



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA E CIÊNCIA DE MATERIAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA E CIÊNCIA DE
MATERIAIS

RAPHAELLA HERMONT FONSECA MURTA

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM UTILIZANDO
CLASSIFICADORES TREINADOS COM SINAIS ULTRASSÔNICOS SIMULADOS
NUMERICAMENTE

FORTALEZA

2018

RAPHAELLA HERMONT FONSECA MURTA

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM UTILIZANDO
CLASSIFICADORES TREINADOS COM SINAIS ULTRASSÔNICOS SIMULADOS
NUMERICAMENTE

Dissertação apresentada ao Curso de Programa de Pós-Graduação em Engenharia e Ciência de Materiais do Departamento de Engenharia e Ciência de Materiais do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia e Ciência de Materiais. Área de Concentração: Propriedades físicas e mecânicas dos materiais

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)

M965r Murta, Raphaella.

Reconhecimento de defeitos de padrões de soldagem utilizando classificadores treinados com sinais ultrassônicos simulados numericamente / Raphaella Murta. – 2018.

102 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia e Ciência de Materiais, Fortaleza, 2018.

Orientação: Prof. Dr. Elineudo Pinho de Moura.

1. Ultrassom. 2. MVF. 3. Defeitos de soldagem. 4. Redes neurais artificiais. 5. K-NN. I.
Título.

CDD 620.11

RAPHAELLA HERMONT FONSECA MURTA

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM UTILIZANDO
CLASSIFICADORES TREINADOS COM SINAIS ULTRASSÔNICOS SIMULADOS
NUMERICAMENTE

Dissertação apresentada ao Curso de Programa de Pós-Graduação em Engenharia e Ciência de Materiais do Departamento de Engenharia e Ciência de Materiais do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia e Ciência de Materiais. Área de Concentração: Propriedades físicas e mecânicas dos materiais

Aprovada em: 26/01/2018

BANCA EXAMINADORA

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

Prof. Francisco Marcondes; D. Sc.
Universidade Federal do Ceará (UFC)

Prof. André de Pinho Vieira; D. Sc.
Universidade de São Paulo (USP)

Prof. Filipe Francisco Rocha Damasceno; M.Sc.
Universidade Federal do Ceará (UFC)

A Deus.

A minha família.

AGRADECIMENTOS

Aos meus pais, Ana Lúcia Fonseca e Breno Murta, pelo amor, incentivo e apoio incondicional.

Ao meu orientador, Professor Dr. Elineudo Pinho de Moura, pela oportunidade e apoio no desenvolvimento deste trabalho.

Aos integrantes do Centro de Ensaios não Destrutivos - CENDE/UFC, em especial Flávison de Almada e Victor Oliveira pela participação na elaboração desta pesquisa.

Aos meus professores, em especial Francisco Marcondes, pelo incentivo e colaboração.

A minha família, em especial Arthur Murta e Otílio Freire, pelo apoio e companheirismo.

Aos meus amigos, Auxiliadora Almeida, Isabelle Maria, Larissa Almeida, Nadja Nogueira e Thiago Andrade, por se fazerem presentes na minha vida.

Aos meus colegas de curso, em especial Úrsula Cid, Aldecira Gadelha, Vinicius Oliveira, Giovani Gonçalves e Pablo Leão, pela amizade, paciência e convivência durante o mestrado.

A todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

”Uma teoria matemática não deve ser considerada completa, até que você a tenha deixado tão clara, de modo que pode ser explicada para o primeiro homem que você encontrar na rua.”

(DAVID HILBERT)

RESUMO

O ensaio não destrutivo por ultrassom é amplamente utilizado para detectar e dimensionar discontinuidades presentes no interior de materiais. Entre as técnicas ultrassônicas existentes, a técnica do tempo de percurso da onda difratada (TOFD - *Time Of Flight Diffraction* [do inglês]) vem sendo cada vez mais empregada na inspeção de juntas de solda por apresentar alta velocidade de inspeção e alta confiabilidade no dimensionamento. Entretanto, a classificação do tipo de descontinuidade a partir dos sinais ultrassônicos obtidos durante uma inspeção requer um profissional altamente capacitado. Esta tarefa pode ser realizada por algoritmos de reconhecimento de padrões, capazes de processar rapidamente uma grande quantidade de dados. Nesse trabalho, foram modelados meios bidimensionais contendo três diferentes tipos de descontinuidades comumente encontradas em juntas soldadas: falta de penetração, poro e trinca. Em seguida, utilizando-se o método de volumes finitos (MVF), foram realizadas simulações de propagação de ondas mecânicas nos meios modelados, reproduzindo o ensaio ultrassônico pela técnica TOFD. Os sinais ultrassônicos simulados foram pré-processados, e submetidos à algoritmos de reconhecimento de padrões (K-NN - K-vizinhos mais próximos, Redes neurais artificiais e K-médias). Esse estudo é um passo inicial para o emprego de simulação numérica do ensaio ultrassônico em meios contendo descontinuidades modeladas, visando a produção dos sinais simulados que possam ser utilizados no treinamento de ferramentas de reconhecimento de padrões e, posteriormente, na classificação de defeitos de soldagem a partir de sinais capturados experimentalmente.

