



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECÂNICA

VICTOR OLIVEIRA SANTOS

SIMULAÇÃO DE PROPAGAÇÃO DE ONDAS ULTRASSÔNICAS SOB DIFERENTES
REGIMES DE ESPALHAMENTO

FORTALEZA

2018

VICTOR OLIVEIRA SANTOS

SIMULAÇÃO DE PROPAGAÇÃO DE ONDAS ULTRASSÔNICAS SOB DIFERENTES
REGIMES DE ESPALHAMENTO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Mecânica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Engenheiro Mecânico.

Orientador: Prof. Elineudo Pinho de Moura;
D.Sc.

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S239s Santos, Victor Oliveira.
Simulação de propagação de ondas ultrassônicas sob diferentes regimes de espalhamento / Victor Oliveira Santos. – 2018.
61 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Mecânica, Fortaleza, 2018.
Orientação: Prof. Dr. Elineudo Pinho de Moura.
1. Ultrassom. 2. Regimes de espalhamento. 3. Simulação. 4. Método dos volumes finitos. 5. Reconhecimento de padrões. I. Título.

CDD 620.1

VICTOR OLIVEIRA SANTOS

SIMULAÇÃO DE PROPAGAÇÃO DE ONDAS ULTRASSÔNICAS SOB DIFERENTES
REGIMES DE ESPALHAMENTO

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Mecânica
do Centro de Tecnologia da Universidade
Federal do Ceará, como requisito parcial à
obtenção do título de Engenheiro Mecânico.

Aprovada em:

BANCA EXAMINADORA

Prof. Elineudo Pinho de Moura; D.Sc. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Paulo Alexandre Costa Rocha; D.Sc.
Universidade Federal do Ceará (UFC)

Raphaella Hermont Fonseca Murta; M.Sc.
Universidade Federal do Ceará (UFC)

A minha família, amigos e colegas. A todos aqueles a quem este trabalho possa, de alguma forma, ajudar.

AGRADECIMENTOS

Aos meus pais, Maria do Carmo Oliveira Santos e Francisco de Assis dos Santos, por sempre fomentarem minha educação e me apoiarem sempre quando precisei.

Ao meu orientador, Professor Dr. Elineudo Pinho de Moura, por ter proporcionado a oportunidade de integrar o Centro de Ensaios Não Destrutivos (CENDE). Obrigado, também, pela orientação proporcionada, pois sem ela este trabalho não seria possível.

Aos meus amigos de escola, da mecânica e da metalúrgica por me acompanharem ao longo dessa jornada, sendo uma importante válvula de escape nos momentos mais estressantes. Israel, Leandro, Pedro e Thales, obrigado pelos dias no banco.

Aos meus colegas do CENDE, atuais e egressos: Raphaella, Flávison, Pedro, Aldécira e Fabrício. O apoio e a ajuda de todos vocês durante esse tempo de convivência foi muito importante para mim e para a elaboração deste trabalho.

A todos os professores e professoras que me guiaram ao longo desses anos de curso. O ensinamento proporcionado pelos senhores docentes foi imprescindível à minha formação acadêmica.

A Amanda. Obrigado por ser uma pessoa tão especial, estando presente ao meu lado durante esses anos.

A todos, muito obrigado.

“’Tis but a scratch!”

(John Cleese; Monty Python em Busca do
Cálice Sagrado, 1975)

RESUMO

O ensaio não destrutivo por ultrassom é amplamente utilizado na identificação e dimensionamento de descontinuidades, na caracterização de materiais, na determinação de tamanho de grão e de níveis de degradação microestrutural. Meios heterogêneos provocam espalhamento da onda ultrassônica devido a mudanças de impedâncias acústicas durante a propagação. O regime de espalhamento depende da relação entre tamanho das partículas do meio e do comprimento de onda. Assim, ondas propagando em materiais com tamanhos de grãos distintos apresentem diferentes regimes de espalhamento. Diferentes meios heterogêneos bidimensionais foram obtidos a partir da simulação do crescimento de grão através do modelo de Potts e utilizados na simulação de propagação da onda ultrassônica, que foi desenvolvida através do método dos volumes finitos. Os dados obtidos pela simulação da propagação da onda ultrassônica foram submetidos ao pré-processamento de *detrended fluctuation analysis* (DFA). Após o pré-processamento, algoritmos da Transformada Karhunen-Loève (juntamente com o algoritmo da regra da média da classe mais próxima) e Redes Neurais Artificiais foram usados na classificação dos regimes de espalhamento, obtendo respectivamente, taxas de acertos de 97,50% e 95,16%. Tais taxas médias de acerto indicam sucesso na simulação da propagação da onda ultrassônica em diferentes meios heterogêneos.

Palavras-chave: Ultrassom. Regimes de espalhamento. Simulação. Método dos volumes finitos. Crescimento de grão. Modelo de Potts. Reconhecimento de padrões.

ABSTRACT

The ultrasonic non-destructive evaluation is vastly used to identify and measure discontinuities, to characterize material, to measure grain's size and microstructural degradation present in the material. Heterogen medium cause ultrasonic wave scattering during its propagation due the constant change of the acoustic impedance inside the medium. The type of scatter acting during the wave's propagation relies on the relation between the mean grain size composing the medium and the ultrasonic wave lenght. Therefore, waves propagating inside materials containing differents grains sizes, will be under differents scatterings. Differents bidimensional heterogen media were acquired from simulation of grain growth by the Potts model and then used in the simulation of the ultrasonic wave propagation, which was developed according to the finite volume method. The data obtained from the ultrasonic wave propagation were submitted to the detrended fluctuation analysis preprocessing. After this preprocessing, Karhunen-Loève (along with the nearest mean class rule algorithm) and neural networks algorithms were used to classify the scattering of the wave in each modeled media, reaching respectively, 97,50% and 95,16% of mean hit ratios. Such numbers show that the simulation of the ultrasonic wave propagation in different heterogen media was successful.

Keywords: Ultrasound. Simulation. Finit volume methohd. Wave scattering. Grain growth. Potts model. Pattern recognition.

LISTA DE FIGURAS

Figura 1 – Esquematização para o teste ultrassônico por pulso eco	14
Figura 2 – Esquematização para o movimento de ondas transversais	15
Figura 3 – Esquematização para o movimento de ondas longitudinais	15
Figura 4 – Condições de contorno usadas	23
Figura 5 – Malha bidimensional utilizada para obtenção das equações discretizadas . .	25
Figura 6 – Reflexão da onda para meios com diferentes impedâncias	31
Figura 7 – Regimes de espalhamento em função do tamanho de grão	33
Figura 8 – Exemplo de matriz com orientações de grãos	34
Figura 9 – Crescimento de grão	35
Figura 10 – Anatomia de um neurônio biológico	40
Figura 11 – Esquematização de um neurônio artificial	41
Figura 12 – Esquematização de uma rede MLP, onde cada círculo representa um neurônio artificial	43
Figura 13 – Representação esquemática do transdutor simulado	45
Figura 14 – Comparação entre malhas	48
Figura 15 – Comparação entre malhas	48
Figura 16 – Resultados obtidos através da simulação do crescimento de grãos	52
Figura 17 – Resultado do sinal obtido para a simulação de propagação da onda ultrassônica	53
Figura 18 – Gráfico obtido pela análise DFA para os dados	54
Figura 19 – Representação gráfica do agrupamento de sinais ultrassônicos feito pela transformada KL	55
Figura 20 – Representação gráfica do agrupamento de sinais ultrassônicos feito pela transformada KL	55

LISTA DE TABELAS

Tabela 1 – Notação de Voigt para matrizes simétricas	20
Tabela 2 – Comparação dos erros médios quadráticos para as malhas analisadas	49
Tabela 3 – Regime de espalhamento em função do tamanho médio de grão	51
Tabela 4 – Valores de densidades atribuídos para cada orientação de grão simulado	52
Tabela 5 – Matriz de confusão média para os dados de treino obtida pela classificação com KLT	56
Tabela 6 – Matriz de confusão média para os dados de teste obtida pela classificação com KLT	56
Tabela 7 – Matriz de confusão média para os dados de treino obtida pela classificação com redes neurais	57
Tabela 8 – Matriz de confusão média para os dados de teste obtida pela classificação com redes neurais	58

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	14
2.1	Ensaio não destrutivo por ultrassom	14
2.2	Ondas mecânicas	14
2.3	Métodos numéricos	16
2.4	Equação do movimento	16
2.4.1	<i>Termo da força superficial</i>	18
2.4.2	<i>O termo fonte</i>	22
2.5	Condições de contorno	22
2.5.1	<i>Superfície livre</i>	23
2.5.2	<i>Bordas não reflexivas</i>	24
2.5.3	<i>Camadas de amortecimento</i>	24
2.5.4	<i>Deslocamento nulo</i>	25
2.6	Equações discretizadas	25
2.6.1	<i>Volume interno do modelo</i>	28
2.7	Impedância	30
2.8	Regime de espalhamento da onda	32
2.8.0.1	<i>Espalhamento de Rayleigh</i>	32
2.8.0.2	<i>Regime de espalhamento estocástico</i>	32
2.8.0.3	<i>Regime de espalhamento geométrico</i>	33
2.9	Crescimento de grão	33
2.10	Detrended-Fluctuation Analysis (DFA)	36
2.11	Algoritmos de Reconhecimento de Padrões	37
2.11.1	<i>Transformada de Karhunen-Loève</i>	38
2.11.1.1	<i>Regra da média da classe mais próxima</i>	39
2.11.2	<i>Redes neurais artificiais</i>	39
2.11.2.1	<i>Neurônio artificial</i>	40
2.11.2.2	<i>Funções de ativação</i>	42
2.11.2.3	<i>Perceptron de multicamadas</i>	42
3	METODOLOGIA	45

3.1	Parâmetros do modelo	45
3.2	Parâmetros do transdutor	45
3.2.1	<i>Quantidade de cristais</i>	46
3.2.2	<i>Distância entre cristais</i>	46
3.2.3	<i>Tamanho do cristal</i>	46
3.2.4	<i>Delay</i>	46
3.3	Avanço temporal na simulação numérica	47
3.4	Estudo do refino de malha	47
3.5	Simulação do crescimento de grão pelo modelo de Potts	49
3.6	Algoritmos de reconhecimento de padrões	49
3.6.1	<i>Transformada de Karhunen-Loève</i>	49
3.6.2	<i>Redes neurais artificiais</i>	50
4	RESULTADOS	51
4.1	Resultados da simulação do crescimento de grão	51
4.1.1	<i>Determinação do tamanho médio do grão</i>	51
4.1.2	<i>Atribuição da densidade aos grãos simulados</i>	51
4.1.3	<i>Visualização dos resultados do crescimento de grão</i>	52
4.2	Resultados da simulação da propagação da onda ultrassônica	53
4.3	Resultados da análise de flutuação sem tendência	54
4.4	Resultados do agrupamento e classificação pelo algoritmo da transformada de Karhunen-Loève	55
4.5	Resultados da classificação pelo algoritmo de redes neurais	57
5	CONCLUSÃO	59
	REFERÊNCIAS	60

1 INTRODUÇÃO

Ensaaios não destrutivos são técnicas utilizadas para inspeção de materiais sem que haja alteração de suas propriedades físicas, químicas, mecânicas ou dimensionais e sem comprometer seu uso posterior. O presente trabalho estudou o ensaio ultrassônico, mais especificamente o tipo pulso-eco. O teste ultrassônico é um ensaio não destrutivo amplamente utilizado em vários setores da indústria. Este teste consiste no emprego ondas mecânicas de alta frequência para realizar a inspeção, podendo ser utilizado na identificação e dimensionamento de descontinuidades, na caracterização de materiais, na determinação de tamanho de grão e de níveis de degradação microestrutural.

A análise dos resultados produzidos durante um ensaio por ultrassom requer um profissional altamente qualificado e, considerando o grande volume de dados a ser analisado, muito tempo. Essa tarefa pode ser realizada por técnicas de processamento de sinais e algoritmos de reconhecimento de padrões, que possuem capacidade de análise de grandes quantidades de dados em tempo reduzido. Tais algoritmos podem ser ensinados a reconhecer padrões a partir de exemplos conhecidos e, posteriormente, utilizados para classificar dados desconhecidos. O treinamento desses algoritmos requer uma base de dados grande e diversificada, que abrange os casos desejados para análise. Um modo rápido e barato de se obter um banco de dados suficientemente grande é através da simulação computacional do ensaio ultrassônico.

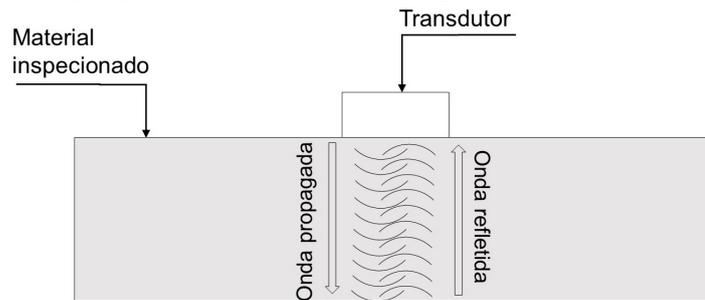
No presente trabalho, a propagação da onda ultrassônica foi simulada utilizando o Método dos Volumes Finitos (MVF). Com o objetivo de avaliar a qualidade da simulação, essa foi executada em meios que provocam diferentes regimes de espalhamento em virtude do tamanho médio de grão modelado computacionalmente. A relação entre o comprimento da onda e o tamanho médio dos grãos presentes no meio por onde ela se propaga determinará qual dos três regimes de espalhamento que essa onda experimentará: espalhamento de Rayleigh, estocástico ou geométrico (SHULL, 2002). Os resultados obtidos foram então submetidos a análise dos algoritmos de reconhecimento de padrão para verificar se, de fato, ocorreu o espalhamento de onda ultrassônica de diferentes formas, como o que é esperado para cada tamanho médio de grão simulado. A presença de diferentes regimes de espalhamento nos dados obtidos pode caracterizar, então, o sucesso da simulação proposta.

2 REVISÃO BIBLIOGRÁFICA

2.1 Ensaio não destrutivo por ultrassom

Ensaaios não destrutivos realizados por ultrassom utilizam-se de ondas de altas frequências, acima de 20.000 Hertz (Hz), para realização da inspeção do material (SHULL, 2002). Esse ensaio baseia-se na emissão de uma onda de alta frequência pelo transdutor de emissão. A onda se propaga, interagindo com a geometria e propriedades mecânicas do material, sendo refletida até retornar ao transdutor de recepção, onde os dados obtidos são observados em um osciloscópio (SHULL, 2002). Para o caso do ensaio utilizando pulso eco, no entanto, há apenas um transdutor que atuará como emissor e receptor da onda gerada. A figura 1 mostra a esquematização do teste ultrassônico por pulso eco.

Figura 1 – Esquemática para o teste ultrassônico por pulso eco



Fonte: o autor

Os resultados obtidos pelos ensaios ultrassônicos podem ser usados na identificação e dimensionamento de descontinuidades, além de poder ser utilizado na caracterização de materiais, determinação de tamanho de grão e nível de degradação microestrutural (HULL; JOHN, 1988). No presente estudo, o ensaio ultrassônico por pulso eco foi modelado computacionalmente para averiguar de forma qualitativa a presença de diferentes meios heterogêneos obtidos através de simulação do crescimento de grão, que será discutido mais adiante.

