figura 5.64. Assim como visto na seção 5.2.2.1, as curvas obtidas para a simulação de poço com *tubing* são mais esparsas e muitas delas são mais curtas que as vistas nos casos de poço sem *tubing*, indicando que porções das curvas relativas a certos modos de propagação não puderam ser captadas pelo algoritmo. A região de inflexão também não é mais captada nesse caso, o que deve influenciar na capacidade de diferenciação dos casos com defeito.




Figura 5.64: Curvas obtidas por 2-D FT com Ridge de poço com *tubing* e sem defeito (ND).

Para simulações de defeito do tipo Channeling (CH), os resultados obtidos podem ser observados na figura 5.65, com aproximação apresentada na figuras 5.66. As ondulações percebidas nas extrações da seção 5.2.1.2 continuam presentes aqui, algo evidente mesmo na visão geral da figura 5.65. É possível notar seções espúrias nas pontas das curvas encontradas, até mesmo no caso ND. Em geral, as curvas de defeito não apresentam desvios tão claros da referência, porém, no foco da figura 5.66 é possível notar algumas seções em que os desvios das curvas dos defeitos estão relacionados à porcentagem de CH como 15 – 20 kHz e 32 – 34 kHz, mas existem alguns cruzamentos entre as curvas, que, em geral, estão bem próximas entre si.

Os resultados para diferentes qualidades de cimentação (CQ) são vistos figura 5.67, e o destaque para a seção das inflexões está na figura 5.68. Novamente se apresentam bastantes artefatos nas pontas de algumas das




Figura 5.65: Curvas de slowness extraídas por 2-D FT com Ridge de poço com *tubing* com defeito CH.

curvas. Observa-se que para os dois agrupamentos de curvas de maior valor de slowness na região $10 - 30\text{kHz}$, é possível perceber uma distância maior da referência. Isso é mais evidente no grupo de segundo maior slowness, que é evidenciado na figura 5.68. Aqui, é possível observar também a correlação dos desvios com relação a ND com o valor de intensidade de CQ, graças à distância que as curvas relativas a valores distintos de degradação possuem entre si nessa região. A figura 5.67 mostra também algumas curvas partidas e outras ausentes para determinados valores de CQ.

A extração a partir das simulações de poço com descolamento interno (SC) resultou na figura 5.69, que é aproximada na figura 5.70. A partir dos plots, sobretudo da 5.70, é possível observar que, novamente nas regiões de $15 - 20\text{kHz}$ e $32 - 34\text{kHz}$, o ordenamento das curvas de diferentes erros se correlaciona com as porcentagens de defeito SC. A faixa $32 - 34\text{kHz}$ destaca um grupo de curvas em que os desvio estão associados ao percentual de erro, porém, o conjunto de curvas de SC está muito próximo da curva ND. Aqui, é difícil diferenciar a ondulação causada pelo algoritmo dos desvios nas curvas dos modos de propagação associados a defeitos. No resto dos gráficos é difícil identificar um padrão específico de diferença no comportamento das curvas de dispersão dos casos de defeito.

Para o caso dos defeitos de descolamento externo (CR), as relações slowness \times frequência encontradas são apresentadas na figura 5.71, e, subsequentemente, na figura 5.72, com aproximação na área de maior interesse. Assim como nos outros casos, as faixas de frequência $15 - 20\text{kHz}$ e $32 - 34\text{kHz}$ são as




Figura 5.66: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com *tubing* com defeito CH.

que apresentam mais claramente a ordenação correlacionada às porcentagens de defeito, sendo o desvio dos grupo de curvas da primeira faixa mais evidente com relação ao caso ND. Porém, na região $15 - 20\text{kHz}$ ocorrem entrelaçamentos e existem certas curvas muito próximas umas das outras. Nas outras regiões, é bem difícil de tirar conclusão sobre relação dos defeitos com a forma ou desvio das curvas.

Os resultados dessa seção indicam, similarmente à seção 5.2.2.1, que o modo de propagação referente ao grupo de curvas de segundo maior valor de slowness é o que apresenta mais variação com relação a ND para todos os tipos de defeito. Nesse grupo, é possível correlacionar os desvios com os valores associados de defeito simulados de forma mais clara que nos casos de extração por 2-D FT com operação morfológicas da seção 5.2.2.1, mas seria desejável uma diferença observável maior.

É possível que a dificuldade em obter maior qualidade nos resultados visto pelo algoritmos que usam 2-D FT nesta seção e na 5.2.2.1 esteja associada a limitações provocadas pelo uso da 2-D FT. Mesmo uma inspeção visual da imagem f-k obtida para o caso ND, apresentada na figura 5.73, indica que as curvas são de difícil identificação no caso com *tubing*. É possível que uma maior resolução em frequência e número de onda, que poderia ser obtida com um maior número de amostras em tempo-espaco, sem alteração das taxas de amostragem, resultasse em uma figura mais nítida para os algoritmos de extração, porém, o número de amostras espaciais usadas nas simulações já é bem mais elevado do que seria possível em implementações reais.




Figura 5.67: Curvas de slowness extraídas por 2-D FT com Ridge de poço com *tubing* com defeito CQ.

O tempo de processamento para cada simulação da figura f-k foi de 105s em média, enquanto a geração das máscaras e rastreamento demorou 15s, totalizando em 120s. O uso máximo de memória foi de 9.1GB.




Figura 5.68: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com *tubing* com defeito CQ.




Figura 5.69: Curvas de slowness extraídas por 2-D FT com Ridge de poço com *tubing* com defeito SC.




Figura 5.70: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com *tubing* com defeito SC.




Figura 5.71: Curvas de slowness extraídas por 2-D FT com Ridge de poço com *tubing* com defeito CR.




Figura 5.72: Vista aproximada das curvas de slowness obtidas por 2-D FT com Ridge de poço com *tubing* com defeito CR.




Figura 5.73: Imagem obtida a partir da matriz f-k gerada pela 2-D FT do conjunto de dados com *tubing* ND.

5.2.2.3

Método Pencil

Devido a diferenças entre os conjuntos de dados simulados para os casos com e sem *tubing*, foi necessário fazer alterações nos parâmetros de entrada do algoritmo de Pencil para se obter melhores resultados. As configurações utilizadas para obtenção das curvas mostradas nessa seção estão na tabela 5.11.

Parâmetro	Valor
mg	0.1
p	200
$sStep$	1:5
$sInit$	0.020
$sSamp$	360
$tStep$	1:10

Tabela 5.11: Parâmetros do algoritmo Pencil usados com os dados de entrada da poço multimaçada com *tubing*.

Dessa vez utilizou-se valores mais extremos da combinação de margem baixa e número alto de modos esperados, vistas nas seções 5.1.3 e 5.2.1.3, com o objetivo de reduzir ao máximo a quantidade de artefatos encontrados, mas ainda assim encontrar um número de pontos razoável relativo às curvas de dispersão. O número de posições utilizadas também foi substancialmente elevado até proporcionar resultados satisfatórios. A razão de undersampling no tempo não alterou significativamente o resultado e foi escolhida a relação 1:10 para reduzir o custo computacional.

A figura 5.74 mostra o resultado da extração para o caso de simulação de poço sem defeito (ND). Essas curvas serão a referência de comparação para os resultados obtidos pelo algoritmo para as simulações de defeito. Percebe-se que a extração por Pencil capturou porções muito mais longas das curvas, além de um número maior delas, que os algoritmos baseados em 2-D FT mostrados nas seções 5.2.2.1 e 5.2.2.2. Também se verifica a tendência do algoritmo Pencil de não captar bem pontos relativos a regiões que combinam alta frequência e número de onda menor. É possível observar trechos das regiões de inflexão vistas nos casos sem *tubing* na faixa $20 - 40kHz$, o que não foi demonstrado nos algoritmos baseados em 2-D FT para esse conjunto de dados.