Palavras-chave: Ultrassom. TOFD. Simulação. MVF. Defeitos de soldagem. K-NN. Redes neurais artificiais. K-médias.

ABSTRACT

Non-destructive evaluation based on ultrasound propagation is widely used to detect and to size up discontinuities. Time of Flight Diffraction (TOFD), an ultrasonic technique, has been increasingly used in welding joints inspections due to quick inspection and reliability. However, the classification of the kind of discontinuity from the ultrasound signals acquired during an inspection requires a high skilled professional. This task can be done by using pattern recognition algorithms, which are able to quickly process a great amount of data. In this present work, three types of discontinuities usually found in welding joint (lack of penetration, porosity and crack) were embedded in a bidimensional modelated media. Following, the finite volume method (FVM) was used to simulating wave propagation in the modelated media, mimicking the ultrasonic testing. Simulated ultrasonic signals were pre processed and submitted to pattern recognition algorithms (K-Nearest Neighbors, Artificial neural networks e K-means). This work aims to evaluate the use of simulated signals during the training stage of pattern recognition tools which will be used to classify signals acquired during welded joints inspections.

Keywords: Ultrasound. TOFD. Simulation. FVM. Welding defects. K-NN. Artificial neural network. K-means.

LISTA DE FIGURAS

Figura 1 – Representação de uma descontinuidade do tipo falta de penetração	22
Figura 2 – Representação de uma descontinuidade do tipo poro	23
Figura 3 – Representação de uma descontinuidade do tipo trinca	24
Figura 4 – Representação esquemática da técnica TOFD	25
Figura 5 – Direcionamento do feixe ultrassônico	26
Figura 6 – Representação do <i>Phased Array</i>	27
Figura 7 – Direcionamento do feixe com a variação do número de cristais piezoelétricos. 28	
Figura 8 – Representação esquemática das condições de contorno do material	33
Figura 9 – Esquematização da malha bidimensional	36
Figura 10 – Representação dos dados antes e depois do PCA.	44
Figura 11 – Exemplo da técnica K-NN	45
Figura 12 – Mudança no mapeamento de regiões com a variação do k.....	46
Figura 13 – Modelo matemático de um neurônio artificial.....	47
Figura 14 – Modelo matemático de um neurônio artificial.....	48
Figura 15 – Representação do funcionamento do k-médias	50
Figura 16 – Distância entre os transdutores na técnica TOFD	52
Figura 17 – Estudo do refino de malha	54
Figura 18 – Representação esquemática de uma descontinuidade do tipo Falta de Penetração	55
Figura 19 – Representação esquemática do posicionamento das descontinuidades do tipo Poro.....	56
Figura 20 – Representação esquemática de uma descontinuidade do tipo Poro	56
Figura 21 – Representação esquemática do posicionamento das descontinuidades do tipo Trinca	57
Figura 22 – Representação esquemática de uma descontinuidade do tipo Trinca.....	57
Figura 23 – (a) Sinal simulado, (b) Sinal simulado normalizado e (c) Envoltória do sinal simulado de uma descontinuidade do tipo falta de penetração ($h = 3.0$ mm e l $= 1.0$ mm)	59
Figura 24 – Campo de deslocamento gerado no instante em que a onda encontra uma descontinuidade do tipo falta de penetração ($h = 3,0$ mm e $l = 1,0$ mm).	65
Figura 25 – A-scan gerado por um modelo contendo uma descontinuidade do tipo falta de penetração: (a) sinal simulado e (b) sinal obtido experimentalmente.....	66