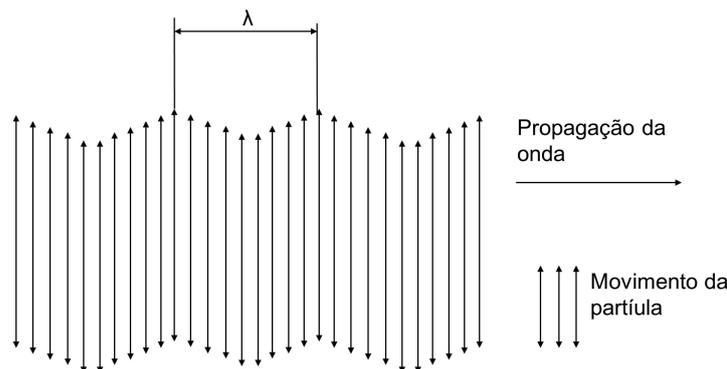
2.2 Ondas mecânicas

Ondas ultrassônicas ondas mecânicas (também conhecidas por ondas elásticas). Essas ondas são causadas em meios que possuem matéria, proporcionando transporte de energia através da movimentação das partículas (SERWAY; JEWETT JR., 2014). Esse tipo de onda é regido pelas leis de Newton (HALLIDAY *et al.*, 2009). Quando há propagação da onda em

meios materiais, as partículas que antes estavam em equilíbrio são perturbadas, fazendo com que tensões internas inerentes ao material atuem para o retorno da posição inicial de equilíbrio (AMERICAN SOCIETY FOR METALS, 1992). A forma como a onda mecânica desloca as partículas do material define o tipo de propagação da onda no meio, que, considerando ondas ultrassônicas, pode ser dividido em ondas transversais e ondas longitudinais (HULL; JOHN, 1988).

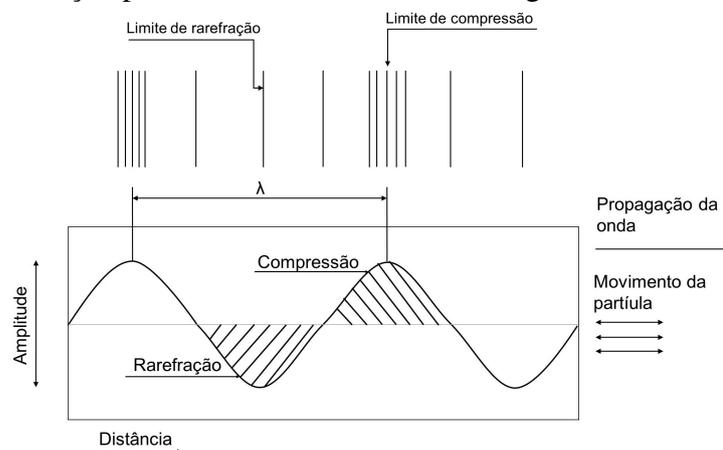
As ondas transversais, ou cisalhantes, possuem partículas cujo movimento se dá de forma perpendicular à propagação da onda, causando uma tensão de cisalhamento associada ao movimento da partícula (HULL; JOHN, 1988). As ondas longitudinais, ou de pressão, são caracterizadas pela movimentação paralela das partículas em relação a onda propagada, ocasionando uma tensão periódica de compressão e rarefação das partículas (HULL; JOHN, 1988). As figuras 2 e 3 mostram, respectivamente, os modos de vibração transversais e longitudinais.

Figura 2 – Esquemática para o movimento de ondas transversais



Fonte: Adaptado de American Society for Metals (1992)

Figura 3 – Esquemática para o movimento de ondas longitudinais



Fonte: Adaptado de American Society for Metals (1992)

A maioria das ondas ultrassônicas pode ser descrita como tendo comportamento harmônico. A velocidade de propagação da onda, então, pode ser dada em função do período, ou frequência, e do comprimento de onda. A equação que descreve essa relação é:

$$v = \lambda f \quad (2.1)$$

Onde v é a velocidade de propagação da onda em m/s , λ é o comprimento da onda em m e f é a frequência em $1/s$.

2.3 Métodos numéricos

Métodos analíticos para solução de problemas lineares ou quase lineares, onde a geometria do problema é relativamente simples, podem ser utilizados para a obtenção de soluções exatas (KOLDITZ, 2002). Entretanto, em casos de equações não lineares e de geometria complexa, onde resultados exatos não são possíveis através do emprego dos métodos analíticos, é necessário então que haja uma aproximação para as soluções. Nesses casos de complexidade sem soluções exatas, o uso dos métodos numéricos torna-se uma opção viável (KOLDITZ, 2002). Dentre os métodos numéricos mais conhecidos, podem ser destacados os métodos de diferenças finitas, método de elementos finitos e o método dos volumes finitos, sendo este último o utilizado no presente trabalho.

O método dos volumes finitos baseia-se na discretização da geometria em volumes de controle conhecidos, onde o fluxo da propriedade a ser analisada que passa dentro de cada volume será conservado através da aplicação das equações de conservação. Essas equações, diferentemente do método das diferenças finitas, não são aproximadas por meio de diferenças infinitesimais, mas sim através da integração das equações discretizadas em cada volume (KOLDITZ, 2002). Esse método impõe a conservação de massa, quantidade de movimento e energia em níveis locais, tornando o fluxo de propriedades em volumes adjacentes prontamente balanceados, significando que o fluxo de entrada no volume será, essencialmente, o mesmo que na saída.

2.4 Equação do movimento

O desenvolvimento da equação de movimento parte da segunda lei de Newton, onde é declarado que todas as forças atuantes em um corpo podem ser expressas pela igualdade massa

× aceleração (ROSE, 2014). Assim:

$$F_{total} = \sum F = ma \quad (2.2)$$

Sendo a aceleração reescrita como:

$$a_i = \frac{\partial^2 u_i}{\partial t^2} \quad (2.3)$$

Onde a é aceleração em m/s^2 , u é o deslocamento em m e t é o tempo em s em um sistema cartesiano. A massa do corpo pode ser reescrita como:

$$m = \rho dx_1 dx_2 dx_3 \quad (2.4)$$

Onde m é a massa do corpo em kg , ρ é a densidade do corpo em kg/m^3 e dx_1 , dx_2 e dx_3 são as dimensões infinitesimais do corpo nas direções x_1 , x_2 e x_3 (análogas as direções x , y e z) respectivamente. Desconsiderando as forças de corpo, o termo $\sum F$ pode ser decomposto em forças externas, F_{ext} e forças superficiais, F_{sup} , ambos em N .

$$F_{ext} = F_f dx_1 dx_2 dx_3 \quad (2.5)$$

$$F_{sup} = \frac{\partial \tau_{ij}}{\partial x_j} dx_1 dx_2 dx_3 \quad (2.6)$$

Onde F_f é uma fonte de força em N/m^3 . O termo $\partial \tau_{ij} / \partial x_j$ é referente as forças superficiais atuantes em meios elásticos em cada dimensão x_j , também em unidade N/m^3 . Reescrevendo a equação 2.2 e simplificando os termos repetidos, tem-se a equação para quantidade de movimento mostrada pela equação 2.7 (ROSE, 2014):

$$\rho \frac{\partial^2 u_i}{\partial t^2} = F_i + \frac{\partial \tau_{ij}}{\partial x_j} \quad (2.7)$$

Nota-se que a equação 2.7 possui os termos representando as forças em unidades de N/m^3 .

2.4.1 Termo da força superficial

Assumindo que o meio de propagação da onda ultrassônica é elástico, é possível aplicar a lei de Hooke, que define a relação entre tensão e deformação. Em materiais elásticos, as componentes de tensão τ_{ij} são linearmente dependentes de cada componente de deformação ε_{kl} (NYE; LINDSAY, 1957) (THOMSEN, 1986). Essa relação entre tensão e deformação pode ser escrita matematicamente como (RYCHLEWSKI, 1984):

$$\tau_{ij} = C_{ijkl}\varepsilon_{kl} \quad (2.8)$$

Sendo τ_{ij} o tensor de tensões, ε_{kl} o tensor de deformação e C_{ijkl} é o módulo elástico inerente ao material que compõe o meio analisado. Os índices subscritos (i, j, k e l) podem assumir valores de 1 a 3 referentes as coordenadas cartesianas.

Para pequenas deformações, o tensor ε_{kl} é definido como (LANDAU; LIFSHITZ, 1970):

$$\varepsilon_{kl} = \frac{1}{2} \left(\frac{\partial u_k}{\partial x_l} + \frac{\partial u_l}{\partial x_k} \right) \quad (2.9)$$

Assumindo um material isotrópico, onde suas propriedades não são variáveis com a direção, nota-se que $\frac{\partial u_k}{\partial x_l} = \frac{\partial u_l}{\partial x_k}$. Logo:

$$\varepsilon_{kl} = \frac{\partial u_k}{\partial x_l} \quad (2.10)$$

Substituindo a equação 2.10 na equação 2.8, o tensor de tensões será:

$$\tau_{ij} = C_{ijkl} \frac{\partial u_k}{\partial x_l} \quad (2.11)$$

Reescrevendo a equação 2.7:

$$\rho \frac{\partial^2 u_i}{\partial t^2} = F_i + \frac{\partial}{\partial x_j} \left(C_{ijkl} \frac{\partial u_k}{\partial x_l} \right) \quad (2.12)$$

O módulo elástico, por sua vez, possui um total de $3 \times 3 \times 3 \times 3$ componentes caracterizando o meio (THOMSEN, 1986). Em materiais isotrópicos, o tensor de tensões possui

simetria($\tau_{ij} = \tau_{ji}$). A simetria indica que há uma relação de independência somente em seis tensões dentre as possíveis descritas na equação 2.8. A simetria do tensor das deformações ($\varepsilon_{kl} = \varepsilon_{lk}$) também indica que somente seis termos à direita da equação 2.8 são independentes. Assim, devido à simetria, Voigt propôs em 1910 uma notação simplificada para a redução da ordem de um tensor, nesse caso o módulo elástico (VOIGT, 1910). Essa notação altera os índices da matriz, reduzindo a ordem de C_{ijkl} de $3 \times 3 \times 3 \times 3$ para 6×6 (THOMSEN, 1986). A matriz do módulo elástico com os termos simétricos é:

$$C_{ijkl} = \begin{bmatrix} C_{1111} & C_{1122} & C_{1133} & C_{1123} & C_{1113} & C_{1112} \\ & C_{2222} & C_{2233} & C_{2223} & C_{2213} & C_{2212} \\ & & C_{3333} & C_{3323} & C_{3313} & C_{3312} \\ & & & C_{2323} & C_{2313} & C_{2312} \\ & & & & C_{1313} & C_{1312} \\ & & & & & C_{1212} \end{bmatrix} \quad (2.13)$$

Aplicando a notação de Voigt, mostrada na tabela 1, ao tensor mostrado em 2.13 obtém-se uma nova notação com índices mn :

$$C_{mn} = \begin{bmatrix} C_{33} & (C_{33} - 2C_{44}) & (C_{33} - 2C_{44}) & & & \\ & C_{33} & (C_{33} - 2C_{44}) & & & \\ & & C_{33} & & & \\ & & & C_{44} & & \\ & & & & C_{44} & \\ & & & & & C_{44} \end{bmatrix} \quad (2.14)$$

A matriz obtida é para um meio isotrópico. Os termos omitidos na parte superior a diagonal principal da equação 2.14 possuem valores nulos (THOMSEN, 1986). É notável também que a equação 2.14 indica igualdade entre componentes de C_{mn} , sendo elas (THOMSEN, 1986):

- $C_{11} = C_{22} = C_{33}$
- $C_{44} = C_{55} = C_{66}$
- $C_{12} = C_{13} = C_{23} = C_{33} - 2C_{44} = \lambda$

Os componentes não nulos de C_{mn} são dados em função dos parâmetros de Lamè (THOMSEN, 1986):

$$C_{11} = \lambda + 2\mu \quad (2.15)$$

$$C_{66} = \mu \quad (2.16)$$

Onde λ e μ são, respectivamente, o primeiro e o segundo parâmetros de Lamè.

O cálculo das componentes de C_{mn} relaciona densidade e velocidade de propagação da onda transversal e longitudinal, como mostrado em Thomsen (1986). Desse modo, C_{33} e C_{44} são reescritos como:

$$C_{11} = \rho v_p^2 \quad (2.17)$$

$$C_{66} = \rho v_s^2 \quad (2.18)$$

Sendo v_p a velocidade de propagação da onda longitudinal e v_s a velocidade da onda transversal. Relacionando as equações 2.15 e 2.16 com 2.17 e 2.18 (além de usar a relação $C_{33} - 2C_{44} = \lambda$), é possível obter as seguintes relações para λ e μ :

$$\lambda = \rho(v_p^2 - 2v_s^2) = C_{12} \quad (2.19)$$

$$\mu = \rho v_s^2 \quad (2.20)$$

Tabela 1 – Notação de Voigt para matrizes simétricas

Índice ij ou kl	
Notação antiga	Notação de Voigt
11	1
22	2
33	3
32 = 23	4
31 = 13	5
12 = 21	6

2.4.2 O termo fonte

Os termos de fonte ultrassônica por unidade de volume, F_1 e F_2 , são as fontes atuantes em x_1 e x_2 respectivamente. Elas são definidas de modo geral, como:

$$F_1 = \frac{F \cos \theta}{V} \quad (2.25)$$

$$F_2 = \frac{F \sen \theta}{V} \quad (2.26)$$

Onde θ representa a angulação de incidência da onda ultrassônica no meio e V o volume do meio analisado. Para o caso específico de fonte ultrassônica utilizada em um teste não destrutivo de pulso eco, a onda incide de modo normal à superfície do meio, sendo então $\theta = \pi/2$. Para esse valor, a componente do eixo x_1 do termo da fonte será nulo, restando apenas a componente do eixo x_2 .

O valor de F é calculado em função do tempo, da frequência da onda e do número de ciclos. Esse termo representa a propagação da onda ultrassônica no material, onde um pulso inicial é usado para excitar a superfície do material dando início, assim, a onda ultrassônica. A modelagem numérica do termo fonte pode ser descrita analiticamente como encontrado em Lord *et al.* (1990) e Ludwig e Lord (1986):

$$F(t) = \begin{cases} [1 - \cos(\frac{2\pi ft}{N_c})] \cos(2\pi ft), & 0 \leq t \leq \frac{N_c}{f} \\ 0, & \text{caso contrário} \end{cases} \quad (2.27)$$

Onde f representa a frequência da onda, que nesse caso possui valor de 5MHz ; t é o tempo de propagação da onda em segundos; e N_c é o número de ciclos, sendo este igual a 3. A equação 2.27 após integração no intervalo de $0 \leq t \leq \frac{N_c}{f}$ é, então (MURTA, 2018):

$$F_{integrada} = \int_0^t F(t) = \frac{\sen(2\pi f)}{2\pi f} - \frac{N_c \sen[2\pi ft(1 + \frac{1}{N_c})]}{4\pi f(N_c + 1)} - \frac{N_c \sen[2\pi ft(1 - \frac{1}{N_c})]}{4\pi f(N_c - 1)} \quad (2.28)$$

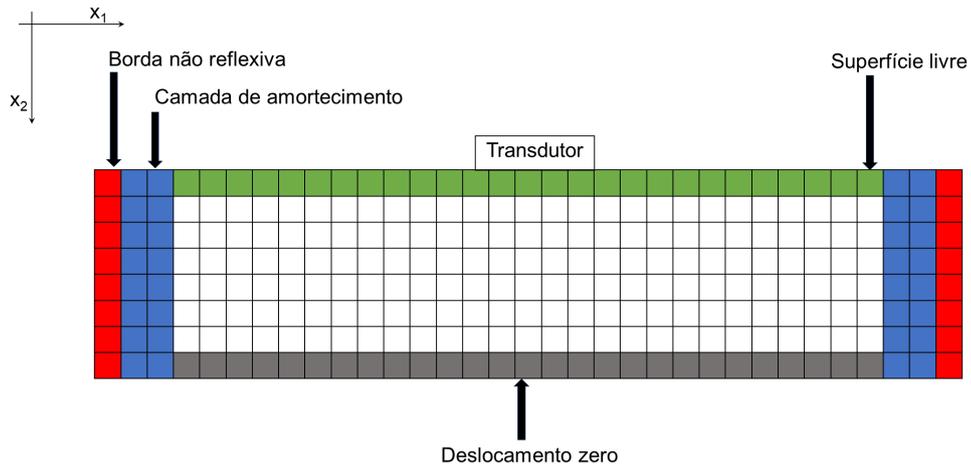
2.5 Condições de contorno

As condições de contorno são limitações impostas ao modelo matemático para que a simulação aconteça dentro do meio de interesse modelado de maneira mais verossímil possível,

além de reduzir os esforços computacionais exercidos durante a simulação (MURTA, 2018). Essas condições são aplicadas nas extremidades do meio modelado, onde a onda simulada irá interagir de modo diferente durante sua propagação.