Os resultados da extração dos dados de defeito Channeling (CH) são mostrados nas figuras 5.75 e 5.76, esta última com foco nas regiões de inflexão. Na visão da figura 5.75 é possível perceber que existem bastantes elementos indesejáveis detectados em algumas das curvas de defeito, sobretudo acima de $50kHz$, o que está relacionado ao conjunto de parâmetros usados junto

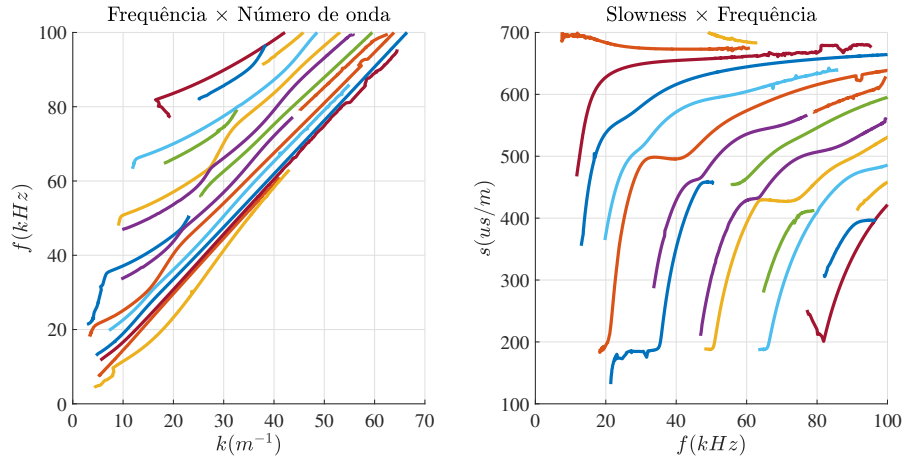


Figura 5.74: Curvas obtidas por Pencil de poço com *tubing* e sem defeito (ND).

ao algoritmo de Pencil para esses casos. Ainda assim, é possível identificar as seções das curvas análogas ao caso ND abaixo da frequência 50kHz , e as curvas relativas às simulações CH se agrupam com alguma distância da referência. Nota-se claramente a relação da intensidade de defeito CH com o desvio de ND através da figura 5.76, apesar da proximidade entre as curvas de defeito.




Figura 5.75: Curvas de slowness extraídas por Pencil de poço com *tubing* com defeito CH.

As simulações com diferentes qualidades de cimentação (CQ) para o caso com *tubing* têm suas curvas expostas na figura 5.77, com foco específico apresentado na figura 5.78. Mesmo na visão geral já é possível observar as diferenças graduais entre as curvas de diferentes valores de CQ com relação à referência abaixo da frequência 50kHz e excluindo-se o grupo de curvas na faixa de slowness $650 - 800\text{us/m}$, que apresenta característica ruidosa elevada.




Figura 5.76: Vista aproximada das curvas de slowness obtidas por Pencil de poço com *tubing* com defeito CH.

A figura 5.78 evidencia as diferenças dos casos distintos de CQ entre si e com relação a ND.

A figura 5.79 ilustra o resultado obtido com o conjunto de dados de descolamento interno (SC), enquanto a figura 5.80 aproxima a seção onde são mais claros os desvios entre as curvas de diferentes valores de defeito. Novamente, nota-se alguns artefatos indesejados para alguns dos valores de defeito na visão geral da figura 5.79, e caráter ruidoso das curvas para valores de slowness e frequência mais elevados. As curvas de cada modo de propagação se aproximam entre si nos casos de defeito e distanciam-se da referência, ND, na faixa 10 – 50kHz. Na figura 5.80, apesar de as curvas para diferentes porcentagens de defeitos permanecerem bem próximas entre si, há uma separação clara entre elas, e nota-se a relação de desvio com relação a ND com os valores percentuais de SC.

A partir das simulações de descolamento externo (CR), gerou-se as curvas de slowness vistas nas figuras 5.81 e 5.82, onde a última foca na seção de inflexão. Pela figura 5.81, é possível ver que muitas curvas análogas ao caso ND podem ser identificadas e o formato delas é bem claro dentro da faixa específica analisada na figura 5.82, assim como a separação das curvas dos modos de propagação nos casos de defeito com relação a ND. Tal como nos casos dos defeitos anteriores, é evidente o ordenamento das curvas com relação aos valores distintos de CR.

Os resultados dessa seção mostram que o algoritmo Pencil é indicado para a identificação da presença de defeitos, por separar claramente os grupos de




Figura 5.77: Curvas de slowness extraídas por Pencil de poço com *tubing* com defeito CQ.

curvas com defeito da referência de poço sem falha, ND. Além disso, o algoritmo se mostrou bastante sensível à mudança nos valores de defeito utilizados, indicando claramente diferenças entre as curvas para diferentes simulações dos mesmos tipos de defeito. O tempo médio de execução do algoritmo de Pencil em conjunto com o rastreamento foi de 132s, com o uso máximo de memória alcançando 2.3GB.




Figura 5.78: Vista aproximada das curvas de slowness obtidas por Pencil de poço com *tubing* com defeito CQ.




Figura 5.79: Curvas de slowness extraídas por Pencil de poço com *tubing* com defeito SC.




Figura 5.80: Vista aproximada das curvas de slowness obtidas por Pencil de poço com *tubing* com defeito SC.




Figura 5.81: Curvas de slowness extraídas por Pencil de poço com *tubing* com defeito CR.




Figura 5.82: Vista aproximada das curvas de slowness obtidas por Pencil de poço com *tubing* com defeito CR.

5.2.2.4

Comparação dos resultados

Nessa seção, são expostos os resultados das extrações das curvas de dispersão pelos três algoritmos—2-D FT morfológico, 2-D FT com Ridge e Pencil—, para distintos tipos e valores de defeito e também para o caso sem defeito de poço multicamada com *tubing*. A partir do uso de 2-D FT com operações morfológicas, apenas para os dados relativos ao erro CQ foi possível observar de forma mais consistente e clara os desvios apresentados pelas curvas de poucos dos modos de propagação com relação ao caso sem defeito, assim como correlação entre esses desvios e os valores dos defeitos. Para os outros casos de defeito, muitas vezes as curvas de dispersão para certos modos não estavam presentes em alguns dos valores de defeito ou os desvios eram difíceis de serem diferenciados das ondulações apresentadas pelas curvas extraídas pelo algoritmo de forma geral. Além disso, muitos artefatos, desvios e descontinuidades são encontradas nas curvas obtidas por esse método com esse conjunto de dados, o que atrapalha bastante a visualização e comparação dos resultados. Utilizando o algoritmo 2-D FT com Ridge, foi possível extrair as curvas e se observar desvios com relação ao caso sem defeito para poucos dos modos de propagação. O modo de propagação com origem em torno da frequência $13kHz$ parece ser aquele extraído de forma mais consistente pelo algoritmo, permitindo a correlação entre os valores de defeito e os desvios em suas curvas com relação ao caso ND. Novamente, destaca-se que bastantes artefatos e ondulações são perceptíveis entre as curvas extraídas, o que dificulta o processo de avaliação de defeito com relação à referência, ND. O algoritmo de Pencil se destaca entre os três vistos aqui, apresentando poucos ruídos, descontinuidades ou artefatos nas áreas de inflexão, de maior relevância, para todos os dados de entrada utilizados nessa seção. Assim, a comparação entre os diferentes tipos de defeito e seus valores se mostra muito mais vantajosa por Pencil, onde é possível observar os desvios claros entre as curvas de defeito e o caso ND em múltiplos dos modos de propagação na faixa de inflexão.