Figura 26 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados.	69
Figura 27 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados normalizados.	71
Figura 28 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para a envoltória dos sinais ultrassônicos simulados.	73
Figura 29 – Variação da taxa média de acerto e da proporção de dados simulados representada de acordo com o número de componentes utilizadas.	75
Figura 30 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 15 primeiras componentes principais dos sinais ultrassônicos simulados.	76
Figura 31 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas para $k=1$	77
Figura 32 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados.	79
Figura 33 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas.	80
Figura 34 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 22 primeiras componentes principais para a envoltória dos sinais ultrassônicos simulados.	82
Figura 35 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados e capturados experimentalmente.	84
Figura 36 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados e capturados experimentalmente normalizados.	86
Figura 37 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para a envoltória dos sinais ultrassônicos simulados e capturados experimentalmente.	88
Figura 38 – Variação da taxa média de acerto e da proporção de dados simulados e experimentais representados de acordo com o número de componentes utilizadas.	89
Figura 39 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 9 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados.	90

Figura 40 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas.	91
Figura 41 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 4 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados normalizados.	93
Figura 42 – Variação da taxa média de acerto e da proporção da envoltória dos dados representada de acordo com o número de componentes utilizadas.	94
Figura 43 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 5 primeiras componentes principais da envoltória dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados.	95

LISTA DE TABELAS

Tabela 1 – Propriedades do material	51
Tabela 2 – Parâmetros e dimensões referentes ao transdutor	53
Tabela 3 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais ultrassônicos simulados	68
Tabela 4 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos simulados	69
Tabela 5 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos simulados sugerida pela k-médias	70
Tabela 6 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais ultrassônicos simulados normalizados	70
Tabela 7 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos simulados normalizados	71
Tabela 8 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos simulados normalizados sugerida pela k-médias	72
Tabela 9 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos a envoltória dos sinais ultrassônicos simulados	72
Tabela 10 – Matriz de confusão obtida pelo emprego de redes neurais artificiais a envoltória dos sinais ultrassônicos simulados	73
Tabela 11 – Agrupamento, ou pseudo-classificação, envoltória dos sinais ultrassônicos simulados sugerida pela k-médias	74
Tabela 12 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos às 15 primeiras componentes principais dos sinais ultrassônicos simulados para k=1	74
Tabela 13 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 15 primeiras componentes principais dos sinais ultrassônicos simulados	75
Tabela 14 – Agrupamento, ou pseudo-classificação, das 15 primeiras componentes principais dos sinais ultrassônicos simulados sugerida pela k-médias	77
Tabela 15 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados para k=1	78
Tabela 16 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados	78

Tabela 17 – Agrupamento, ou pseudo-classificação, das 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados sugerida pela k-médias	79
Tabela 18 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados	81
Tabela 19 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados	81
Tabela 20 – Agrupamento, ou pseudo-classificação, das 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados sugerida pela k-médias	82
Tabela 21 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais capturados experimentalmente quando utilizados os sinais simulados na fase de teste para k=1	83
Tabela 22 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos capturados experimentalmente	83
Tabela 23 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias	85
Tabela 24 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais capturados experimentalmente normalizados quando utilizados os sinais simulados normalizados na fase de teste para k=22	85
Tabela 25 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos capturados experimentalmente normalizados	85
Tabela 26 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias	87
Tabela 27 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos a envoltória dos sinais capturados experimentalmente quando utilizados os sinais simulados normalizados na fase de teste para k=1	87
Tabela 28 – Matriz de confusão obtida pelo emprego de redes neurais artificiais a envoltória dos sinais ultrassônicos capturados experimentalmente	87
Tabela 29 – Agrupamento, ou pseudo-classificação, das envoltórias dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias	88

Tabela 30 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 9 primeiras componentes principais dos sinais capturados experimentalmente quando utilizados as 9 primeiras componentes principais aos sinais simulados na fase de teste para k=1	89
Tabela 31 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 9 primeiras componentes principais dos sinais capturados experimentalmente quando utilizados as 9 primeiras componentes principais dos sinais simulados na fase de teste	90
Tabela 32 – Agrupamento, ou pseudo-classificação, das 9 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias	91
Tabela 33 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 4 primeiras componentes principais dos sinais capturados experimentalmente normalizados quando utilizados as 4 primeiras componentes principais aos sinais simulados normalizados na fase de teste para k=3	92
Tabela 34 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 4 primeiras componentes principais dos sinais capturados experimentalmente normalizados quando utilizados as 4 primeiras componentes principais dos sinais simulados normalizados na fase de teste	92
Tabela 35 – Agrupamento, ou pseudo-classificação, das 4 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente normalizados e dos sinais simulados normalizados sugerido pelo k-médias	93
Tabela 36 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 5 primeiras componentes principais das envoltória dos sinais capturados experimentalmente quando utilizados as 5 primeiras componentes principais das envoltórias dos sinais simulados na fase de teste para k=1	94
Tabela 37 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 5 primeiras componentes principais da envoltória dos sinais capturados experimentalmente quando utilizados as 5 primeiras componentes principais da envoltória dos sinais simulados na fase de teste	95