As condições de contorno usadas são mostradas na figura 4.

Figura 4 – Condições de contorno usadas



Fonte: Adaptado de Camurça (2014)

2.5.1 Superfície livre

A condição de superfície livre é aplicada na camada superior do modelo. Essa condição visa garantir que as componentes de tensão normais e tangenciais à superfície sejam nulas durante a propagação da onda, segundo Landau e Lifshitz (1970), conseqüentemente tornam as deformações também nulas. As equações que modelam essa condição são:

$$\frac{\partial u_1}{\partial x_2} + \frac{\partial u_2}{\partial x_1} = 0 \quad (2.29)$$

$$v_p^2 \frac{\partial u_2}{\partial x_2} + (v_p^2 - 2v_s^2) \frac{\partial u_1}{\partial x_1} = 0 \quad (2.30)$$

Substituindo as relações presentes nas equações 2.15 e 2.19 na equação 2.30:

$$C_{11} \frac{\partial u_2}{\partial x_2} + C_{12} \frac{\partial u_1}{\partial x_1} = 0 \quad (2.31)$$

2.5.2 Bordas não reflexivas

Para evitar que a propagação da onda simulada seja refletida nas bordas laterais do meio modelado, fazendo com que retornem ao receptor, a condição de borda não reflexiva se faz necessária (CAMURÇA, 2014). A reflexão ocorre devido à diferença de impedância entre o metal e o ar nessa região (CATUNDA, 2004). A condição de contorno para esse caso foi proposta por Reynolds (1978), e visa tornar as bordas laterais suficientemente distantes da fonte ultrassônica de tal forma que a frente de onda, ao atingir a região, seja considerada plana (ANCELME, 2011). O seu equacionamento é:

$$\frac{1}{v} \frac{\partial^2 u}{\partial t^2} - \frac{\partial^2 u}{\partial x_1^2} - \frac{\partial^2 u}{\partial x_2^2} = 0 \quad (2.32)$$

Onde u , nesse caso, denota a velocidade potencial da onda e v a velocidade da onda no meio (REYNOLDS, 1978).

2.5.3 Camadas de amortecimento

Juntamente com as bordas não reflexivas, uma condição para amortecimento das ondas que incidem nas laterais do meio também foi implementada. Camadas de amortecimento evitam que a onda ultrassônica continue se propagando indefinidamente no material após sua incidência nas laterais do modelo (ANCELME, 2011). Essa condição de contorno reduz gradativa e exponencialmente a energia da onda através de um fator de amortecimento, de tal forma que ao atingir as extremidades do meio simulado sua energia seja nula impossibilitando seu retorno ao transdutor. Essa condição de contorno foi proposta inicialmente no trabalho de (CERJAN *et al.*, 1985). A implementação da condição de contorno para cada lado do meio modelado, esquerda e direita respectivamente, são:

$$W(k) = \exp[-f_{at}(N_a - k)]^2 \quad (2.33)$$

$$W(k) = \exp\{-f_{at}[k - (N_x - N_a)]\}^2 \quad (2.34)$$

Sendo $W(k)$ o fator de atenuação, f_{at} o fator de amortecimento, N_a o número de volumes utilizados na atenuação da onda, k é o índice de volume da malha e N_x é o número de volumes na direção x .

2.5.4 Deslocamento nulo

A última condição de contorno é aplicada na superfície inferior do meio modelado, como mostrado na figura 4. Seu propósito é garantir a reflexão total da onda, impedindo sua propagação além do meio modelado, diminuindo, por consequência, os esforços computacionais. A equação para essa condição de contorno é (CAMURÇA, 2014):

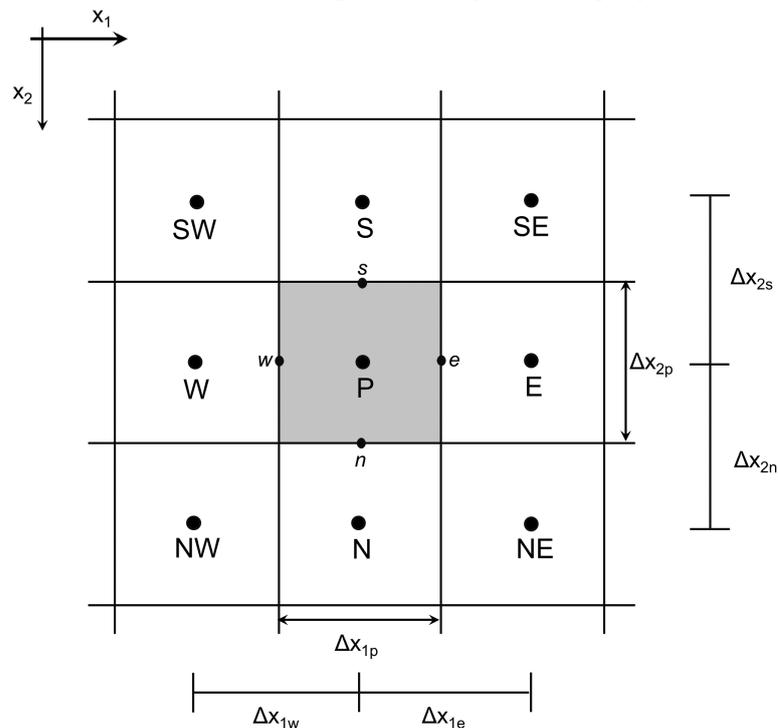
$$u_x = u_y = 0 \quad (2.35)$$

2.6 Equações discretizadas

O método dos volumes finitos requer que as equações diferenciais que descrevem o movimento da onda sejam discretizadas em cada volume de controle e no tempo. As equações obtidas a seguir foram apresentadas no trabalho de Camurça (2014), sendo revisadas posteriormente por Murta (2018).

Primeiramente, é necessário definir um referencial para os volumes de controle, como proposto pela figura 5.

Figura 5 – Malha bidimensional utilizada para obtenção das equações discretizadas



Fonte: Adaptado de Camurça (2014)

Na figura 5, o ponto P central é volume no qual é efetuada a integração espacial. Os demais símbolos (N, S, E, W, NE, NO, SE e SO) são os volumes vizinhos a norte, a sul, a leste, etc (CAMURÇA, 2014). A malha possui espaçamento Δx_1 e Δx_2 no eixo horizontal e vertical, respectivamente.

As derivadas diretas para as componentes x_1 e x_2 do deslocamento, aproximadas pela série de Taylor, são (CAMURÇA, 2014) (MURTA, 2018):

$$\left. \frac{\partial u_1}{\partial t} \right|_P^{t+\Delta t} = \frac{u_{1P}^{t+\Delta t} - u_{1P}^t}{\Delta t} \quad (2.36)$$

$$\left. \frac{\partial u_2}{\partial t} \right|_P^{t+\Delta t} = \frac{u_{2P}^{t+\Delta t} - u_{2P}^t}{\Delta t} \quad (2.37)$$

$$\left. \frac{\partial u_1}{\partial t} \right|_P^t = \frac{u_{1P}^t - u_{1P}^{t-\Delta t}}{\Delta t} \quad (2.38)$$

$$\left. \frac{\partial u_2}{\partial t} \right|_P^t = \frac{u_{2P}^t - u_{2P}^{t-\Delta t}}{\Delta t} \quad (2.39)$$

$$\left. \frac{\partial u_1}{\partial x_1} \right|_e^t = \frac{u_{1E}^t - u_{1P}^t}{\Delta x_{1e}} \quad (2.40)$$

$$\left. \frac{\partial u_2}{\partial x_1} \right|_e^t = \frac{u_{2E}^t - u_{2P}^t}{\Delta x_{1e}} \quad (2.41)$$

$$\left. \frac{\partial u_1}{\partial x_1} \right|_w^t = \frac{u_{1P}^t - u_{1W}^t}{\Delta x_{1w}} \quad (2.42)$$

$$\left. \frac{\partial u_2}{\partial x_1} \right|_w^t = \frac{u_{2P}^t - u_{2W}^t}{\Delta x_{1w}} \quad (2.43)$$

$$\left. \frac{\partial u_1}{\partial x_2} \right|_n^t = \frac{u_{1N}^t - u_{1P}^t}{\Delta x_{2n}} \quad (2.44)$$

$$\left. \frac{\partial u_2}{\partial x_2} \right|_n^t = \frac{u_{2N}^t - u_{2P}^t}{\Delta x_{2n}} \quad (2.45)$$

$$\left. \frac{\partial u_1}{\partial x_2} \right|_s^t = \frac{u_{1P}^t - u_{1S}^t}{\Delta x_{2s}} \quad (2.46)$$

$$\left. \frac{\partial u_2}{\partial x_2} \right|_s^t = \frac{u_{2P}^t - u_{2S}^t}{\Delta x_{2s}} \quad (2.47)$$

Por sua vez, as derivadas cruzadas obtidas são (CAMURÇA, 2014) (MURTA, 2018):

$$\left. \frac{\partial u_1}{\partial x_1} \right|_n^t = \frac{u_{1NE}^t + u_{1E}^t - u_{1NW}^t - u_{1W}^t}{2(\Delta x_{1w} - \Delta x_{1e})} \quad (2.48)$$

$$\left. \frac{\partial u_2}{\partial x_1} \right|_n^t = \frac{u_{2NE}^t + u_{2E}^t - u_{2NW}^t - u_{2W}^t}{2(\Delta x_{1w} - \Delta x_{1e})} \quad (2.49)$$

$$\left. \frac{\partial u_1}{\partial x_1} \right|_s^t = \frac{u_{1SE}^t + u_{1E}^t - u_{1SW}^t - u_{1W}^t}{2(\Delta x_{1w} - \Delta x_{1e})} \quad (2.50)$$

$$\left. \frac{\partial u_2}{\partial x_1} \right|_s^t = \frac{u_{2SE}^t + u_{2E}^t - u_{2SW}^t - u_{2W}^t}{2(\Delta x_{1w} - \Delta x_{1e})} \quad (2.51)$$

$$\left. \frac{\partial u_1}{\partial x_2} \right|_e^t = \frac{u_{1NE}^t + u_{1N}^t - u_{1SE}^t - u_{1S}^t}{2(\Delta x_{2s} - \Delta x_{2n})} \quad (2.52)$$

$$\left. \frac{\partial u_2}{\partial x_2} \right|_e^t = \frac{u_{2NE}^t + u_{2N}^t - u_{2SE}^t - u_{2S}^t}{2(\Delta x_{2s} - \Delta x_{2n})} \quad (2.53)$$

$$\left. \frac{\partial u_1}{\partial x_2} \right|_s^t = \frac{u_{1NW}^t + u_{1N}^t - u_{1SW}^t - u_{1S}^t}{2(\Delta x_{2s} - \Delta x_{2n})} \quad (2.54)$$

$$\left. \frac{\partial u_2}{\partial x_2} \right|_s^t = \frac{u_{2NW}^t + u_{2N}^t - u_{2SW}^t - u_{2S}^t}{2(\Delta x_{2s} - \Delta x_{2n})} \quad (2.55)$$

As derivadas diretas e cruzadas para o deslocamento no eixo x_2 podem ser encontradas de forma análoga ao apresentado para o eixo x_1 .

2.6.1 Volume interno do modelo

A equação para o deslocamento no volume interno, em x_1 e x_2 , precisa primeiramente das integrações no tempo e espaço das equações 2.23 e 2.24 (MURTA, 2018).

$$\begin{aligned}
\int_s^n \int_w^e \int_t^{t+\Delta t} \left(\rho \frac{\partial^2 u_1}{\partial t^2} \right) dt dx_1 dx_2 &= \int_t^{t+\Delta t} \int_s^n \int_w^e (F_1) dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{11} \frac{\partial}{\partial x_1} \left(\frac{\partial u_1}{\partial x_1} \right) \right] dx_1 dx_2 dt + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{12} \frac{\partial}{\partial x_1} \left(\frac{\partial u_2}{\partial x_2} \right) \right] dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{66} \frac{\partial}{\partial x_2} \left(\frac{\partial u_1}{\partial x_2} \right) \right] dx_2 dx_1 dt + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{66} \frac{\partial}{\partial x_2} \left(\frac{\partial u_2}{\partial x_1} \right) \right] dx_2 dx_1 dt
\end{aligned} \tag{2.56}$$

$$\begin{aligned}
\int_s^n \int_w^e \int_t^{t+\Delta t} \left(\rho \frac{\partial^2 u_2}{\partial t^2} \right) dt dx_1 dx_2 &= \int_t^{t+\Delta t} \int_s^n \int_w^e (F_2) dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{66} \frac{\partial}{\partial x_1} \left(\frac{\partial u_1}{\partial x_2} \right) \right] dx_1 dx_2 dt + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{66} \frac{\partial}{\partial x_1} \left(\frac{\partial u_2}{\partial x_1} \right) \right] dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{12} \frac{\partial}{\partial x_2} \left(\frac{\partial u_1}{\partial x_1} \right) \right] dx_2 dx_1 dt + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{11} \frac{\partial}{\partial x_2} \left(\frac{\partial u_2}{\partial x_2} \right) \right] dx_2 dx_1 dt
\end{aligned} \tag{2.57}$$