A figura 5.83 mostra as curvas de dispersão extraídas pelos três algoritmos de extração sobrepostas para o caso de poço multicamada com *tubing* sem defeito. A vista aproximada pode ser está na figura 5.84, onde maior foco é dado à região de inflexão das curvas de dispersão. É possível observar sobreposição de alguns trechos das curvas dos três algoritmos, porém, o algoritmo Pencil parece mostrar a trajetória das curvas por faixas de valores de frequência e slowness claramente maiores. Além disso, observa-se a tendência dos algoritmos baseados em imagem de captar ondulações de caráter aleatórios em conjunto com as curvas, além de promoverem algumas bifurcações e um




Figura 5.83: Curvas de slowness sobrepostas de poço multicamada com *tubing* e sem defeito extraídas com os três algoritmos.

número maior de discontinuidades.

Na figuras 5.85, 5.86, 5.87 e 5.88 são comparadas as curvas extraídas pelos três algoritmos para os defeitos de channeling, qualidade de cimentação, descolamento interno e descolamento externo, respectivamente. Por meio das figuras, observa-se que os dois algoritmos baseados em 2-D FT apresentam muitos artefatos, tornando difícil a extração de informação sobre os defeitos. O algoritmo de Pencil, no entanto, é capaz de ressaltar a presença dos defeitos para todos os casos, assim como correlacionar seus valores com os offsets com relação ao caso sem defeito (ND).

A comparação do desempenho médio obtido durante a extração para os diferentes casos, com e sem defeito, com os três algoritmos de extração, assim como o número de amostras utilizadas durante a extração, é apresentada na tabela 5.12. Com base nos dados nela expostos, pode-se evidenciar:

- O uso de memória dos algoritmos com base em imagem é novamente mais alto que o de Pencil, chegando a ser 3.9 vezes superior no caso de Ridge;
- O tempo de processamento do algoritmo 2-D FT com operações morfológicas é em torno de 4 vezes superior ao dos outros algoritmos, apesar de ter mostrado resultados apenas comparáveis a Ridge e claramente inferiores a Pencil, no que diz respeito às curvas extraídas;
- Pencil utiliza 5 vezes menos amostras espaciais e 10 vezes menos amostras temporais que os dois outros algoritmos. Isso se reflete no consumo menor de memória e é mais apropriado à extração das curvas com base em




Figura 5.84: Vista aproximada das curvas de slowness sobrepostas de poço multicamada com *tubing* e sem defeito extraídas com os três algoritmos.

dados de entrada obtidos experimentalmente e em campo, que estão sujeitos a mais limitações no que diz respeito à quantidade de amostras espaciais (49).

Algoritmo	Desempenho médio		Número de amostras	
	Tempo (s)	Memória (GB)	Espaço	Tempo
2-D FT Morfológico	493	8.9	1830	89523
2-D FT Ridge	120	9.1	1830	89523
Pencil	132	2.3	360	8953

Tabela 5.12: Comparação do desempenho médio e número de amostras utilizadas pelos algoritmos para a extração das curvas com base nos dados de poço multicamada com *tubing*.

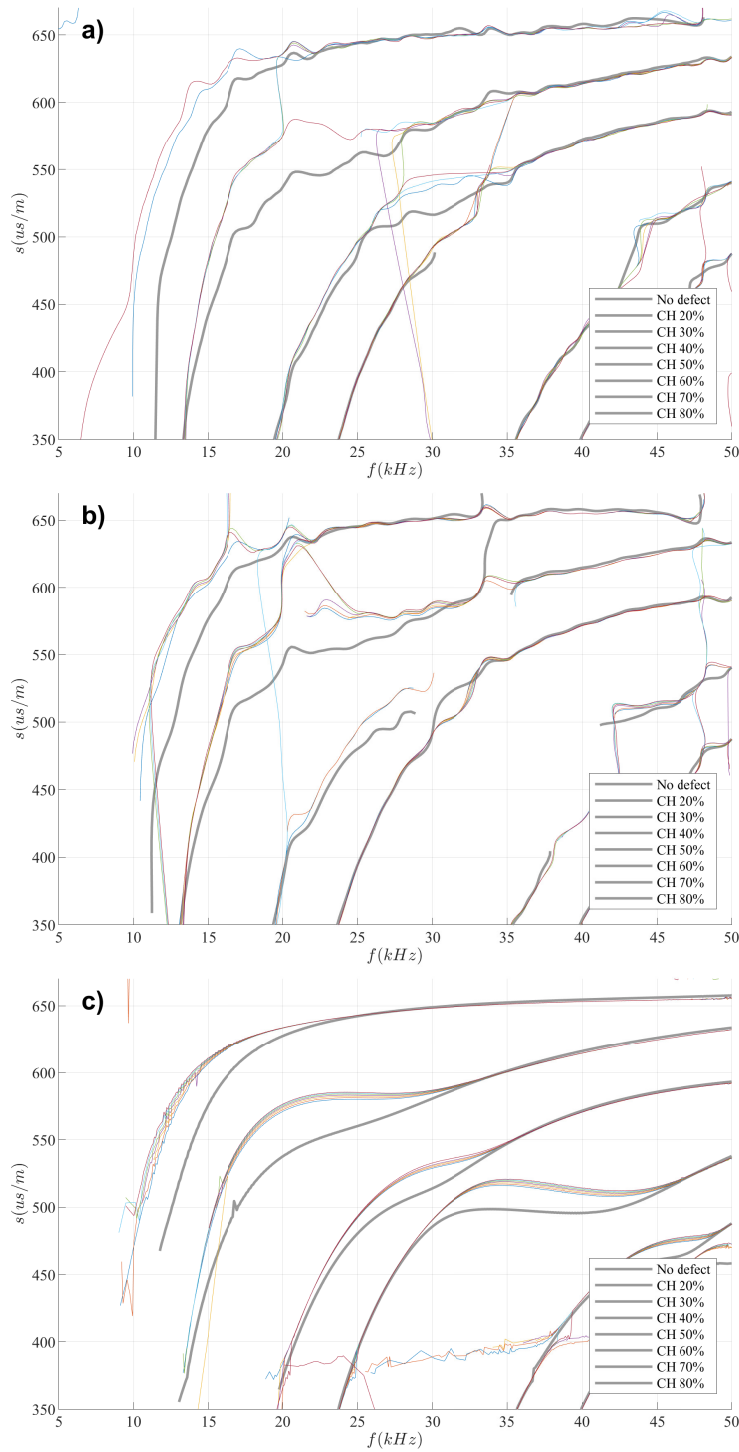


Figura 5.85: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com defeito de Channeling (CH): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