Tabela 38 – Agrupamento, ou pseudo-classificação, das 5 primeiras componentes principais da envoltória dos sinais ultrassônicos capturados experimentalmente e da envoltória dos sinais simulados sugerido pelo k-médias	96
Tabela 39 – Sintetização dos resultados	98

LISTA DE ALGORITMOS

Algoritmo 1 – Análise de Componentes Principais	60
Algoritmo 2 – K-vizinhos mais próximos	61
Algoritmo 3 – Redes Neurais Artificiais	63
Algoritmo 4 – K-médias	64

SUMÁRIO

1	INTRODUÇÃO	19
2	OBJETIVOS	21
2.1	Objetivo geral	21
2.2	Objetivos específicos	21
3	REVISÃO BIBLIOGRÁFICA	22
3.1	Defeitos de Soldagem	22
3.1.1	<i>Falta de Penetração</i>	22
3.1.2	<i>Poros</i>	23
3.1.3	<i>Trinca</i>	23
3.2	Ensaio não destrutivo por ultrassom	24
3.2.1	<i>A técnica Técnica do tempo de percurso da onda difratada (TOFD)</i>	25
3.3	O transdutor <i>Phased Array</i>	26
3.4	Métodos Numéricos	29
3.5	Equação do Movimento	30
3.6	Condições de contorno	32
3.6.1	<i>Superfície livre</i>	33
3.6.2	<i>Bordas não reflexivas</i>	33
3.6.3	<i>Camadas de amortecimento</i>	34
3.6.4	<i>Deslocamento nulo</i>	35
3.7	Obtenção das ondas discretizadas pelo MVF	35
3.7.1	<i>Equação do volume interno do modelo</i>	37
3.7.2	<i>Equação da superfície do modelo</i>	39
3.7.3	<i>Equação das bordas laterais do modelo</i>	40
3.7.4	<i>Equação das regiões próximas as bordas do modelo</i>	41
3.7.5	<i>Equação da extremidade inferior do modelo</i>	41
3.8	Análise de Componentes Principais	41
3.9	Reconhecimento de padrões	44
3.9.1	<i>k-vizinhos mais próximos</i>	44
3.9.2	<i>Redes Neurais Artificiais</i>	46
3.9.3	<i>K-médias</i>	49

4	MATERIAIS E MÉTODOS	51
4.1	Definição de parâmetros do modelo	51
4.2	Definição de parâmetros da fonte	51
4.3	Avanço temporal	53
4.4	Tamanho da malha	54
4.5	Modelagem da descontinuidade	55
4.5.1	<i>Falta de penetração</i>	55
4.5.2	<i>Porosidade</i>	55
4.5.3	<i>Trinca</i>	56
4.6	Sinais capturados experimentalmente	57
4.7	Pré-processamento dos sinais	58
4.8	Análise de Componentes Principais	59
4.9	Reconhecimento de Padrões	60
4.9.1	<i>k-vizinhos mais próximos</i>	60
4.9.2	<i>Redes neurais artificiais</i>	61
4.9.3	<i>k-médias</i>	62
5	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	65
5.1	Simulação	65
5.2	Pré-processamento dos sinais	66
5.3	Reconhecimento de Padrões	67
5.3.1	<i>Sinais ultrassônicos simulados</i>	68
5.3.2	<i>Sinais ultrassônicos simulados normalizados</i>	70
5.3.3	<i>Envoltórias dos sinais ultrassônicos simulados</i>	72
5.3.4	<i>Componentes principais dos sinais ultrassônicos simulados</i>	74
5.3.5	<i>Componentes principais dos sinais ultrassônicos simulados normalizados</i>	77
5.3.6	<i>Componentes principais das envoltórias dos sinais ultrassônicos simulados</i>	80
5.3.7	<i>Sinais ultrassônicos capturados experimentalmente e simulados</i>	82
5.3.8	<i>Sinais ultrassônicos capturados experimentalmente e simulados normalizados</i>	84
5.3.9	<i>Envoltórias dos sinais ultrassônicos capturados experimentalmente e simulados</i>	86

5.3.10	<i>Componentes principais dos sinais ultrassônicos capturados experimentalmente e simulados</i>	88
5.3.11	<i>Componentes principais dos sinais ultrassônicos capturados experimentalmente e simulados normalizados</i>	90
5.3.12	<i>Componentes principais das envoltórias dos sinais ultrassônicos capturados experimentalmente e simulados</i>	93
6	CONCLUSÕES	99
	REFERÊNCIAS	100

1 INTRODUÇÃO

Ensaaios não destrutivos são técnicas aplicadas para detectar a existência de descontinuidades nos materiais sem danificá-los, permitindo, assim, o seu uso posterior. Tais ensaios contribuem para garantir a qualidade do material, prevenir acidentes e reduzir custos.