Usando formulação explícita, onde os termos de deslocamentos são tomados no instante anterior, e aproximações de diferentes centros para os termos das derivadas, os desenvolvimentos das equações 2.56 e 2.57 resultam, respectivamente (CAMURÇA, 2014) (MURTA, 2018):

$$\begin{aligned}
\rho \int_s^n \int_w^e \left(\frac{\partial u_1}{\partial t} \Big|_P^{t+\Delta t} - \frac{\partial u_1}{\partial t} \Big|_P^t \right) dx_1 dx_2 &= \int_t^{t+\Delta t} \int_s^n \int_w^e (F_1) dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_s^n \left(C_{11}^e \frac{\partial u_1}{\partial x_1} \Big|_e^t - C_{11}^w \frac{\partial u_1}{\partial x_1} \Big|_w^t \right) dx_2 dt + \int_t^{t+\Delta t} \int_s^n \left(C_{12}^e \frac{\partial u_2}{\partial x_2} \Big|_e^t - C_{12}^w \frac{\partial u_2}{\partial x_2} \Big|_w^t \right) dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_w^e \left(C_{66}^n \frac{\partial u_1}{\partial x_2} \Big|_n^t - C_{66}^s \frac{\partial u_1}{\partial x_2} \Big|_s^t \right) dx_1 dt + \int_t^{t+\Delta t} \int_w^e \left(C_{66}^n \frac{\partial u_2}{\partial x_1} \Big|_n^t - C_{66}^s \frac{\partial u_2}{\partial x_1} \Big|_s^t \right) dx_1 dt
\end{aligned} \tag{2.58}$$

$$\begin{aligned}
\rho \int_s^n \int_w^e \left(\frac{\partial u_2}{\partial t} \Big|_P^{t+\Delta t} - \frac{\partial u_2}{\partial t} \Big|_P^t \right) dx_1 dx_2 &= \int_t^{t+\Delta t} \int_s^n \int_w^e (F_2) dx_1 dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_s^n \left(C_{66}^e \frac{\partial u_1}{\partial x_2} \Big|_e^t - C_{66}^w \frac{\partial u_1}{\partial x_2} \Big|_w^t \right) dx_2 dt + \int_t^{t+\Delta t} \int_s^n \left(C_{66}^e \frac{\partial u_2}{\partial x_1} \Big|_e^t - C_{66}^w \frac{\partial u_2}{\partial x_1} \Big|_w^t \right) dx_2 dt \\
&+ \int_t^{t+\Delta t} \int_w^e \left(C_{12}^n \frac{\partial u_1}{\partial x_1} \Big|_n^t - C_{12}^s \frac{\partial u_1}{\partial x_1} \Big|_s^t \right) dx_1 dt + \int_t^{t+\Delta t} \int_w^e \left(C_{11}^n \frac{\partial u_2}{\partial y} \Big|_n^t - C_{11}^s \frac{\partial u_2}{\partial x_2} \Big|_s^t \right) dx_1 dt
\end{aligned} \tag{2.59}$$

A malha sendo do tipo estruturada e quadrada, com os termos fontes sendo nulos no interior do volume (já que atuam somente na superfície do material), tem-se (MURTA, 2018):

$$\Delta F_1 = \Delta F_2 = 0 \tag{2.60}$$

$$\Delta x_{1e} = \Delta x_{1w} \tag{2.61}$$

$$\Delta x_{2n} = \Delta x_{2s} \tag{2.62}$$

Em seguida, substituindo nas equações 2.58 e 2.59 as equações 2.36 a 2.55, juntamente com a reorganização dos termos, é possível obter as equações para o cálculo do deslocamento no volume interno em x_1 e x_2 , respectivamente:

$$\begin{aligned}
u_{1P}^{t+\Delta t} &= 2u_{1P}^t - u_{1P}^{t-\Delta t} + \frac{\Delta t^2}{\rho \Delta x_1^2} [C_{11}^e (u_{1E}^t - u_{1P}^t) - C_{11}^w (u_{1P}^t - u_{1W}^t)] \\
&+ \frac{\Delta t^2}{\rho \Delta x_2^2} [C_{66}^n (u_{1N}^t - u_{1P}^t) - C_{66}^s (u_{1P}^t - u_{1S}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x_1 \Delta x_2} [C_{12}^e (u_{2NE}^t + u_{2NW}^t - u_{2SE}^t - u_{2S}^t) - C_{12}^w (u_{2N}^t + u_{2NW}^t - u_{2S}^t - u_{2SW}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x_1 \Delta x_2} [C_{66}^n (u_{2NE}^t + u_{2E}^t - u_{2NW}^t - u_{2W}^t) - C_{66}^s (u_{2E}^t + u_{2SE}^t - u_{2W}^t - u_{2SW}^t)]
\end{aligned} \tag{2.63}$$

$$\begin{aligned}
u_{2P}^{t+\Delta t} = & 2u_{2P}^t - u_{2P}^{t-\Delta t} + \frac{\Delta t^2}{\rho \Delta x_1^2} [C_{66}^e (u_{2E}^t - u_{2P}^t) - C_{66}^w (u_{2P}^t - u_{2W}^t)] \\
& + \frac{\Delta t^2}{\rho \Delta x_2^2} [C_{11}^n (u_{2N}^t - u_{2P}^t) - C_{11}^s (u_{2P}^t - u_{2S}^t)] \\
& + \frac{\Delta t^2}{4\rho \Delta x_1 \Delta x_2} [C_{66}^e (u_{1NE}^t + u_{1NN}^t - u_{1SE}^t - u_{1S}^t) - C_{66}^w (u_{1N}^t + u_{1NW}^t - u_{1S}^t - u_{1SW}^t)] \\
& + \frac{\Delta t^2}{4\rho \Delta x_1 \Delta x_2} [C_{12}^n (u_{1NE}^t + u_{1E}^t - u_{1NW}^t - u_{1W}^t) - C_{12}^s (u_{1E}^t + u_{1SE}^t - u_{1W}^t - u_{1SW}^t)]
\end{aligned} \tag{2.64}$$

Destaca-se que os módulos elásticos nas equações 2.63 e 2.64 são os módulos referentes às interfaces de cada volume de controle (CAMURÇA, 2014). Esses módulos são calculados através da média harmônica, como sugerido por Patankar (1980).

A integração dos volumes da malha referentes as condições de contorno impostas nas fronteiras do modelo, como mostrado pela figura 4, é realizada de forma similar a apresentada nas equações 2.63 e 2.63 (CAMURÇA, 2014). Nesse caso, deve-se respeitar as condições impostas para cada condição de contorno proposta em cada superfície modelada (CAMURÇA, 2014).

2.7 Impedância

Em qualquer movimento de natureza física (sendo ele elétrico, mecânico ou químico), há sempre duas forças atuantes nesse processo: uma força motriz e uma força restritiva ao movimento (SHULL, 2002). Sendo assim, a impedância pode ser classificada como a resistência que o meio faz a onda acústica que se propaga, e seu equacionamento pode ser descrito como:

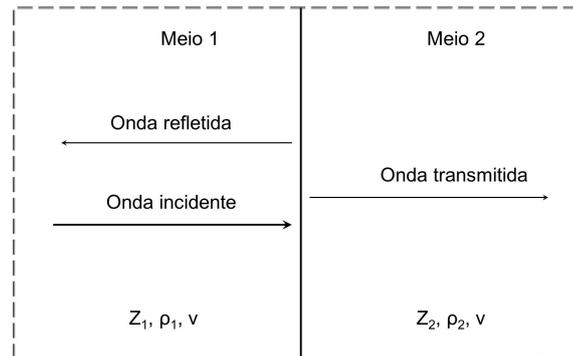
$$Z = \rho v_p \tag{2.65}$$

Onde Z é a impedância em $kg/(m^2s)$, ρ é a densidade do meio e v_p é a velocidade da onda longitudinal.

Pelo equacionamento em 2.65, percebe-se que materiais homogêneos têm valores de impedância constante ao longo de seu interior, enquanto materiais heterogêneos possuem impedâncias diferentes para variação das propriedades em seu interior. Quando a onda que se propaga proveniente do meio um, com densidade ρ_1 , atinge a superfície de um meio dois, que possui densidade ρ_2 sendo a relação $\rho_1 \neq \rho_2$ verdadeira, uma parte da energia carregada

pela onda propagada é dissipada para o meio (AMERICAN SOCIETY FOR METALS, 1992). Assim, em uma situação de simulação de ensaio ultrassônico considerando apenas a dissipação de energia devido a impedância, a energia emitida pelo transdutor será diferente e menor do que a energia captada pelo receptor (SANTIN, 2003). A figura 6 mostra a reflexão de parte da onda na transição para meios com diferentes impedâncias.

Figura 6 – Reflexão da onda para meios com diferentes impedâncias



Fonte: Adaptado de Shull (2002)

Para uma onda incidindo normalmente ao meio, a taxa de reflexão e de transmissão, considerando a energia da onda, podem ser determinados como mostrado nas equações 2.66 e 2.67 (AMERICAN SOCIETY FOR METALS, 1992).

$$R = \frac{(Z_2 - Z_1)^2}{(Z_2 + Z_1)^2} \quad (2.66)$$

$$T = \frac{4Z_2Z_1}{(Z_2 + Z_1)^2} \quad (2.67)$$

Onde R e T são a taxa de reflexão e de transmissão da onda, respectivamente. Como a energia da onda propagada ou é toda refletida ou transmitida, a relação $R + T = 1$ é verdadeira (AMERICAN SOCIETY FOR METALS, 1992).

Razões de reflexão e transmissão podem ser determinadas em relação, também, da pressão sônica da onda (SHULL, 2002).

$$r = \frac{Z_2 - Z_1}{Z_2 + Z_1} \quad (2.68)$$

$$t = \frac{2Z_2}{Z_2 + Z_1} \quad (2.69)$$

2.8 Regime de espalhamento da onda

O espalhamento da onda acústica é uma resposta às imperfeições presentes no meio. Descontinuidades como porosidade, inclusões não metálicas e estrutura de grão, por exemplo, ocasionam deflexão de parte da energia da onda, fazendo com que a onda seja refletida, refratada ou modo convertida em função do seu ângulo de incidência e das mudanças de densidade e propriedades elásticas (SHULL, 2002). Essas imperfeições aparecem de forma aleatória no meio a ser propagado, fazendo com que a energia dissipada seja enviada para direções aleatórias dentro do material (SHULL, 2002).

A quantidade de energia dissipada pelo espalhamento da onda é fortemente dependente da relação entre o tamanho de grão no qual a onda ultrassônica se propaga e o comprimento de onda, λ (AMERICAN SOCIETY FOR METALS, 1992). Desse modo, em função do tamanho de grão, o espalhamento da onda pode ser classificado em três diferentes regimes: espalhamento de Rayleigh, estocástico e geométrico.

2.8.0.1 *Espalhamento de Rayleigh*

Nessa região, o tamanho de grão é de ordem de tamanho muito menor do que o comprimento de onda. Sua representação aritmética é:

$$a \ll \lambda \quad (2.70)$$

Onde a é o diâmetro do grão e λ o comprimento de onda. Nessa região, o espalhamento da onda ocorre praticamente em todas as direções e é fortemente dependente do λ da onda que se propaga (SHULL, 2002). É nesse regime de espalhamento que geralmente são feitas as inspeções ultrassônicas para determinação do tamanho de partículas (SHULL, 2002).

2.8.0.2 *Regime de espalhamento estocástico*

O regime de espalhamento estocástico é caracterizado por ter tamanho de grão de mesma ordem de grandeza do comprimento de onda, por ser um regime de transição entre o espalhamento de Rayleigh e geométrico e por possuir ressonância (variação de magnitudes) da

onda espalhada (SHULL, 2002). Pode ser representado matematicamente por:

$$a \cong \lambda \quad (2.71)$$

Nota-se que o espalhamento máximo ocorre quando $a = \lambda$.

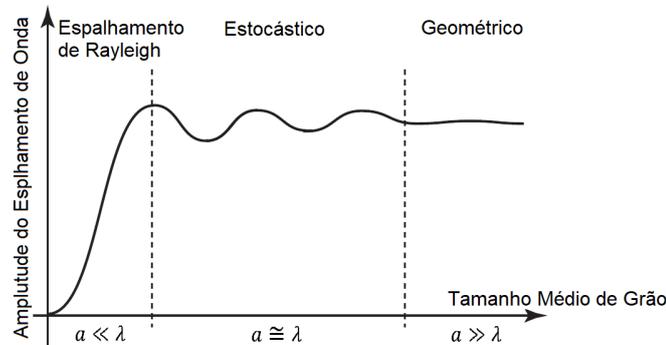
2.8.0.3 Regime de espalhamento geométrico

O terceiro regime de espalhamento é o geométrico. Caracteriza-se por ter tamanho de grão de ordem de tamanho muito maior do que o comprimento de onda. A grande diferença entre tamanho de grão e comprimento de onda faz com que esse regime de espalhamento seja regido por condições geométricas (SHULL, 2002).

$$a \gg \lambda \quad (2.72)$$

A figura 7 mostra graficamente a dispersão de energia da onda para cada regime mencionado.

Figura 7 – Regimes de espalhamento em função do tamanho de grão



Fonte: Adaptado de Shull (2002)

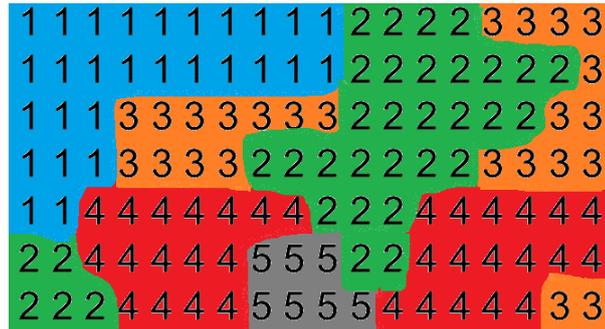
2.9 Crescimento de grão

Para estudar a relação do crescimento de grão no comportamento do espalhamento da onda ultrassônica, foi proposta a realização da simulação, também, do crescimento do grão através do modelo de Potts.

Primeiramente, foi determinado o tamanho do modelo no qual deseja-se estudar o crescimento dos grãos. Dessa maneira, uma matriz $m \times n$ foi gerada onde cada elemento dessa

matriz representa uma orientação Q de grão, com valores inteiros do tipo $1 \leq Q$ que foram atribuídos de forma aleatória. A figura 8 mostra um exemplo de matriz com orientações de grãos. Nessa figura, números iguais e adjacentes representam grãos, onde cada orientação possui uma cor escolhida arbitrariamente. No exemplo da figura ??, grãos de orientação 1 têm cor azul; grãos de orientação 2 têm cor verde; grãos de orientação 3 possuem cor laranja; grãos de orientação 4 possuem cor vermelha e grãos de orientação 5 têm cor cinza.

Figura 8 – Exemplo de matriz com orientações de grãos



Fonte: o autor

A região que separa os grãos com orientações diferentes, representa o contorno de grão (ANDERSON *et al.*, 1984). A energia do contorno de grão nessa região, pode ser descrita como mostrado na equação 2.73:

$$H = -J \sum_m (\delta_{S_i S_j} - 1) \quad (2.73)$$

Onde H é o hamiltoniano que caracteriza a interação entre as orientações vizinhas, S_i e S_j representam uma orientação possível de forma $1 \leq S_i \leq Q$ e δ representa o delta de Kronecker, cujos valores são:

$$\delta_{ij} = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (2.74)$$

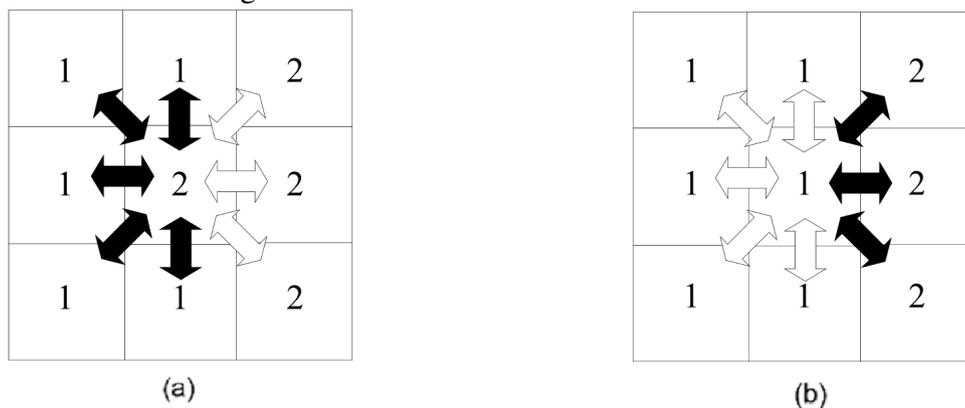
A somatória é tomada em cada elemento da malha, onde todos os seus vizinhos são comparados para verificar se há ou não contribuição para a energia do sistema, J . Pela equação 2.73, valores vizinhos com orientações diferentes contribuem para a energia do sistema, enquanto vizinhos com orientações iguais, não.