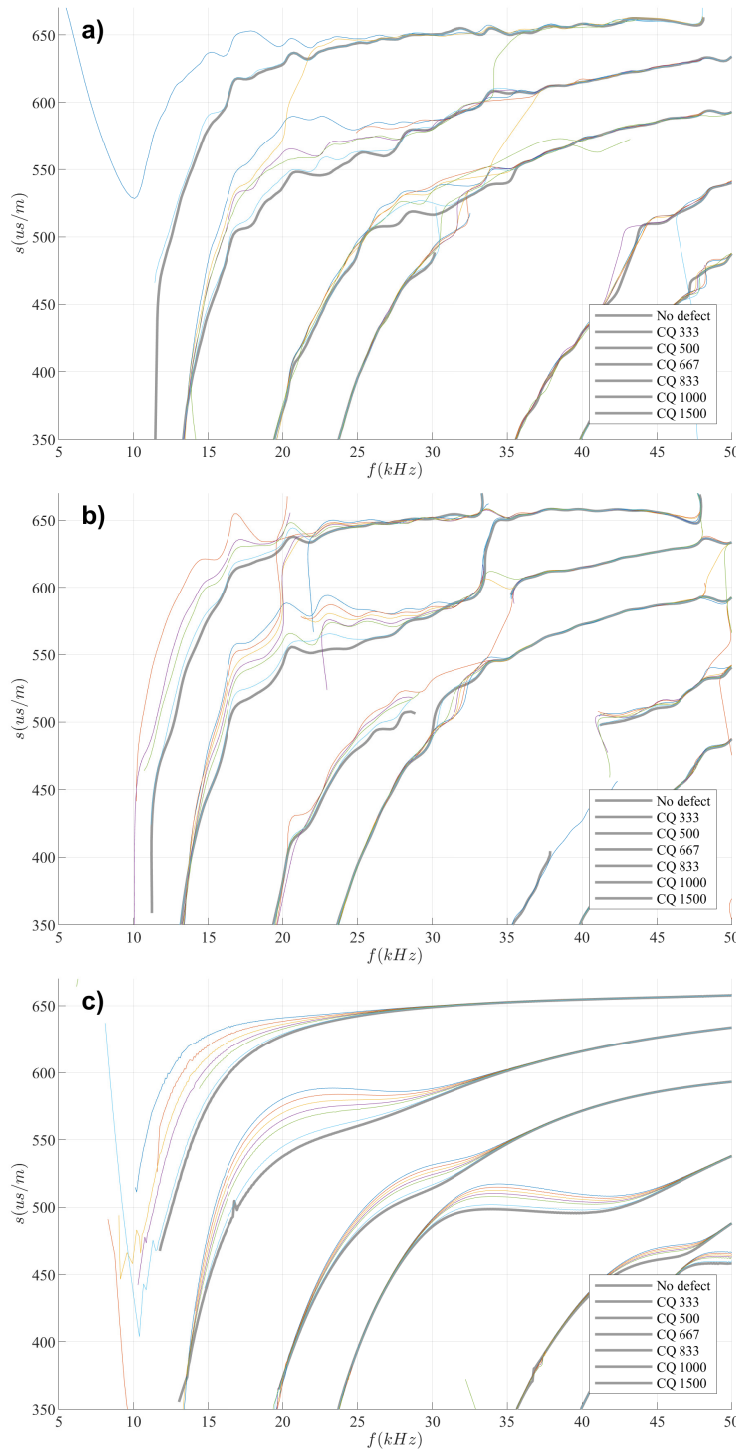


Figura 5.86: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com qualidade de cimentação baixa (CQ): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

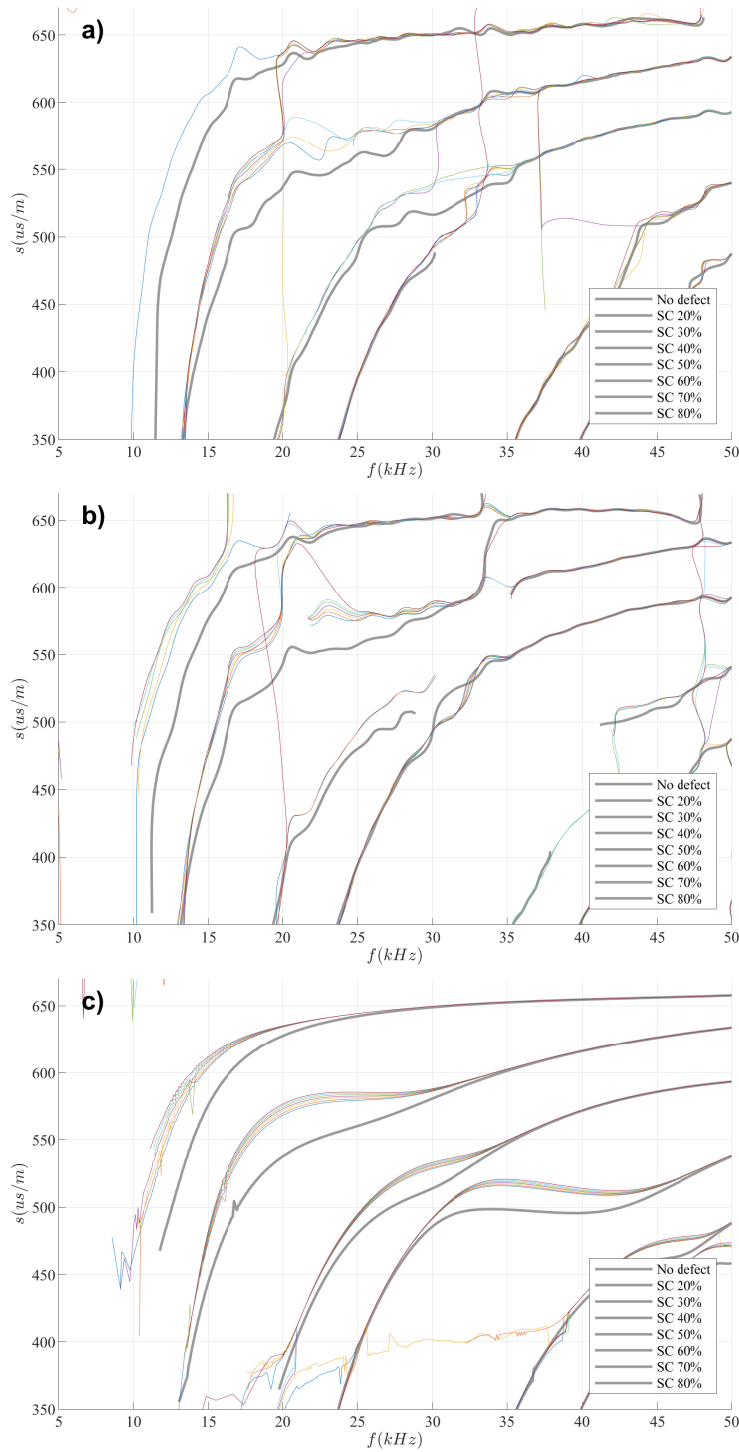


Figura 5.87: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com descolamento interno (SC): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

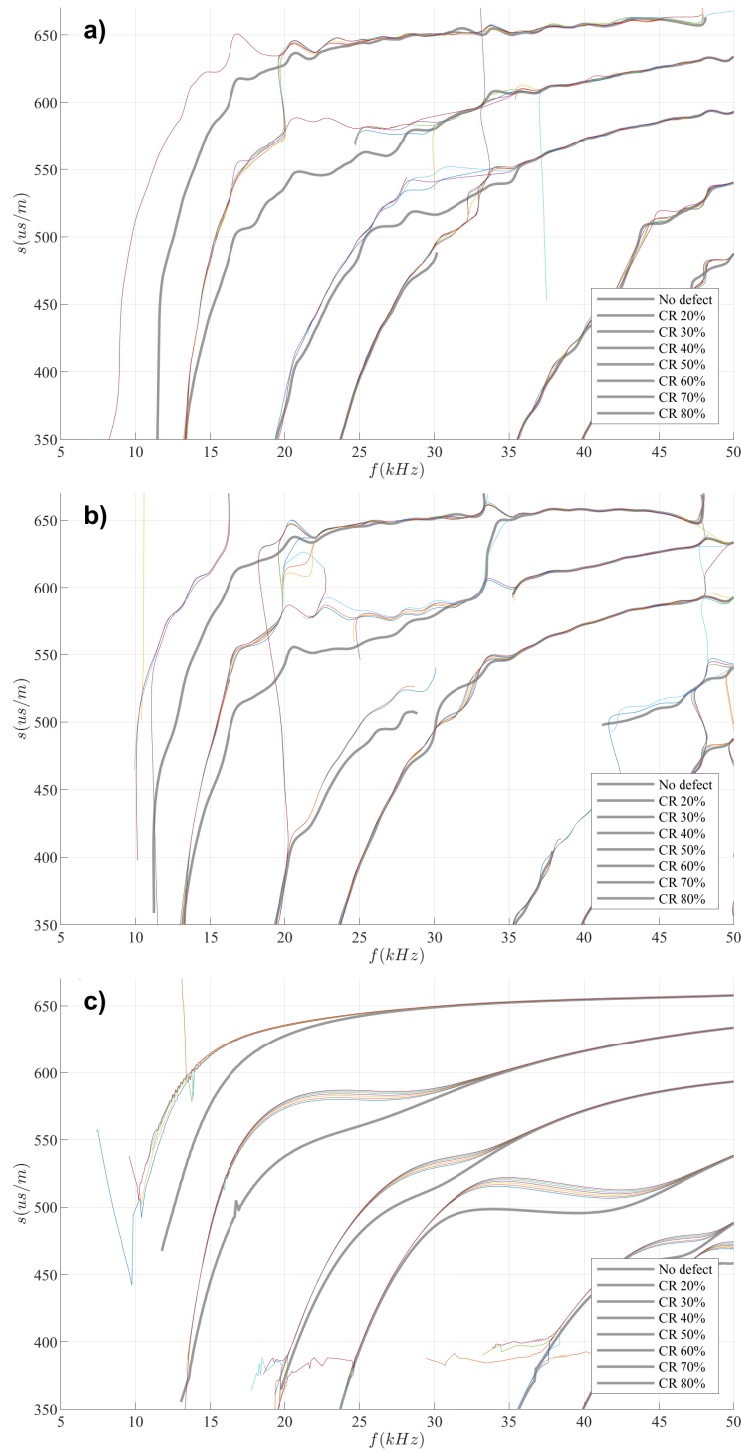


Figura 5.88: Resultados das extrações das curvas de dispersão pelos 3 algoritmos para poço com *tubing* com descolamento externo (CR): a) 2-D FT Morfológico; b) 2-D FT Ridge; c) Pencil. Os plots foram repetidos para maior conveniência de inspeção das diferenças entre os algoritmos.

6

Conclusão

A obtenção das curvas de dispersão relativas aos modos de propagação de ondas guiadas é de relevância para distintas áreas de aplicação, tal como a avaliação de poços na área de óleo e gás, monitoramento estrutural na engenharia civil e caracterização de materiais. Neste trabalho foram propostos dois métodos de extração das curvas de dispersão a partir de uma matriz de dados de sensores ultrassônicos no espaço-tempo com base no uso da 2-D FT. O primeiro foi desenvolvido neste trabalho com base em operação morfológicas, exposto na seção 3.1.4. O segundo, exposto na seção 3.1.2, foi desenvolvido com base no algoritmo de extração de estruturas curvilíneas de imagens proposto por Steger (51). Foi também proposta uma modificação em um terceiro algoritmo de extração das curvas de dispersão a partir de uma matriz tempo-espaço, o método de Pencil, proposto por Ekstrom (49), objetivando-se aprimorar a estimativa dos números de ondas referentes aos modos de propagação em cada frequência de interesse. O mesmo é mostrado na seção 3.2. Além disso, propôs-se, também, um algoritmo que separa pontos f - k não triados em curvas na seção 3.3. As adições e técnicas propostas e implementadas apresentaram bons resultados e ajudaram a automatizar o processo de extração para diferentes conjuntos de dados de entrada.

Os três algoritmos abordados foram utilizados em conjuntos com dados simulados de estudos de caso distintos, sendo seus desempenhos comparados, estes foram: uma placa de alumínio fina com sensores ultrassônicos fornecendo medições em dois sentidos, x e y , sujeita à distintos níveis de tração uniaxial paralela ao sentido de propagação; um poço multicamada preenchido com água, análogo a um poço encontrado na indústria de óleo e gás, sem a estrutura de aço interna, denominada *tubing*, com quatro distintos tipos de defeito—channeling, qualidade de cimentação baixa e descolamento interno e externo da camada de cimento— e sem defeito; um poço multicamada preenchido com água, com camada de aço interna referente ao *tubing* e com os mesmos tipos de defeito supracitados, assim como sem defeito.

Observou-se que os três algoritmos apresentaram resultados satisfatórios com respeito à extração de dados relativos à placa de alumínio, visto na seção 5.1. os mesmos foram capazes de extrair os modos de curva presentes na faixa de valores f - k trabalhada com erro baixo com relação aos valores teóricos, além de captarem de forma clara as mudanças esperadas nas curvas para os casos com tração uniaxial aplicada a placa. Os algoritmos com base

em imagem tiveram resultados semelhante, porém o tempo de processamento utilizado pelo algoritmo 2-D FT com Ridge foi 11 vezes menor que o visto com 2-D FT morfológico. O algoritmo de Pencil merece destaque por ter obtido resultados muito próximos aos outros dois algoritmos com o uso de apenas 80 amostras espaciais (quase 100 vezes menor que os outros algoritmos), o que é mais próximo do número de amostras disponíveis em campo e diminui os requisitos de memória na eletrônica embarcada ao equipamento de captação das ondas guiadas.

Os resultados obtidos com o conjunto de dados do poço multicamada sem *tubing* indicam que os três algoritmos são capazes de fornecer curvas de dispersão que diferenciam conjuntos de dados de poços com e sem defeito. Para identificar o tipo e grau dos defeitos, no entanto, apenas o algoritmo de Pencil se mostrou consistentemente apropriado para comparar as diferenças nas curvas de múltiplos modos de propagação com respeito aos diferentes tipos de defeito dos dados simulados. No caso dos dados de poço com *tubing*, as curvas extraídas por todos os algoritmos foram menos claras e mais sujeitas a artefatos. Se mostrou difícil identificar com confiança a presença de defeitos por 2-D FT morfológico, enquanto 2-D FT com Ridge permitiu a identificação de defeitos em curvas relativas a poucos modos de propagação, porém sem informação mais clara sobre características dos defeitos. Pencil novamente foi o algoritmo mais robusto, consistentemente permitindo a identificação de diferenças entre os dados de distintos tipos e graus de defeitos para múltiplos modos de propagação. Além disso, para os dados de poço com e sem *tubing*, Pencil precisou de 5 vezes menos amostras espaciais e 10 vezes menos amostras temporais.