Definida a matriz, a quantidade máxima possível de orientações e como a energia entre os contornos de grão se comporta para cada orientação, é possível então iniciar o algoritmo de crescimento de grão, que pode ser dividido em cinco passos principais (BLIKSTEIN; TSCHIPTSCHIN, 1999):

1. Seleção aleatória de um elemento da matriz
2. Cálculo da energia do sistema para a orientação atual do elemento
3. Seleção aleatória de uma nova orientação para o mesmo elemento
4. Comparar a nova energia do sistema com a energia anterior
5. selecionar a orientação que gere a menor energia

Os passos enumerados acima podem ser vistos pela ilustração mostrada pela figura 9.

Figura 9 – Crescimento de grão



Fonte: Blikstein e Tschiptschin (1999)

Na imagem (a) da figura 9, um elemento da matriz $m \times n$ de orientação 2 foi selecionado de forma aleatória. Calculou-se então a energia do sistema para a orientação selecionada. Setas brancas representam os vizinhos do elemento que não contribuem para aumento da energia do sistema, pois possuem mesma orientação; as setas pretas indicam os vizinhos que contribuem para o acréscimo da energia do sistema, pois possuem orientações diferentes do elemento selecionado. Nesse caso, a energia calculada tem valor de 5 (de acordo com a equação 2.73). A imagem (b) mostra uma nova orientação de 1 selecionada aleatoriamente para o mesmo elemento da matriz. Novamente, o cálculo da energia do sistema é realizado. A energia obtida para a nova orientação tem valor de 3. A orientação que proporcionar a menor energia do sistema é então escolhida como sendo o novo elemento da matriz.

O passo temporal desse tipo de simulação é chamado de *Monte Carlo Step* (passo

de Monte Carlo, ou MCS), onde 1 MCS representa $m \times n$ mudanças aleatórias de orientação na matriz (ANDERSON *et al.*, 1984). Ou seja, os cinco passos descritos acima para o algoritmo de crescimento do grão é realizado um total de $m \times n$ vezes.

O resultado obtido é então uma simulação em escala microscópica do decaimento da energia no sistema, que é usualmente a força motriz para o crescimento de grão (BLIKSTEIN; TSCHIPTSCHIN, 1999).

2.10 Detrended-Fluctuation Analysis (DFA)

Apresentada pela primeira vez por Peng *et al.* (1994), *Detrended-Fluctuation Analysis* (DFA) é uma ferramenta matemática que analisa propriedades de correlação para dados de séries temporais não estacionárias. O uso do DFA visa a eliminação de tendências presentes nos dados que, de alguma forma, impedem uma análise mais precisa da correlação existente entre eles (VIEIRA *et al.*, 2008). O DFA também previne a falsa detecção de autossimilaridade nos dados (HU *et al.*, 2001). A partir de um ponto de vista de processamento de sinais, DFA pode ser enxergado, também, como uma forma de compressão dos dados originais presentes na série temporal em um conjunto reduzido com um menor número de variáveis a serem analisadas (MOURA *et al.*, 2009).

Para calcular DFA, o primeiro passo consiste na integração de um novo conjunto de dados a partir do conjunto inicial.

$$y_i = \sum_{j=1}^i (x_j - \bar{x}) \quad (2.75)$$

Onde y_i é a função integrada, x_j é o j -ésimo elemento do conjunto de dados original e \bar{x} é o valor médio do conjunto x , como definido pela equação 2.76:

$$\bar{x} = \frac{1}{L} \sum_{i=1}^L x_i \quad (2.76)$$

Após a integração, os dados são divididos em n intervalos de tamanhos iguais, τ . Em cada intervalo, uma linha de ajuste é traçada através dos pontos, determinando a tendência local, h_i , dos dados. A eliminação das tendências acontece com a subtração dos dados integrados pelas

tendências locais em cada ponto da linha de ajuste, como mostrado pela equação 2.77:

$$\Delta_i = y_i - h_i \quad (2.77)$$

A flutuação da série de dados para cada intervalo é calculada, finalmente, como:

$$F(\tau) = \sqrt{\frac{1}{\tau} \sum_i \Delta_i^2} \quad (2.78)$$

O cálculo de flutuação é realizado para diversos valores de intervalo τ . Uma relação entre a flutuação $F(\tau)$ e o tamanho do intervalo é esperada na forma

$$F(\tau) \sim \tau^\alpha \quad (2.79)$$

Sendo o parâmetro de autossimilaridade, α , o que representa as propriedades de correlações de leis de potência de longos períodos do sinal (MOURA *et al.*, 2009).

2.11 Algoritmos de Reconhecimento de Padrões

Define-se o reconhecimento de padrões como sendo um ramo da ciência que busca classificar e/ou agrupar objetos através da percepção de características comuns presentes em conjuntos de dados (THEODORIDIS; KOUTROUMBAS, 2008) (BISHOP, 2006).

O algoritmo para o reconhecimento de padrões pode ser classificado como supervisionado ou não supervisionado. No primeiro caso, é dito previamente ao algoritmo a qual classe pertence o dado analisado. Essa informação é disponibilizada na fase de treinamento do algoritmo, onde parte dos dados a serem analisados são escolhidos como dados de treinamento para ensinar ao algoritmo como o conjunto de dados se caracteriza (THEODORIDIS; KOUTROUMBAS, 2008). Em seguida, acontece a fase de teste do algoritmo, onde o restante dos dados não utilizados são fornecidos, cabendo agora ao algoritmo identificar as classes/grupos a qual cada dado pertence baseado em no conhecimento prévio adquirido na fase de treinamento (THEODORIDIS; KOUTROUMBAS, 2008).

no aprendizado não supervisionado não é requerido uma informação previa sobre a classificação real dos dados

O segundo tipo de algoritmo é dito como sendo não supervisionado. Nesse caso, nenhuma informação prévia sobre os dados analisados é dada ao algoritmo, que por sua vez terá

que determinar o melhor agrupamento dos dados, baseados na similaridades encontradas entre eles. Esse tipo de algoritmo, diferentemente do tipo supervisionado, não necessariamente classifica os dados fornecido, mas sim os agrupa de acordo com suas similaridades (THEODORIDIS; KOUTROUMBAS, 2008).

No presente trabalho, os algoritmos utilizados são do tipo de aprendizagem supervisionada e são apresentados nas seções seguintes.

2.11.1 Transformada de Karhunen-Loève

A Transformada de Karhunen-Loève (do inglês *Karhunen-Loève Transformation*, KLT) é uma ferramenta bastante utilizada na área de processamento de sinais, na compressão ou segmentação de imagens (WEBB, 2003). Seu objetivo é filtrar os dados obtidos (sinais ou imagens), proporcionando uma descorrelação entre eles e eliminando redundâncias (HUA; LIU, 1998) (WEBB, 2003). Permite também selecionar e extrair informações de maior interesse, permitindo análise e classificação mais eficiente (VIEIRA *et al.*, 2008). A combinação de análise fractal (DFA) com a Transformada de Karhunen-Loève já foi mostrada ser exitosa no estudo de classificação de sinais (VIEIRA *et al.*, 2008). Neste trabalho, a versão empregada do algoritmo KLT consiste na compressão e discriminação da informação contida nos dados analisados, como apresentado em (KITTLER; YOUNG, 1973) e usado por (VIEIRA *et al.*, 2008).

O algoritmo KLT consiste primeiramente na projeção dos vetores de treinamento ao longo dos autovetores dentro da matriz de covariância, S_W , definida como (VIEIRA *et al.*, 2008):

$$S_W = \frac{1}{N} \sum_{k=1}^{N_C} \sum_{i=1}^{N_K} y_{ik} (x_i - m_k)(x_i - m_k)^T \quad (2.80)$$

Onde N é o número total de vetores. O elemento N_C é o número de classes diferentes presentes no conjunto de dados, N_K é o número de vetores dentro da k -ésima classe e m_k é o vetor médio também da k -ésima classe; x_i é um vetor coluna contendo o i -ésimo sinal obtido. O elemento y_{ik} possui valor igual a 1 se x_i pertencer a classe k , ou zero caso contrário.

Os vetores resultantes da equação 2.80 são reescalados por uma matriz diagonal formada pelo autovalores da matriz S_W . Matematicamente, essa operação é definida como (VIEIRA *et al.*, 2008):

$$X' = \Lambda^{-\frac{1}{2}} U^T X \quad (2.81)$$

Onde X' é uma matriz cujas colunas são os vetores de treinamento x_i , Λ é uma matriz diagonal com os autovalores da matriz S_W e U é uma matriz com suas colunas sendo os autovetores da matriz S_W .

Para compressão da informação das classes, os vetores obtidos a partir da equação 2.81 são projetados nos autovalores da matriz de covariância S_B , definida como (VIEIRA *et al.*, 2008):

$$S_B = \sum_{k=1}^{N_C} \frac{N_K}{N} (m_k - m)(m_k - m)^T \quad (2.82)$$

Onde m é o vetor médio geral do conjunto de dados.

Por fim, toda a transformada KL pode ser descrita como

$$X'' = V^T \Lambda^{-\frac{1}{2}} U^T X \quad (2.83)$$

Com V sendo uma matriz cujas colunas são os autovetores de S_B .

Ao final, o algoritmo KLT proporcionará o agrupamento dos dados de acordo com suas características comuns em um plano formado pelos eixos de suas componentes principais.

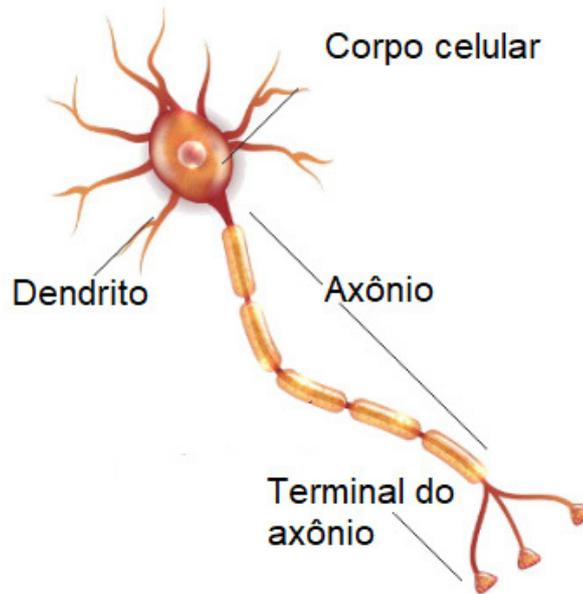
2.11.1.1 Regra da média da classe mais próxima

A transformada de Karhunen-Loève por si só não classifica os dados de acordo com as classes ou grupos desejados. Para isso, é necessário o uso de outro algoritmo capaz de determinar a proximidade entre os dados agrupados pela transformada e os dados previamente conhecidos com as classes desejadas. Assim, optou-se pelo uso do algoritmo da regra da média da classe mais próxima, que consiste na classificação dos dados de teste de acordo com o vetor médio da classe mais próxima, segundo a distância euclidiana medida (MURTA *et al.*, 2018).

2.11.2 Redes neurais artificiais

O modelo matemático para um neurônio artificial foi proposto inicialmente por McCulloch e Pitts (1943). As redes neurais artificiais (RNAs) são compostas por neurônios artificiais capazes de aprender. Como o nome sugere, os neurônios artificiais são baseados em neurônios biológicos, cuja anatomia é mostrada na figura 10.

Figura 10 – Anatomia de um neurônio biológico



Fonte: Adaptado de Brasil Escola (2018)

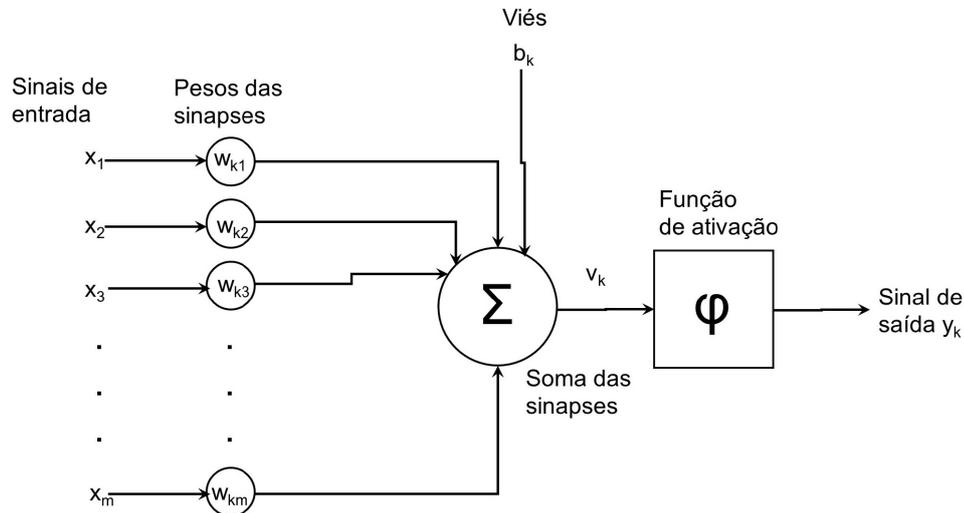
Neurônios biológicos são células altamente especializadas que compõem o sistema nervoso dos animais. De forma simplificada, estímulos externos são captados por receptores, que os encaminham para os neurônios através das sinapses nervosas presentes nos dendritos (SILVERTHORN, 2010). O estímulo recebido segue então para o corpo da célula nervosa, onde a energia dos estímulos recebida de cada dendrito é balanceada (SILVERTHORN, 2010). Caso a energia atinja o valor de ativação necessário do neurônio, a informação segue pelo axônio até o terminal, onde o estímulo continua sua propagação seja para outra célula nervosa, muscular ou glandular através de sinapses (SILVERTHORN, 2010).

2.11.2.1 *Neurônio artificial*

Um neurônio artificial será composto por partes equivalentes a de um neurônio real. O equivalente artificial ao neurônio real é chamado de nó ou unidade (GURNEY, 2004). As sinapses são modeladas como números unitários ou pesos, fazendo com que os dados de entrada sejam multiplicados por um valor antes de chegarem ao corpo do neurônio artificial (GURNEY, 2004). No corpo celular artificial, a ativação do neurônio dá-se através da soma das sinapses já multiplicadas por seus respectivos pesos, constituindo assim um combinador linear (HAYKIN, 2009). É possível a presença de um viés a ser adicionado juntamente com os demais sinais de entrada. A função desse viés é para aumentar ou diminuir o valor total dos sinais de entrada, dependendo se $b_k > 0$ ou $b_k < 0$, respectivamente (HAYKIN, 2009).

Em seguida, uma função de ativação limitando a amplitude do sinal de saída é usada, indicando a ativação ou não do neurônio ao estímulo recebido (HAYKIN, 2009). A esquematização desse processo é mostrada na figura 11.

Figura 11 – Esquematização de um neurônio artificial



Fonte: o autor

Na figura 11, os índices subscritos nos pesos sinápticos indicam, respectivamente, o neurônio e a sinapse na qual o peso multiplica. Similarmente, em v_k e y_k o índice subscrito representa o viés e o sinal de saída do respectivo neurônio k (HAYKIN, 2009).

O neurônio k mostrado na figura 11 pode ser descrito matematicamente através das seguintes equações (HAYKIN, 2009):

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.84)$$

$$y_k = \phi(u_k + b_k) \quad (2.85)$$

Onde x_j representa o j -ésimo sinal de entrada no neurônio k ; u_k é o resultado do combinador linear das somas dos sinais de entrada. O termo v_k pode ser escrito em função de u_k e b_k , como mostrado abaixo (HAYKIN, 2009):

$$v_k = u_k + b_k \quad (2.86)$$

Assim, a equação 2.85 pode ser reescrita como:

$$y_k = \phi(v_k) \quad (2.87)$$

2.11.2.2 Funções de ativação

A função de ativação determina o dado de saída do neurônio. Duas formas básicas de função de ativação podem ser utilizadas no neurônio artificial.