Os algoritmos propostos e utilizados aqui foram capazes de extrair as curvas de dispersão com diferentes graus de precisão e consistência, de acordo com dados de entrada diversos. Os algoritmos baseados na 2-D FT, morfológico e Ridge, obtiveram resultados similares, porém Ridge necessitou de um tempo de processamento significativamente menor. Ridge se mostrou diminutamente mais eficaz que o algoritmo morfológico para comparação de curvas extraídas com diferentes dados de entrada. Pencil se mostrou o algoritmo mais robusto, tendo fornecido bons resultados para todos os dados de entrada, o que está associado à quantidade de parâmetros ajustáveis pelo usuário para a extração, permitindo um ajuste-fino com base no caso explorado. É importante ressaltar que o algoritmo Pencil demonstrou uma tendência de não captar pontos em regiões no plano $f-k$ com valores de frequência menores combinados a números de onda mais elevados. Pencil também se mostrou muito menos dependente do número de amostras espaciais, sendo mais indicado a trabalhar com dados

experimentais e de campo. O algoritmo de separação de curvas proposto na seção 3.3 se mostrou exitoso em organizar os pontos f-k em curvas de dispersão correspondentes a partir de dados de entrada dos três distintos algoritmos de extração, ajudando a suprir suas deficiências, a um custo computacional baixo.

A tabela 6.1 compara alguns parâmetros de desempenho dos algoritmos de extração de forma resumida. Na mesma, são comparados as seguintes características:

- Esforço computacional - Tempo de processamento necessário para a extração das curvas;
- Consumo de memória - Consumo máximo de memória RAM utilizado durante a extração da curvas;
- Presença de artefatos - Identificação de curvas, inteiras ou trechos, erradas devido a extração de pontos f-k espúrios;
- Presença de ondulações - Característica de ondulação de caráter aleatório identificadas em curvas extraídas;
- Distinção entre tensões - Capacidade do algoritmo de identificar as diferenças entre as curvas de dispersão para diferentes valores de tensão uniaxial aplicada na placa de alumínio;
- Distinção entre defeitos - Capacidade do algoritmo de fornecer curvas de dispersão que indiquem as diferenças entre os diferentes casos e intensidades de defeito de cimentação nas simulações do poço multicamada com e sem *tubing*;
- Número de amostras espaciais - Quantidade de pontos espaciais necessários no conjunto de dados de entrada para que o algoritmo identifique as curvas de dispersão de forma apropriada.

	2-D FT Morfológico	2-D FT Ridge	Pencil
Esforço computacional	Alto	Baixo	Moderado
Consumo de memória	Alto	Alto	Baixo
Presença de artefatos	Moderado	Baixo	Moderado
Presença de ondulações	Moderado	Alto	Baixo
Distinção entre trações	Bom	Bom	Bom
Distinção entre defeitos sem <i>tubing</i>	Moderado	Moderado	Bom
Distinção entre defeitos com <i>tubing</i>	Ruim	Ruim	Bom
Número de amostras espaciais	Alto	Alto	Baixo

Tabela 6.1: Comparação simplificada do desempenho dos algoritmos de extração abordados nesse trabalho.

6.1

Trabalhos futuros

Como continuação ao trabalho aqui apresentado, são sugeridas as seguintes investigações futuras:

- Analisar os resultados dos distintos algoritmos de extração para conjuntos de dados de entrada com componentes de ruído sobrepostas para diferentes valores de relação sinal-ruído (SNR);
- Uso de dados experimentais de poço multicamada e placa de alumínio como entrada para os algoritmos, e investigação de possíveis mudanças necessárias nos algoritmos para esses conjuntos de dados;
- Averiguação de uma outra forma de Threshold (77) usada no algoritmo 2-D FT morfológico, de forma a reduzir o tempo de processamento associado;
- Investigar uma outra forma de pré-processamento da imagem f-k fornecida pela 2-D FT de forma a evitar as ondulações observadas nas curvas extraídas pelos algoritmos baseados em imagem para os conjuntos de dados de poço multicamada;
- Comparação da transformada *slant* f-k (SFK), proposta por Serdyukov et al. (44), com os algoritmos abordados nesse trabalho para estimativa das curvas de dispersão.

Referências bibliográficas

- 1 CHEEKE, J. D. N. **Fundamentals and applications of ultrasonic waves**. CRC Press, 2012.
- 2 GRAFF, K. F. **Wave motion in elastic solids**. Dover, 1991.
- 3 ROSE, J. L. **Ultrasonic waves in solid media**. Cambridge University Press, 1999.
- 4 ROSE, J. L. **Ultrasonic guided waves in solid media**. Cambridge University Press, 2014.
- 5 KRAUTKRAMER, J.; KRAUTKRAMER, H.; GRABENDORFER, W. **Ultrasonic testing of materials**. Springer-Verlag, 1990.
- 6 MACE, B. R.; MANCONI, E. Wave motion and dispersion phenomena: Veering, locking and strong coupling effects. **The Journal of the Acoustical Society of America**, v. 131, n. 2, p. 1015–1028, 2012.
- 7 GROTH, E. B.; ITURRIOZ, I.; CLARKE, T. G. R. The dispersion curve applied in guided wave propagation in prismatic rods. **Latin American Journal of Solids and Structures**, v. 15, n. 6, 2018.
- 8 DEÁN, J. L.; TRILLO, C.; DOVAL, A. F.; FERNÁNDEZ, J. L. Determination of thickness and elastic constants of aluminum plates from full-field wavelength measurements of single-mode narrowband lamb waves. **The Journal of the Acoustical Society of America**, v. 124, n. 3, p. 1477–1489, 2008.
- 9 BAR-COHEN, Y.; LIH, S.-S.; MAL, A. K. Nde of composites using leaky lamb waves (llw). **Nondestructive Testing and Evaluation**, v. 17, n. 2, p. 91–119, 2001.
- 10 STASZEWSKI, W. J.; BOLLER, C.; TOMLINSON, G. R. **Health monitoring of aerospace structures: smart sensor technologies and signal processing**. John Wiley & Sons, 2004.
- 11 VIGGEN, E. M.; JOHANSEN, T. F.; MERCIU, I.-A. Analysis of outer-casing echoes in simulations of ultrasonic pulse-echo through-tubing logging. **Geophysics**, v. 81, n. 6, 2016.
- 12 OSTACHOWICZ, W.; OSTACHOWICZ, W.; OSTACHOWICZ, W. **Guided waves in structures for SHM: the time-domain spectral element method**. Wiley, 2012.
- 13 CHEN, H.-P.; NI, Y.-Q. **Structural health monitoring of large civil engineering structures**. John Wiley & Sons, 2018.
- 14 ZEROUG, S.; BOSE, S.; SINHA, B.; SKATARIC, M.; LIU, Y.; DANGELO, R. Sonic and ultrasonic measurement applications for cased oil wells. **Insight - Non-Destructive Testing and Condition Monitoring**, v. 58, n. 8, p. 423–430, 2016.

- 15 BOMMER, P. **A primer of oilwell drilling: a basic text of oil and gas drilling**. The University of Texas at Austin. Div. of Continuing Education. Petroleum Extension Service, 2008.
- 16 PATTILLO, P. D. **Elements of oil and gas well tubular design**. Gulf Professional Publishing, 2018.
- 17 VRÅLSTAD, T.; SAASEN, A.; FJÆR, E.; ØIA, T.; YTREHUS, J. D.; KHALIFEH, M. Plug & abandonment of offshore wells: Ensuring long-term well integrity and cost-efficiency. **Journal of Petroleum Science and Engineering**, v. 173, p. 478–491, 2019.
- 18 ØSTERBØ, K. **Cement Bond Evaluation**. Dissertação (Mestrado), 2014.
- 19 PILKINGTON, P. E. Cement evaluation - past, present, and future. **Journal of Petroleum Technology**, v. 44, n. 02, p. 132–140, 1992.
- 20 TIXIER, M.; ALGER, R.; DOH, C. Sonic logging. **Transactions of the AIME**, v. 216, n. 01, p. 106–114, 1959.
- 21 PAULA, J. L. D.; RODRIGUES, V. F.; VICENTE, R. Cement sheath evaluation in nonconventional environment—case history. **All Days**, 2007.
- 22 **Ultrasonic Cement Bond Evaluation**, All Days de **SPWLA Annual Logging Symposium**, (SPWLA Annual Logging Symposium, All Days). SPWLA-1982-N.
- 23 BRAGA, A.; RIVAS A., C. E. High-frequency response of isotropic-laminated cylindrical shells modeled by a layer-wise theory. **International Journal of Solids and Structures**, v. 42, n. 14, p. 4278–4294, 2005.
- 24 IZUHARA, W.; YAMAMOTO, H.; BLYTH, M.; SAENZ, E. Full-range quantitative cement bond evaluation with lwd sonic: The right way of approach using a hybrid of amplitude and attenuation. **Day 3 Wed, October 11, 2017**, 2017.
- 25 WILCOX, P. D.; DALTON, R.; LOWE, M.; CAWLEY, P. Mode and transducer selection for long range lamb wave inspection. **Key Engineering Materials**, v. 167-168, p. 152–161, 1999.
- 26 LIU, Y.; D'ANGELO, R. M.; SINHA, B. K.; ZEROUG, S. Acoustic guided waves in cylindrical solid-fluid structures: Modeling with a sweeping frequency finite element method and experimental validation. **AIP Conference Proceedings**, v. 1806, n. 1, p. 030004, 2017.
- 27 **Case Studies In Evaluation of Cement With Wireline Logs In a Deep Water Environment**, All Days de **SPWLA Annual Logging Symposium**, (SPWLA Annual Logging Symposium, All Days).
- 28 HORA, P.; CERVENÁ, O. Determination of lamb wave dispersion curves by means of fourier transform. **Applied and Computational Mechanics**, v. 6, 2012.
- 29 ALLEYNE, D.; CAWLEY, P. A two-dimensional fourier transform method for the measurement of propagating multimode signals. **The Journal of the Acoustical Society of America**, v. 89, n. 3, p. 1159–1168, 1991.

- 30 LAMB, H. S. On waves in an elastic plate. **Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 93, p. 114–128, 1917.
- 31 XU, K.; MINONZIO, J.-G.; TA, D.; HU, B.; WANG, W.; LAUGIER, P. Sparse svd method for high-resolution extraction of the dispersion curves of ultrasonic guided waves. **IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control**, v. 63, n. 10, p. 1514–1524, 2016.
- 32 GOLUB, G. H.; F., V. L. C. **Matrix computations**. Johns Hopkins Univ Press, 2013.
- 33 OPPENHEIM, A. V.; WILLSKY, A. S.; NAWAB, S. H. **Signals & systems**. Pearson, 2015.
- 34 KULESH, M.; HOLSCHNEIDER, M.; OHRNBERGER, M.; LÜCK, E. Modeling of wave dispersion using continuous wavelet transforms ii: Wavelet-based frequency-velocity analysis. **Pure and Applied Geophysics**, v. 165, n. 2, p. 255–270, 2008.
- 35 MALLAT, S. G. **A wavelet tour of signal processing**. Acad. Press, 2006.
- 36 HOLSCHNEIDER, M.; DIALLO, M. S.; KULESH, M.; OHRNBERGER, M.; LÜCK, E.; SCHERBAUM, F. Characterization of dispersive surface waves using continuous wavelet transforms. **Geophysical Journal International**, v. 163, n. 2, p. 463–478, 2005.
- 37 XU, K.; TA, D.; WANG, W. Multiridge-based analysis for separating individual modes from multimodal guided wave signals in long bones. **IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control**, v. 57, n. 11, p. 2480–2490, 2010.
- 38 CARMONA, R.; HWANG, W.; TORRESANI, B. Multiridge detection and time-frequency reconstruction. **IEEE Transactions on Signal Processing**, v. 47, n. 2, p. 480–492, 1999.
- 39 NIETHAMMER, M.; JACOBS, L. J.; QU, J.; JARZYNSKI, J. Time-frequency representations of lamb waves. **The Journal of the Acoustical Society of America**, v. 109, n. 5, p. 1841–1847, 2001.
- 40 ASKARI, R.; FERGUSON, R. J. Dispersion and the dissipative characteristics of surface waves in the generalized s-transform domain. **Geophysics**, v. 77, n. 1, 2012.
- 41 PINNEGAR, C. R.; MANSINHA, L. The bi-gaussian s-transform. **SIAM Journal on Scientific Computing**, v. 24, n. 5, p. 1678–1692, 2003.
- 42 ASKARI, R.; HEJAZI, S. H. Estimation of surface-wave group velocity using slant stack in the generalized s-transform domain. **Geophysics**, v. 80, n. 4, 2015.
- 43 YILMAZ, O.; DOHERTY, S. M.; YILMAZ, O. **Seismic data analysis: processing, inversion, and interpretation of seismic data**. Society of Exploration Geophysicists, 2001.

- 44 SERDYUKOV, A. S.; YABLOKOV, A. V.; DUCHKOV, A. A.; AZAROV, A. A.; BARANOV, V. D. Slant f-k transform of multichannel seismic surface wave data. **Geophysics**, v. 84, n. 1, 2019.
- 45 WU, L.; CASTAGNA, J. S-transform and fourier transform frequency spectra of broadband seismic signals. **Geophysics**, v. 82, n. 5, 2017.
- 46 LANG, S. W.; KURKJIAN, A. L.; MCCLELLAN, J. H.; MORRIS, C. F.; PARKS, T. W. Estimating slowness dispersion from arrays of sonic logging waveforms. **Geophysics**, v. 52, n. 4, p. 530–544, 1987.
- 47 LOBOS, T.; REZINER, J.; SCHEGNER, P. Parameter estimation of distorted signals using prony method. **2003 IEEE Bologna Power Tech Conference Proceedings**,, 2003.
- 48 TUFTS, D.; KUMARESAN, R. Estimation of frequencies of multiple sinusoids: Making linear prediction perform like maximum likelihood. **Proceedings of the IEEE**, v. 70, n. 9, p. 975–989, 1982.
- 49 EKSTROM, M. Dispersion estimation from borehole acoustic arrays using a modified matrix pencil algorithm. **Conference Record of The Twenty-Ninth Asilomar Conference on Signals, Systems and Computers**, 1995.
- 50 HUA, Y.; SARKAR, T. Matrix pencil method for estimating parameters of exponentially damped/undamped sinusoids in noise. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 38, n. 5, p. 814–824, 1990.
- 51 STEGER, C. An unbiased detector of curvilinear structures. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 20, n. 2, p. 113–125, 1998.
- 52 AULD, B. A. **Acoustic fields and waves in solids**. Wiley, 1990.
- 53 RAYLEIGH, J. W. S. **The theory of sound**. Dover Publ., 1969.
- 54 KINSLER, L. E.; FREY, A. R.; COPPENS, A. B.; SANDERS, J. V. **Fundamentals of acoustics**. 4. ed. John Wiley & Sons, 2000.
- 55 CHILLARA, V. K.; REN, B.; LISSENDEN, C. J. Guided wave mode selection for inhomogeneous elastic waveguides using frequency domain finite element approach. **Ultrasonics**, v. 67, p. 199–211, 2016.
- 56 CLOUTIER, T. J. An experimental study of ultrasonic beam reflection from fluid-loaded cylindrical shells. 1998.
- 57 MIKLOWITZ, J. **The Theory of Elastic Waves and Waveguides**. Elsevier Science, 2012.
- 58 LIU, Y.; DANGELO, R. M.; SINHA, B. K.; ZEROUG, S. Theoretical and experimental investigations of acoustic waves in embedded fluid-solid multi-string structures. **Applied Physics Letters**, v. 110, n. 10, p. 101906, 2017.
- 59 LAMB, H. On the flexure of an elastic plate. **Proceedings of the London Mathematical Society**, s1-21, n. 1, p. 70–91, 1889.