A primeira é a função de limiar. Nesse tipo de função, o sinal de saída gerado pelo neurônio artificial, y_k , assume valor 1 e 0 para as condições de $v_k \geq 0$ e $v_k < 0$, respectivamente (HAYKIN, 2009).

O segundo modelo comumente empregado, é o de função sigmóide. Esse tipo de função de ativação consegue combinar comportamentos lineares e não lineares (HAYKIN, 2009). Um exemplo de função sigmóide é a função logística representada como:

$$\phi(v_k) = \frac{1}{1 + \exp(-av_k)} \quad (2.88)$$

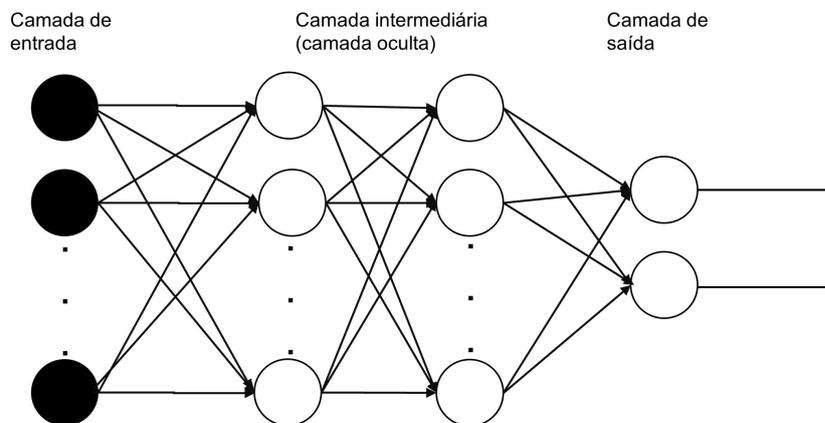
A forma gráfica dessa função lembra a da letra "S", e pode ser ajustada de acordo com variações no parâmetro de inclinação a . De fato, a função de limiar é um caso específico da função sigmóide para a tendendo ao infinito. Através da função sigmóide, também é possível ainda determinar um terceiro caso específico para função de ativação ϕ . Nesse caso específico, semelhante à função de limiar, um valor intermediário $\phi(v_k) = 0$ quando $v_k = 0$ é adicionado.

2.11.2.3 Perceptron de multicamadas

O perceptron de multicamadas (*multilayer perceptron*, MLP, do inglês) é uma forma de implementação de uma rede neural artificial utilizada para separação não linear de classes. Esse modelo faz uso de um sistema de aprendizado do neurônio para o modelo de multicamadas, juntamente com camadas ocultas que vão processar os dados de entrada antes de serem propriamente utilizados no cálculo do sinal de saída gerados na camada de saída. Uma rede neural MLP é dita ser um aproximador universal de função, capaz de aproximar qualquer função contínua com precisão arbitrária para um número suficientemente grande de neurônios ativados por função sigmóide (HAYKIN, 2009).

Primeiramente, os dados de entrada são recebidos pelos neurônios da camada de entrada. Em seguida, esses dados são repassados aos neurônios presentes nas camadas ocultas (que possuem esse nome pois não têm contato direto com os dados de saída), onde as características presentes nos sinais são detectadas, tornando-os assim um componente importantíssimo no modelo MLP (HAYKIN, 2009). Por fim, os dados oriundos dos neurônios ocultos são apresentados pela camada de saída, sendo essa de fato a resposta da rede para o usuário (HAYKIN, 2009). O modelo MLP é mostrado na figura 12.

Figura 12 – Esquemática de uma rede MLP, onde cada círculo representa um neurônio artificial



Fonte: o autor

O treinamento dos neurônios para uma configuração de multicamadas pode ser realizado através da técnica de *error backpropagation* (retropropagação dos erros). Essa técnica consiste na propagação do erro a partir dos neurônios da camada de saída em direção a todos os neurônios da camada oculta, percorrendo assim sentido inverso ao da propagação dos dados de entrada (RUMELHART *et al.*, 1986) (HAYKIN, 2009). São necessárias duas regras de aprendizagem, nesse caso: uma para os neurônios na camada de saída e outra para neurônios na camada oculta. A regra de aprendizagem para configuração MLP consiste em um ajuste dos pesos utilizados nas sinapses artificiais e é, para os neurônios na camada de saída, definida como:

$$w_{km}^{novo} = w_{km}^{antigo} + \eta \delta_k^s y_m \quad (2.89)$$

Onde η é a taxa de aprendizado, y_m é o conjunto de sinais de saída e δ_k^s é chamado

de gradiente local do k-ésimo neurônio de saída, como mostrado a seguir (HAYKIN, 2009):

$$\delta_k^s = e_k \phi_k' \quad (2.90)$$

Onde e_k representa o erro associado e ϕ_k' é a derivada da função de ativação em função de v_k no k-ésimo neurônio de saída, respectivamente (HAYKIN, 2009). O erro associado a um neurônio, e_k , pode ser definido como:

$$e_k = d_k - y_k \quad (2.91)$$

Onde d_k é o erro esperado gerado pelo neurônio e y_k é o resultado obtido pelo neurônio.

De maneira similar, a regra de aprendizado para neurônios presentes nas camadas ocultas é dada em função do erro retropropagado pelo m-ésimo neurônio da camada oculta, da derivada da função de ativação e do conjunto de sinais de entrada da rede (HAYKIN, 2009). A sua forma matemática é:

$$w_{mj}^{novo} = w_{mj}^{antigo} + \eta \delta_m^o x_j \quad (2.92)$$

Onde x_j é o conjunto de dados de entrada da rede e δ_m^o é o m-ésimo gradiente local do neurônio da camada oculta, definido como:

$$\delta_m^o = e_m \phi_m' \quad (2.93)$$

Onde e_m representa o erro retropropagado e ϕ_m' é a derivada da função de ativação em função de v_m no m-ésimo neurônio da camada oculta, respectivamente (HAYKIN, 2009). O erro retropropagado, e_m , é:

$$e_m = \sum_{k=1}^n m_{km} \delta_k^s \quad (2.94)$$

Tendo sido feitos todos os ajustes para os pesos das sinapses, diz-se que foi passada uma época na rede neural. A passagem de épocas é continuado durante a execução do algoritmo, até que seja alcançada a condição de parada definida.

3 METODOLOGIA

Os parâmetros utilizados no presente estudo são apresentados nas sessões seguintes.

3.1 Parâmetros do modelo

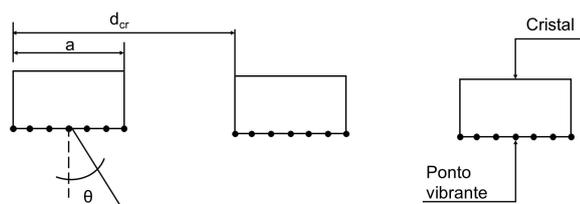
O modelo desenvolvido busca simular um material metálico do tipo aço carbono. Sua disposição espacial é bidimensional com tamanhos para comprimento e largura de 60mm e 19mm , respectivamente. A densidade do material foi tomada como sendo o valor de $7800\text{kg}/\text{m}^3$. Os valores para as velocidades de propagação das ondas longitudinal e transversal foram definidas como $5900\text{m}/\text{s}$ e $3200\text{m}/\text{s}$.

3.2 Parâmetros do transdutor

Como previamente dito, no ensaio não destrutivo por pulso eco, o transdutor desempenha a função de emissor e receptor da onda ultrassônica. A modelagem desse componente foi adaptada a partir do trabalho desenvolvido por Camurça (2014), que modelou o transdutor para a simulação de ensaio ultrassônico utilizando a técnica TOFD (sigla em inglês para *time of flight displacement*) juntamente com direcionamento de feixe da onda ultrassônica (*phased array*). Dessa forma, o desenvolvimento teórico utilizado por Camurça (2014) foi adaptado para que pudesse ser implementado na simulação do ensaio pulso eco.

O trabalho de Wooh e Shi (1999), que foi usado como referência bibliográfica para a modelagem do transdutor, determina parâmetros pertinentes na modelagem da fonte ultrassônica, sendo eles a quantidade de cristais, a distância entre cristais e o tamanho do cristal. A figura 13 mostra o esquema do transdutor modelado utilizado na simulação.

Figura 13 – Representação esquemática do transdutor simulado



Fonte: o autor

3.2.1 Quantidade de cristais

Em seu trabalho, Wooh e Shi (1999) comprovam que quanto mais cristais no modelo do transdutor, melhor será a qualidade do sinal obtido devido à elevada pressão sonora gerada. Desse modo (considerando a geometria do problema tal como testes preliminares), um conjunto de 7 cristais foi escolhido. Cada cristal foi modelado possuindo um total de 7 pontos vibrantes, que serão os responsáveis pela geração da onda ultrassônica.

3.2.2 Distância entre cristais

Pela figura 13, nota-se que há presença de um ângulo de incidência θ entre o cristal e a direção perpendicular de propagação da onda. Essa angulação é referente ao modelo TOFD no qual a simulação anterior foi desenvolvida, como mencionado anteriormente. Entretanto, o ângulo θ ainda se faz necessário para a determinação do parâmetro de distância entre cristais, d_{cr} . Essa distância considera o maior ângulo possível para orientação do feixe ultrassônico, que varia no intervalo $0 \leq \theta \leq 90^\circ$. Valores maiores que 90° comprometem o feixe ultrassônico gerado pelo transdutor (WOOH; SHI, 1999). O equacionamento para determinação de d_{cr} é:

$$d_{cr} = \frac{\lambda}{1 + \text{Sen}\theta_{max}} \quad (3.1)$$

Sendo $\theta_{max} = 90^\circ$, o valor obtido na equação 3.1 é $\lambda/2$.

Ressalta-se que o valor de $\theta = 0^\circ$ foi usado durante a realização das simulações.

3.2.3 Tamanho do cristal

O tamanho do cristal, a , também influencia na intensidade do feixe ultrassônico gerado pelo modelo do transdutor (WOOH; SHI, 1999). Seu valor foi definido como sendo, também, $\lambda/2$. A quantidade de 7 pontos vibrantes por cristal resulta num espaçamento entre eles de $\lambda/12$.

3.2.4 Delay

Como mencionado anteriormente, o transdutor foi modelado de forma que fosse possível direcionar o feixe de onda ultrassônica para uma determinada área de interesse. Esse direcionamento é obtido pelo acionamento dos pontos vibrantes em diferentes intervalos de

tempo, que é chamado de *delay*. Entretanto, para o caso abordado de ensaio ultrassônico por pulso-eco, o direcionamento do feixe da onda não se faz necessário, sendo o *delay* nulo.

3.3 Avanço temporal na simulação numérica

O avanço temporal na simulação determina a mudança incremental do tempo na qual as equações que modelam a simulação estão sendo resolvidas. A convergência da simulação de propagação da onda depende de um avanço temporal que permita o maior número possível de coeficientes positivos na equação da onda discretizada (MALISKA, 2017). Dessa forma, propõe-se uma relação para a determinação do avanço temporal (MURTA, 2018):

$$\Delta t < \sqrt{\frac{\Delta x_1^2}{v_p^2 + v_s^2}} \quad (3.2)$$

Onde Δx_1 representa a dimensão do elemento de malha na direção x_1 . A relação apresentada pelo equação 3.2 (que pode ser chamada também de condição de Courant–Friedrichs–Lewy, ou número de Courant) indica que o avanço temporal da simulação Δt deve ser menor do que a razão entre o tamanho da malha utilizada e a magnitude da velocidade de propagação da onda ultrassônica. Ou seja, a velocidade da simulação desenvolvida deve ser maior do que a velocidade de propagação da onda ultrassônica. Caso essa relação não seja obedecida, resultados incorretos podem vir a surgir da simulação (COURANT *et al.*, 1928).

Para garantir que Δt será sempre menor do que o termo à direita da inequação, foi imposto que seria tomado 70% do valor total calculado na equação 3.2.

3.4 Estudo do refino de malha

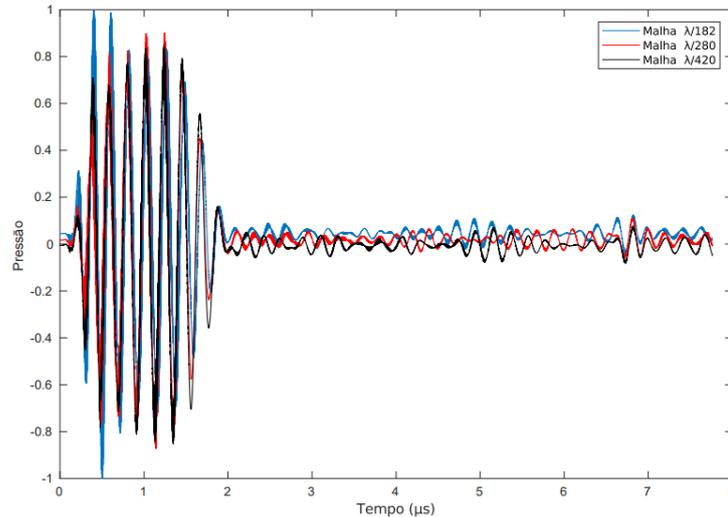
A malha utilizada nas simulações é estruturada e quadrada. A razão do refino da malha partiu do trabalho prévio de (MURTA, 2018), onde a razão $\lambda/140$ foi utilizada na simulação da propagação da onda ultrassônica em material isotrópico.

Como o caso analisado no presente trabalho consiste de material heterogêneo, composto por grãos simulados computacionalmente, uma malha mais refinada que $\lambda/140$ foi necessária para ser possível visualizar melhor o regime de espalhamento. Isso se deve a ordem de grandeza do tamanho médio de grão, que é de milímetros.

Fez-se então o estudo de refino de malha para que fosse selecionada a malha mais adequada. As malhas escolhidas para serem analisadas foram $\lambda/182$, $\lambda/280$ e $\lambda/420$, mode-

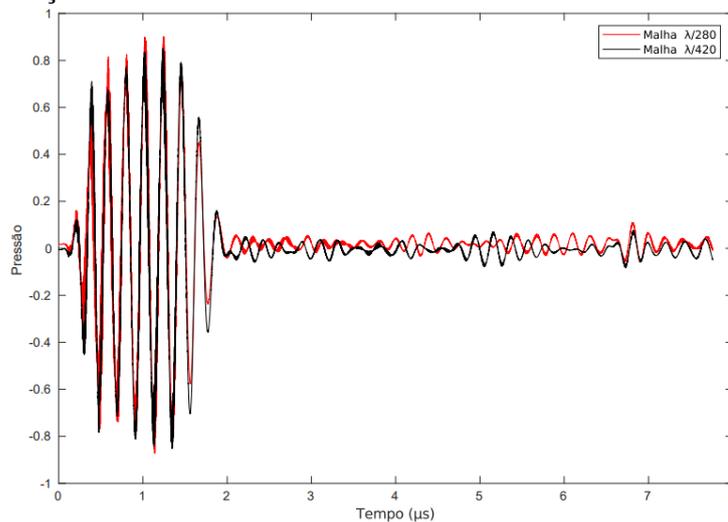
lando a propagação da onda ultrassônica em um material de tamanho médio de grão de 0,337mm de diâmetro, 0,309mm de diâmetro e 0,309mm de diâmetro, respectivamente. Todos esses tamanhos pertencem ao regime de espalhamento de Rayleigh. Os resultados do estudo de refino de malha são visualizados nas figuras 14 e 15.

Figura 14 – Comparação entre malhas



Fonte: o autor

Figura 15 – Comparação entre malhas



Fonte: o autor

Nota-se que nas figuras, quanto maior refino da malha maior a similaridade entre o resultado obtido pela simulação. Tal semelhança pode ser melhor visualizada na figura 15. Além da comparação gráfica apresentada, foi calculado também o erro quadrático médio. Os erros obtidos são mostrados na tabela 2.

A tabela 2 corrobora com a comparação visual mostrada anteriormente: o crescente

Tabela 2 – Comparação dos erros médios quadráticos para as malhas analisadas

Malhas Analisadas	Erro Quadrático Médio
182 e 280	0,0193
182 e 420	0,0251
280 e 420	0,0056

refino da malha resulta em maior erro quando comparado com a malha menos refinada de $\lambda/182$. Quando as malhas mais refinadas são comparadas entre si, o erro obtido é inferior aos demais. Isso mostra que entre a malha $\lambda/280$ e $\lambda/420$ o resultado obtido é muito similar. Após o estudo do refino de malha, optou-se então pela utilização da malha refinada $\lambda/420$.

3.5 Simulação do crescimento de grão pelo modelo de Potts

Para o crescimento de grão, poucos parâmetros são necessários para dar início a sua simulação. Os parâmetros utilizados foram o tamanho da malha $m \times n$, que possui mesmas dimensões da malha utilizada na simulação da propagação da onda ultrassônica; e o número de orientações possíveis para cada grão, Q , que foi determinado como sendo cinco. Isso quer dizer que a simulação do crescimento do grão considerará cinco grãos diferentes durante sua execução. A simulação do crescimento é executada até que sejam obtidos os tamanhos médios de grãos desejados, onde uma matriz numérica contendo os valores de orientação dos grãos é gerada.

3.6 Algoritmos de reconhecimento de padrões

Os algoritmos utilizados no presente trabalho são do tipo supervisionado. Assim, é necessário que sejam dadas aos algoritmos informações prévias sobre os conjuntos de dados a serem analisados para que possa ser realizado treinamento do algoritmo e, em seguida, testá-lo.

3.6.1 Transformada de Karhunen-Loève

Primeiramente, um pré-processamento dos conjuntos de dados obtidos foi realizado utilizando-se DFA. Logo após, a fase de treinamento foi iniciada utilizando 80% dos dados de cada conjunto, onde os dados utilizados foram selecionados de forma aleatória. O teste do algoritmo foi então realizado utilizando os outros 20% restantes.

Como mencionado anteriormente, a KLT realiza o agrupamento dos dados de acordo com suas características em comum dispostos em um plano formado pelas componentes principais, não chegando a classificá-los. A parte da classificação dos dados foi realizada utilizando o

algoritmo da regra da média da classe mais próxima.

O procedimento de treinamento, teste e classificação dos dados foi determinado de ser realizado 100 vezes para cada conjunto de dados, com a finalidade de serem reduzidos possíveis erros gerados pela escolha de algum conjunto dado específico, além de melhorar a precisão dos resultados.

3.6.2 *Redes neurais artificiais*

Para o algoritmo de redes neurais, houve também, primeiramente, o pré-processamento dos dados obtidos por DFA. Em seguida, a fase de treinamento do algoritmo utilizando 80% dos dados escolhidos aleatoriamente foi iniciada, além da conseguinte fase de teste.

Diferentemente da KLT, o algoritmo de redes neurais artificiais é capaz de realizar a classificação dos sinais analisados. Novamente, o processo de treinamento, teste e classificação foi repetido 100 vezes para cada conjunto de dados.

4 RESULTADOS

4.1 Resultados da simulação do crescimento de grão

4.1.1 Determinação do tamanho médio do grão

Terminada a simulação de crescimento de grão, foi realizada em seguida a determinação do tamanho médio gerado. O resultado obtido da simulação do crescimento de grão é uma matriz numérica com números inteiros representando a orientação do grão. Utilizando o *software* MatLab, foi atribuída a cada uma das orientações cores dentro de uma escala de cinza, tornando possível a visualização dos grãos. Em seguida, foi utilizado o *software* de processamento de imagens ImageJ. Com as funções disponíveis no programa, foi possível determinar a área média gerada pela simulação do crescimento do grão, para o MCS desejado. Em seguida, tendo sido considerado o grão como tendo forma circular, foi calculado então o seu diâmetro médio, que é a dimensão utilizada para determinar o tamanho médio do grão e, conseqüentemente, o regime de espalhamento atuante.

No presente trabalho, foram escolhidos três tamanhos médios de grãos que pudessem representar os regimes de espalhamentos que são mostrados na tabela 3. O tamanho médio de grão é mostrado em função do comprimento de onda, λ que tem valor de $1,18mm$.

Tabela 3 – Regime de espalhamento em função do tamanho médio de grão

Tamanho de grão simulado	Regime de espalhamento
$\lambda/5$	Rayleigh
λ	Estocástico
2λ	Geométrico

4.1.2 Atribuição da densidade aos grãos simulados

Como dito anteriormente, foram determinadas cinco orientações possíveis para os grãos. Para cada orientação, foi imposto arbitrariamente um leve desvio no valor de densidade determinado para o aço carbono modelado. A densidade atribuída para cada orientação foi determinada segundo a equação 4.1.

$$D_g = D_a + \left[\frac{(Q_g - 3) \times 2,5}{100} \right] \times D_a \quad (4.1)$$

Onde D_g é a densidade atribuída a orientação do grão; D_a é a densidade do aço carbono e Q_g é a orientação do grão, que pode ter valores de 1 a 5. Na tabela 4, são mostrados os valores de densidade para cada orientação.

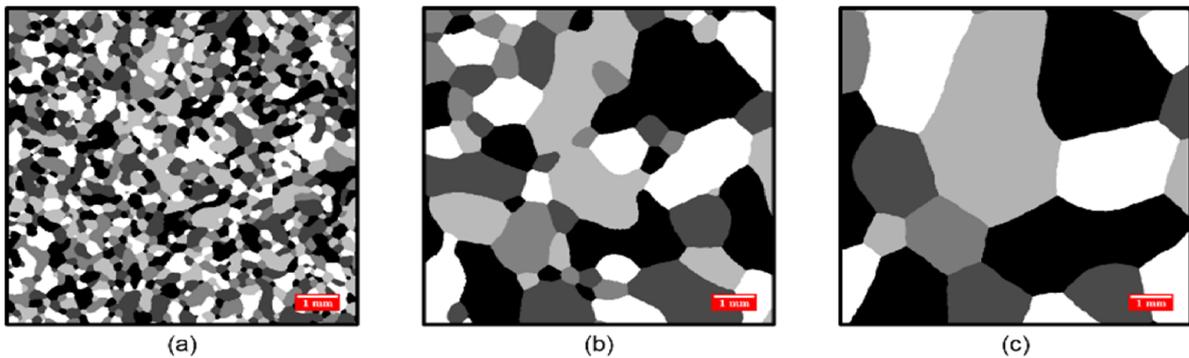
Tabela 4 – Valores de densidades atribuídos para cada orientação de grão simulado

Orientação	1	2	3	4	5
Densidade (kg/m^3)	7410	7605	7800	7995	8190

4.1.3 Visualização dos resultados do crescimento de grão

A figura 16 mostra visualmente três tamanhos médios indicados pela tabela 3, obtidos através da simulação do crescimento de grão.

Figura 16 – Resultados obtidos através da simulação do crescimento de grãos



Fonte: o autor

A figura 16 foi tomada para uma mesma região da matriz obtida após o crescimento de grão. Cada uma das imagens foi tomada em diferentes MCS, onde maior o MCS maior o tamanho médio do grão simulado. Cada uma das cinco cores em escala de cinza representa uma das cinco orientações de grão possíveis que foram determinadas na simulação.

A imagem (a) representa o tamanho médio de 0,2905mm ($\lambda/5$), tamanho esse alcançado após 4000 MCS. A imagem (b) mostra um tamanho médio de grão de 1,1876mm (λ), que foi obtido após 79000 MCS. Por fim, a imagem (c) é o resultado obtido para o tamanho médio de 2,0955mm (2λ) alcançado após 415000 MCS.

Além dos resultados mostrados na figura 16, foram também simulados tamanhos médios de grãos próximos dos apresentados na tabela 3. Ou seja, para o regime de espalhamento de Rayleigh, foram gerados além do tamanho médio $\lambda/5$ outros dois tamanhos médios de grãos

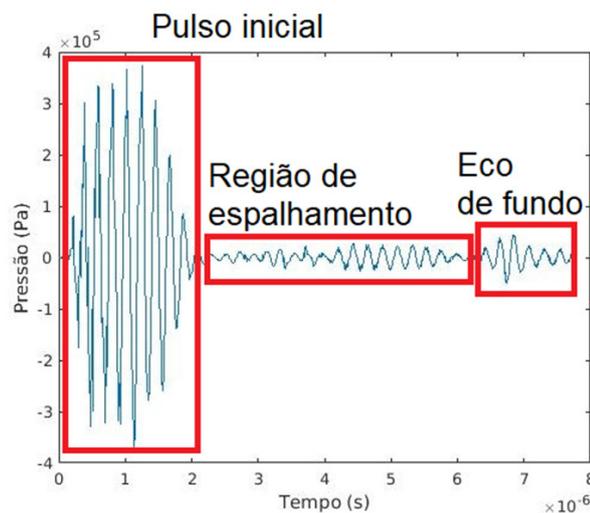
próximos desse valor, sendo um deles um pouco maior e outro um pouco menor. No caso do tamanho médio obtido com 4000 MCS, os outros tamanhos simulados foram 3000 MCS e 5000 MCS; para o tamanho médio obtido com 79000 MCS, foram simulados também tamanhos de 78000 MCS e 81000 MCS; por fim, além do tamanho médio obtido com 415000 MCS, foram simulados tamanhos de 405000 MCS e 425000 MCS. Desse modo, para cada regime de espalhamento há um total de 9 tamanhos médios de grãos.

Ainda, para cada um dos 9 tamanhos médios mencionados anteriormente, foi realizado o espelhamento da matriz contendo os grãos. Espelhamentos vertical, horizontal e misto (misturando os espelhamentos vertical e horizontal simultaneamente) foram feitos, totalizando no final 12 tamanhos médios de grão para cada regime de espalhamento, contando também com a matriz original.

4.2 Resultados da simulação da propagação da onda ultrassônica

Tendo os grãos sido simulados, eles então foram implementados na simulação de propagação da onda ultrassônica para modelar um material heterogêneo. A figura 17 mostra a representação gráfica de um dos sinais obtidos pela simulação.

Figura 17 – Resultado do sinal obtido para a simulação de propagação da onda ultrassônica



Fonte: o autor

Na figura 17 é possível distinguir três regiões: pulso inicial, região de espalhamento e eco de fundo. Na região de pulso inicial, há presente o sinal primeiramente gerado pela vibração dos cristais piezoelétricos, que é justamente o sinal do pulso inicial como modelado pela equação 2.27, justificando assim sua aparição antes das demais regiões.

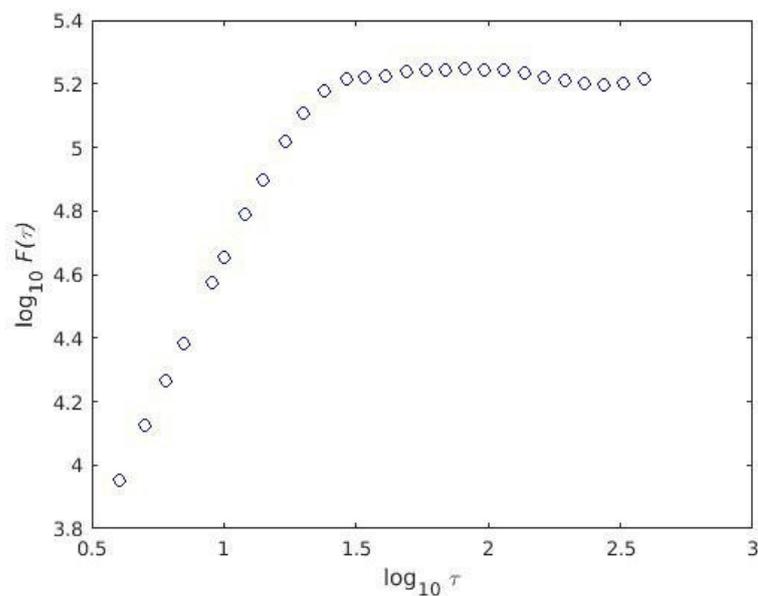
Em seguida, há a região de espalhamento da onda ultrassônica. Essa região representa o comportamento da onda ultrassônica quando sujeita a um material heterogêneo, causando assim seu espalhamento. Caso a situação simulada fosse somente um material isotrópico sem variação de sua densidade ao longo de seu corpo, a região de espalhamento da onda teria forma mais linear do que a apresentada na figura 17. Essa região intermediária entre o pulso inicial e o eco de fundo, dependendo do caso estudado, pode apresentar, também, sinal indicando presença de discontinuidades na peça (MURTA *et al.*, 2018).

Por fim, a última região é a de eco de fundo. Essa região representa o sinal ultrassônico capturado pelo transdutor após a propagação e reflexão da onda ultrassônica na superfície inferior do modelo simulado. Este é então o percurso de maior extensão percorrido pela onda ultrassônica, fazendo assim com que essa região seja a última a ser registrada pelo transdutor.

4.3 Resultados da análise de flutuação sem tendência

Os sinais obtidos das simulações de propagação de onda ultrassônica foram então submetidos a análise de tendência sem flutuação (DFA, em inglês). A figura 18 representa um exemplo de gráfico logarítmico entre a flutuação $F(\tau)$ e o tamanho do intervalo, τ .

Figura 18 – Gráfico obtido pela análise DFA para os dados



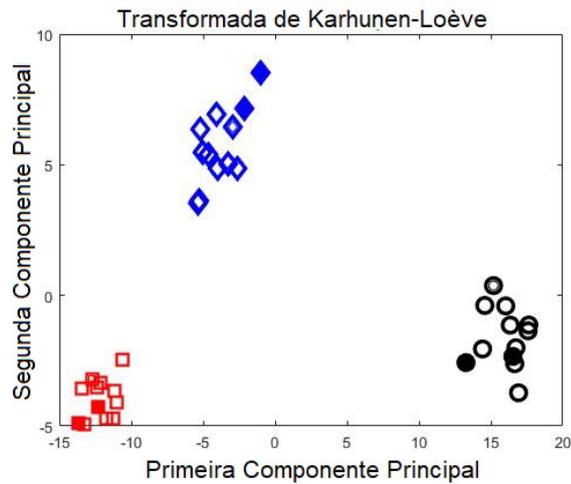
Fonte: o autor

A partir da figura 18, percebe-se que não há mais mudança significativa da flutuação para um intervalo aproximado de $\log_{10} \tau = 1,5$.

4.4 Resultados do agrupamento e classificação pelo algoritmo da transformada de Karhunen-Loève

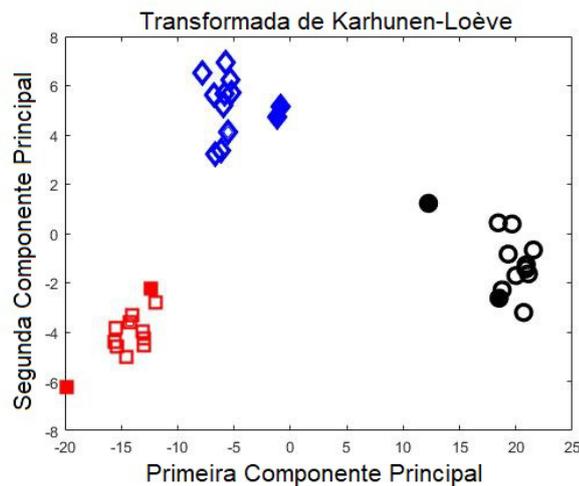
O resultado obtido para o agrupamento dos dados através do algoritmo da transformada KL são mostrados a seguir.