- 60 RAYLEIGH, L. On the free vibrations of an infinite plate of homogeneous isotropic elastic matter. **Proceedings of the London Mathematical Society**, s1-20, n. 1, p. 225–237, 1888.
- 61 SU, Z.; YE, L. Fundamentals and analysis of lamb waves. **Identification of Damage Using Lamb Waves Lecture Notes in Applied and Computational Mechanics**, p. 15–58, 2009.
- 62 KENNETT, B. L. N. Slowness techniques in seismic interpretation. **Journal of Geophysical Research**, v. 86, n. B12, p. 11575, 1981.
- 63 BROWN, L. T. Comparison of shear-wave slowness profiles at 10 strong-motion sites from noninvasive sasw measurements and measurements made in boreholes. **Bulletin of the Seismological Society of America**, v. 92, n. 8, p. 3116–3133, 2002.
- 64 TRAYLOR, T. K.; BURNLEY, P. C.; WHITAKER, M. L. Initial acoustoelastic measurements in olivine: Investigating the effect of stress on p - and s -wave velocities. **Journal of Geophysical Research: Solid Earth**, v. 126, n. 11, 2021.
- 65 MISHAKIN, V. V.; DIXON, S.; POTTER, M. D. G. The use of wide band ultrasonic signals to estimate the stress condition of materials. **Journal of Physics D: Applied Physics**, v. 39, n. 21, p. 4681–4687, 2006.
- 66 HOLGUIN, C. D. V.; AYALA, H. V. H.; KUBRUSLY, A. C. Improved stress estimation with machine learning and ultrasonic guided waves. **Experimental Mechanics**, 2021.
- 67 SCALEA, F. L. D.; RIZZO, P.; SEIBLE, F. Stress measurement and defect detection in steel strands by guided stress waves. **Journal of Materials in Civil Engineering**, v. 15, n. 3, p. 219–227, 2003.
- 68 HUGHES, J. M.; VIDLER, J.; NG, C.-T.; KHANNA, A.; MOHABUTH, M.; ROSE, L. F.; KOTOUSOV, A. Comparative evaluation of in situ stress monitoring with rayleigh waves. **Structural Health Monitoring**, v. 18, n. 1, p. 205–215, 2018.
- 69 KUBRUSLY, A. C.; BRAGA, A. M. B.; WEID, J. P. von der. Derivation of acoustoelastic lamb wave dispersion curves in anisotropic plates at the initial and natural frames of reference. **The Journal of the Acoustical Society of America**, v. 140, n. 4, p. 2412–2417, 2016.
- 70 RHEINFURTH, M.; KOSMANN, N.; SAUER, D.; BUSSE, G.; SCHULTE, K. Lamb waves for non-contact fatigue state evaluation of composites under various mechanical loading conditions. **Composites Part A: Applied Science and Manufacturing**, v. 43, n. 8, p. 1203–1211, 2012.
- 71 DINIZ, P. S. R.; B., D. S. E. A.; NETTO, S. L. **Digital signal processing: system analysis and design**. Cambridge University Press, 2002.
- 72 MITRA, S. K. **Digital signal processing: a computer-based approach**. McGraw-Hill, 2011.

- 73 LIM, J. S. **Two-dimensional signal and image processing**. Prentice- Hall, 1990.
- 74 OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-time signal processing**. Prentice Hall, 2010.
- 75 SERRA, J. **Image analysis and mathematical morphology**. Academic, 1993.
- 76 UMBAUGH, S. E. **Digital image processing and analysis: with MATLAB and CVIPtools**. CRC Press, 2018.
- 77 OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62–66, 1979.
- 78 GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. Pearson, 2018.
- 79 GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital Image Processing Using MATLAB**. Pearson, 2003.
- 80 SHAO, M.; WEI, Z.; HU, M.; ZHANG, G. Correction method for line extraction in vision measurement. **PLOS ONE**, v. 10, n. 5, 2015.
- 81 STEGER, C. Extraction of curved lines from images. **Proceedings of 13th International Conference on Pattern Recognition**, 1996.
- 82 LINDBERG, T. **Scale-space theory in Computer Vision**. Kluwer Academic Publishers, 1994.
- 83 STRANG, G. **Linear Algebra and Its Applications**. 4. ed. Cengage Learning, 2006. ISBN 9780030105678.
- 84 SHIH, F. Y. **Image processing and mathematical morphology: fundamentals and applications**. CRC Press, 2017.
- 85 SCIKIT Image Module: Data. Acessado em 19 de Dezembro 2021. Disponível em: <<https://scikit-image.org/docs/stable/api/skimage.data.html>>.
- 86 AL-HOMIDAN, S. Hankel matrix transforms and operators. **Journal of Inequalities and Applications**, v. 2012, n. 1, 2012.
- 87 HORN, R. A.; JOHNSON, C. R. **Matrix analysis**. Cambridge University Press, 2017.
- 88 HUA, Y.; SARKAR, T. Matrix pencil method for estimating parameters of exponentially damped/undamped sinusoids in noise. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 38, n. 5, p. 814–824, 1990.
- 89 BEN-ISRAEL ADI; GREVILLE, T. N. E. **Generalized Inverses: Theory and Applications**. Springer London, Limited, 2003.
- 90 LARSON, R.; EDWARDS, B. H. **Essential calculus: Early Transcendental Functions**. Cengage, 2018.

- 91 DUFF, I. S.; KOSTER, J. On algorithms for permuting large entries to the diagonal of a sparse matrix. **SIAM Journal on Matrix Analysis and Applications**, v. 22, n. 4, p. 973–996, 2001.
- 92 GELLERT, W.; GOTTWALD, S.; HELLWICH, M. **VNR Concise Encyclopedia of Mathematics**. Springer Netherlands, 2012.
- 93 CASTAINGS, M.; BACON, C.; HOSTEN, B.; PREDOI, M. V. Finite element predictions for the dynamic response of thermo-viscoelastic material structures. **The Journal of the Acoustical Society of America**, v. 115, n. 3, p. 1125–1133, 2004.
- 94 ROSE, J. L. A baseline and vision of ultrasonic guided wave inspection potential. **Journal of Pressure Vessel Technology**, v. 124, n. 3, p. 273–282, 2002.
- 95 ANSYS® INC. **ANSYS Mechanical APDL Element Reference**. 2011.
- 96 SHEN, Y.; GIURGIUTIU, V. Effective non-reflective boundary for lamb waves: Theory, finite element implementation, and applications. **Wave Motion**, v. 58, p. 22–41, 2015.
- 97 MASSEY, B. S.; WARD-SMITH, A. J. **Mechanics of fluids**. CRC Press, 2018.
- 98 VIGGEN, E. M.; JOHANSEN, T. F.; MERCIU, I.-A. Simulation and modeling of ultrasonic pitch-catch through-tubing logging. **Geophysics**, v. 81, n. 4, 2016.
- 99 WANG, T.; YANG, Z.; WU, W.-C.; GREAR, M. A sensitivity analysis of the wind forcing effect on the accuracy of large-wave hindcasting. **Journal of Marine Science and Engineering**, v. 6, n. 4, p. 139, 2018.