Figura 19 – Representação gráfica do agrupamento de sinais ultrassônicos feito pela transformada KL



Fonte: o autor

Figura 20 – Representação gráfica do agrupamento de sinais ultrassônicos feito pela transformada KL



Fonte: o autor

Como dito anteriormente, o algoritmo KLT foi executado 100 vezes, onde cada execução pode gerar uma imagem como as mostradas nas figuras 20 e 19. Optou-se, porém, mostrar apenas duas imagens das 100 possíveis.

Em ambas figuras 19 e 20, os marcadores círculos pretos representam o tamanho médio de $\lambda/5$; os quadrados vermelhos representam o conjunto de dados para tamanho médio de λ ; e os losangos azuis representam o tamanho médio de 2λ . As geometrias preenchidas representam os dados utilizados na fase de teste do algoritmo.

Em ambas figuras 19 e 20, nota-se uma boa separação entre os conjuntos de dados analisados. O que indica que houve boa distinção entre os dados dos regimes de espalhamento simulados agrupados pelo algoritmo.

As matrizes de confusão geradas pelo algoritmo KLT na classificação dos dados são mostradas nas tabelas 5 e 6. As matrizes de confusão mostram a taxa de acerto médio percentual para a classificação dos dados analisados após executar 100 vezes o algoritmo. Os valores presentes na diagonal principal das matrizes representam a porcentagem de acerto da classe que foi corretamente classificada, enquanto os demais valores representam a taxa de classificação errada, ou confusão, para cada classe. Os valores entre parênteses representam o desvio padrão do valor percentual médio obtido. Foram usados 80% dos dados na fase de treino, escolhidos de forma aleatória. Os 20% dos dados restantes foram utilizados na fase de teste.

Tabela 5 – Matriz de confusão média para os dados de treino obtida pela classificação com KLT

	Conjunto $\lambda/5$	Conjunto λ	Conjunto 2λ
Conjunto $\lambda/5$	100 (0)	0	0
Conjunto λ	0	100 (0)	0
Conjunto 2λ	0	0	100 (0)
Taxa média de acerto: 100%			

Tabela 6 – Matriz de confusão média para os dados de teste obtida pela classificação com KLT

	Conjunto $\lambda/5$	Conjunto λ	Conjunto 2λ
Conjunto $\lambda/5$	96,50 (12,76)	0	0
Conjunto λ	0	100 (0)	4,00
Conjunto 2λ	3,50	0	96,00 (13,56)
Taxa média de acerto: 97,50%			

A tabela referente aos dados de treinamento mostrou que o algoritmo obteve 100% de

acerto. Na fase de teste, há presença de confusão na classificação do algoritmo. No conjunto $\lambda/5$, 96,50% dos dados foram classificados corretamente, enquanto 4,00% foram classificados como pertencentes ao conjunto 2λ . Os conjuntos $\lambda/5$ e 2λ , representando os regimes de espalhamento de Rayleigh e geométrico respectivamente, são regimes bastante diferentes entre si, sendo de fato extremos opostos do gráfico mostrado na figura 7. Dessa forma, a confusão mostrada entre esses dois grupos é inesperada.

O conjunto λ foi classificado corretamente em 100% das vezes.

Por fim, o conjunto 2λ apresentou confusão com o conjunto λ . Dessa vez, a confusão mostrada na classificação do algoritmo é plausível, já que estes conjuntos possuem tamanhos médios mais próximos entre si, além de o regime de espalhamento estocástico representado pelo conjunto λ ser uma região de transição entre os espalhamentos de Rayleigh e geométrico. A taxa média de acerto obtida foi de 97,50%.

4.5 Resultados da classificação pelo algoritmo de redes neurais

A seguir, as matrizes de confusão obtidas pela classificação dos dados através do uso de redes neurais é apresentada. Novamente, houve primeiramente a fase de treinamento utilizando 80% dos dados escolhidos aleatoriamente, seguido da fase de teste com os 20% restantes. O algoritmo foi executado 100 vezes.

Tabela 7 – Matriz de confusão média para os dados de treino obtida pela classificação com redes neurais

	Conjunto $\lambda/5$	Conjunto λ	Conjunto 2λ
Conjunto $\lambda/5$	100 (0)	0	0
Conjunto λ	0	100 (0)	0
Conjunto 2λ	0	0	100 (0)
Taxa média de acerto: 100%			

Novamente, para a fase de treinamento houve uma taxa de acerto de 100%, tendo classificado perfeitamente todas as classes.

Na fase de teste, por sua vez, há a presença de classificações erradas entre as classes analisadas. A rede neural classificou sem erros o conjunto $\lambda/5$, não apresentando nenhuma confusão com o conjunto 2λ , como mostrado na tabela 8.

Tabela 8 – Matriz de confusão média para os dados de teste obtida pela classificação com redes neurais

	Conjunto $\lambda/5$	Conjunto λ	Conjunto 2λ
Conjunto $\lambda/5$	100 (0)	0	0
Conjunto λ	0	92,00 (18,33)	6,50
Conjunto 2λ	0	8,00	93,50 (16,81)
Taxa média de acerto: 95,16%			

Apesar de apresentar uma taxa média de acerto um pouco menor, a rede neural exibe confusões mais óbvias. O conjunto λ foi classificado 8,00% das vezes como pertencendo ao conjunto 2λ . Essa confusão é similar a apresentada anteriormente, sendo a justificativa de sua ocorrência, novamente, a proximidade entre os tamanhos médios e dos regimes de espalhamentos representados por estes conjuntos. Finalmente, houve de novo confusão na classificação entre os conjuntos 2λ e λ , onde 93,50% dos dados foram classificados corretamente como pertencentes ao conjunto 2λ , sendo esta ocorrência já justificada anteriormente. A taxa média de acerto obtida para esse classificador foi de 95,16%.

5 CONCLUSÃO

As matrizes de confusão mostradas nas tabelas 6 e 8 mostram resultados de taxa média de acerto de 97,50% e 95,16%, respectivamente. Tais valores são considerados satisfatórios considerando o propósito do estudo desenvolvido no presente trabalho. Essas taxas médias de acerto, juntamente com os exemplos de agrupamento das classes mostrados pelas figuras 19 e 20, permite assumir que foram obtidos classes bem distintas entre si, sendo cada classe referente a um meio heterogêneo onde no qual há presença de regime de espalhamento da onda ultrassônica. Essa boa distinção entre as classes simuladas deve-se ao sucesso da simulação do crescimento do grão, como observado na figura 16.

Pode-se afirmar, então, que as simulações de propagação da onda ultrassônica em meios heterogêneos juntamente com a simulação do crescimento de grão, propostas neste trabalho, foram realizadas com êxito, proporcionando resultados que permitem o avanço da tecnologia dos ensaios não destrutivos, principalmente no desenvolvimento de simulações de ensaios não destrutivos por ultrassom. Desse modo, os resultados simulados podem se tornar gradativamente mais verossímeis com resultados obtidos em ensaios reais.

REFERÊNCIAS

- AMERICAN SOCIETY FOR METALS. **ASM Handbook: Nondestructive Evaluation and Quality Control**. 9. ed. [S.l.]: ASM International, 1992. v. 17.
- ANCELME, R. L. **APLICAÇÃO DA MIGRAÇÃO REVERSA NO TEMPO PARA ANÁLISE DE AVA EM MEIOS COMPLEXOS**. 2011. 159 f. Dissertação (Mestrado em Engenharia Civil) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Ceará, Rio de Janeiro, 2011.
- ANDERSON, M.; SROLOVITZ, D.; GREY, G.; SAHNI, P. Computer simulation of grain growth—i. kinetics. **Acta metallurgica**, Elsevier, v. 32, n. 5, p. 783–791, 1984.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. Nova Iorque: Springer, 2006.
- BLIKSTEIN, P.; TSCHIPTSCHIN, A. P. Monte carlo simulation of grain growth. **Materials Research**, SciELO Brasil, v. 2, n. 3, p. 133–137, 1999.
- BRASIL ESCOLA. **O que é neurônio?** 2018. Disponível em: <<https://www.brasilecola.uol.com.br/o-que-e/biologia/o-que-e-neuronio.htm>>. Acesso em: 02 Out. 2018.
- CAMURÇA, P. J. **SIMULAÇÃO DO ENSAIO ULTRASSÔNICO PELA TÉCNICA TOFD UTILIZANDO O MÉTODO DOS VOLUMES FINITOS**. 2014. 97 f. Dissertação (Mestrado em Engenharia Engenharia e Ciência de Materiais) — Centro de Tecnologia, Programa de Pós-Graduação em Engenharia e Ciência de Materiais: Propriedades Físicas e Mecânicas dos Materiais, Universidade Federal do Ceará, Fortaleza, 2014.
- CATUNDA, C. E. G. **IMPLEMENTAÇÃO DA MODELAGEM ELÁSTICA PARA DETECÇÃO DE DEFEITOS POR ULTRA-SOM EM JUNTAS SOLDADAS DISSIMILARES**. 2004. 155 f. Dissertação (Mestrado em Engenharia Metalúrgica e de Materiais) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Programa de Pós-Graduação em Engenharia Metalúrgica e de Materiais, Universidade Federal do Ceará, Rio de Janeiro, 2004.
- CERJAN, C.; KOSLOFF, D.; KOSLOFF, R.; RESHEF, M. A nonreflecting boundary condition for discrete acoustic and elastic wave equations. **Geophysics**, Society of Exploration Geophysicists, v. 50, n. 4, p. 705–708, 1985.
- COURANT, R.; FRIEDRICHS, K.; LEWY, H. Über die partiellen differenzgleichungen der mathematischen physik. **Mathematische annalen**, Springer, v. 100, n. 1, p. 32–74, 1928.
- GURNEY, K. **An introduction to neural networks**. [S.l.]: UCL Press, 2004.
- HALLIDAY, D.; RESNICK, R.; WALKER, J. Fundamentos de física: gravitação, ondas e termodinâmica. Livros Técnicos e Científicos, Rio de Janeiro, v. 2, 2009.
- HAYKIN, S. S. **Neural networks and learning machines**. [S.l.]: Pearson, 2009. v. 3.
- HU, K.; IVANOV, P. C.; CHEN, Z.; CARPENA, P.; STANLEY, H. E. Effect of trends on detrended fluctuation analysis. **Physical Review E**, APS, v. 64, n. 1, p. 011114, 2001.
- HUA, Y.; LIU, W. Generalized karhunen-loeve transform. **IEEE Signal Processing Letters**, IEEE, v. 5, n. 6, p. 141–142, 1998.

- HULL, B.; JOHN, V. **Non-destructive testing**. Londres: Macmillian Education, 1988.
- KITTLER, J.; YOUNG, P. C. A new approach to feature selection based on the karhunen-loeve expansion. **Pattern recognition**, Elsevier, v. 5, n. 4, p. 335–352, 1973.
- KOLDITZ, O. **Computational methods in environmental fluid mechanics**. [S.l.]: Springer, 2002.
- LANDAU, L.; LIFSHITZ, E. **Theory of Elasticity**. Bristol: Pergamon Press, 1970.
- LORD, W.; LUDWIG, R.; YOU, Z. Developments in ultrasonic modeling with finite element analysis. **Journal of nondestructive evaluation**, Springer, v. 9, n. 2-3, p. 129–143, 1990.
- LUDWIG, R.; LORD, W. Developments in the finite element modeling of ultrasonic ndt phenomena. Springer, p. 73–81, 1986.
- MALISKA, C. R. **Transferência de calor e mecânica dos fluidos computacional**. [S.l.]: Grupo Gen-LTC, 2017.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.
- MOURA, E. P. D.; VIEIRA, A.; IRMAO, M.; SILVA, A. Applications of detrended-fluctuation analysis to gearbox fault diagnosis. **Mechanical Systems and Signal Processing**, Elsevier, v. 23, n. 3, p. 682–689, 2009.
- MURTA, R. H. F. **RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM UTILIZANDO CLASSIFICADORES TREINADOS COM SINAIS ULTRASSÔNICOS SIMULADOS NUMERICAMENTE**. 2018. 103 f. Dissertação (Mestrado em Engenharia e Ciência de Materiais) — Centro de Tecnologia, Programa de Pós-Graduação em Engenharia e Ciência de Materiais: Propriedades Físicas e Mecânicas dos Materiais, Universidade Federal do Ceará, Fortaleza, 2018.
- MURTA, R. H. F.; VIEIRA, F. d. A.; SANTOS, V. O.; MOURA, E. P. D. Welding defect classification from simulated ultrasonic signals. **Journal of Nondestructive Evaluation**, Springer, v. 37, n. 3, p. 40, 2018.
- NYE, J. F.; LINDSAY, R. Physical properties of crystals. **Physics Today**, v. 10, p. 26, 1957.
- PATANKAR, S. **Numerical heat transfer and fluid flow**. [S.l.]: Taylor & Francis, 1980.
- PENG, C.-K.; BULDYREV, S. V.; HAVLIN, S.; SIMONS, M.; STANLEY, H. E.; GOLDBERGER, A. L. Mosaic organization of dna nucleotides. **Physical review e**, APS, v. 49, n. 2, p. 1685, 1994.
- REYNOLDS, A. C. Boundary conditions for the numerical solution of wave propagation problems. **Geophysics**, Society of Exploration Geophysicists, v. 43, n. 6, p. 1099–1110, 1978.
- ROSE, J. L. **Ultrasonic guided waves in solid media**. Nova Iorque: Cambridge university press, 2014.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, Nature Publishing Group, v. 323, n. 6088, p. 533, 1986.

RYCHLEWSKI, J. On hooke's law. **Journal of Applied Mathematics and Mechanics**, Elsevier, v. 48, n. 3, p. 303–314, 1984.

SANTIN, J. L. **Ultra-som: técnica e aplicação**. [S.l.]: Artes Gráficas e Editora Unificado, 2003.

SERWAY, R.; JEWETT JR., J. W. **Princípios de Física: oscilações, ondas e termodinâmica**. 5. ed. São Paulo: Cengage Learning, 2014. v. 2.

SHULL, P. J. **Nondestructive evaluation: theory, techniques, and applications**. Nova Iorque: Marcel Dekker Inc., 2002.

SILVERTHORN, D. U. **Fisiologia humana: uma abordagem integrada**. [S.l.]: Artmed editora, 2010.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. San Diego: Elsevier, 2008.

THOMSEN, L. Weak elastic anisotropy. **Geophysics**, Society of Exploration Geophysicists, v. 51, n. 10, p. 1954–1966, 1986.

VIEIRA, A.; MOURA, E. P. D.; GONÇALVES, L. L.; REBELLO, J. Characterization of welding defects by fractal analysis of ultrasonic signals. **Chaos, Solitons & Fractals**, Elsevier, v. 38, n. 3, p. 748–754, 2008.

VOIGT, W. **Lehrbuch der kristallphysik (mit ausschluss der kristalloptik)**. [S.l.]: Springer-Verlag, 1910.

WEBB, A. R. **Statistical pattern recognition**. Chichester: John Wiley & Sons, 2003.

WOOH, S.-C.; SHI, Y. A simulation study of the beam steering characteristics for linear phased arrays. **Journal of nondestructive evaluation**, Springer, v. 18, n. 2, p. 39–57, 1999.