Líquido penetrante, partículas magnéticas, correntes parasitas e ultrassom são exemplos de ensaios não destrutivos. A escolha da técnica a ser utilizada na inspeção de um material depende de vários fatores, entre eles, as propriedades físicas e metalúrgicas do material inspecionado, o tipo de descontinuidade investigada que está relacionada ao método de fabricação utilizado e o meio em que se encontra o material a ser inspecionado.

Neste trabalho será abordado o ensaio por ultrassom, que permite detectar descontinuidades superficiais e internas e pode ser aplicado a todo tipo de material. O ensaio consiste em propagar ondas mecânicas de alta frequência no interior do material e, caso haja alguma descontinuidade ou encontre a superfície oposta, essas ondas serão refletidas para o sensor piezoelétrico e convertidas em impulsos elétricos. A partir da análise da onda registrada pelo sensor é possível determinar a espessura do material, detectar e dimensionar descontinuidades.

A técnica ultrassônica do tempo de percurso de onda difratada (TOFD - *Time of Flight Diffraction* [do inglês]) vem sendo cada vez mais utilizada em inspeções de juntas de solda, por se tratar de um dos métodos mais confiáveis. Nessa técnica, utiliza-se um par de transdutores ultrassônicos, sendo um o emissor e o outro o receptor, e é baseada nas difrações das ondas ultrassônicas causadas pelas extremidades da descontinuidade presente no interior do cordão de solda.

Entretanto, a classificação do tipo de descontinuidade a partir dos sinais ultrassônicos obtidos durante uma inspeção requer um profissional altamente capacitado e um longo tempo, tendo em vista o volume de dados a serem analisados. Essa tarefa pode ser realizada por algoritmos de aprendizagem de máquinas, que são capazes de classificar rapidamente uma grande quantidade de dados.

Existem duas formas de aprendizado: o supervisionado e o não supervisionado. No aprendizado supervisionado a classificação real dos dados é informada durante a etapa de treinamento, ou seja, exemplos de entrada e respectivas saída desejadas são apresentadas ao algoritmo que procura encontrar uma regra de como as entradas estão relacionadas às saídas. Já no classificador não supervisionado, nenhum tipo de informação é dada ao algoritmo, que procura encontrar a melhor forma de agrupamento de maneira independente. Neste trabalho,

foram utilizados algoritmos de aprendizado supervisionado e não supervisionado (K-vizinhos mais próximos, Redes neurais artificiais e K-médias).

Para que esses algoritmos classifiquem bem as descontinuidades em um material é preciso ter um banco de dados suficientemente grande, que contenha sinais de descontinuidades de diferentes tipos e tamanhos. Uma forma rápida e barata de se obter isso é através da simulação. Neste trabalho, três tipos de defeitos de soldagem foram simulados utilizando o método dos volumes finitos: falta de penetração, poro e trinca.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo deste estudo é avaliar a viabilidade do emprego da simulação numérica do ensaio ultrassônico para produzir sinais para o treinamento de ferramentas de reconhecimento de padrões, posteriormente utilizadas na classificação de sinais capturados durante as inspeções de juntas soldadas.

2.2 Objetivos específicos

1. Modelar meios bidimensionais contendo diferentes tipos de descontinuidades.
2. Utilizar o método de volumes finitos para simular a propagação de ondas ultrassônicas em diversos meios modelados.
3. Produzir um banco de dados com descontinuidades de diferentes tipos e tamanhos, para o treinamento dos algoritmos de reconhecimento de padrão.
4. Avaliar o desempenho de diferentes técnicas de reconhecimento de padrões na classificação dos dados simulados.
5. Avaliar a influência de pré-processamento de sinais (normalização, cálculo de envoltória, etc.) na taxa de acerto na classificação.
6. Avaliar a qualidade da simulação da propagação de ondas e da aprendizagem dos algoritmos de reconhecimento de padrões (realizada com sinais simulados) com a classificação de sinais capturados experimentalmente.

3 REVISÃO BIBLIOGRÁFICA

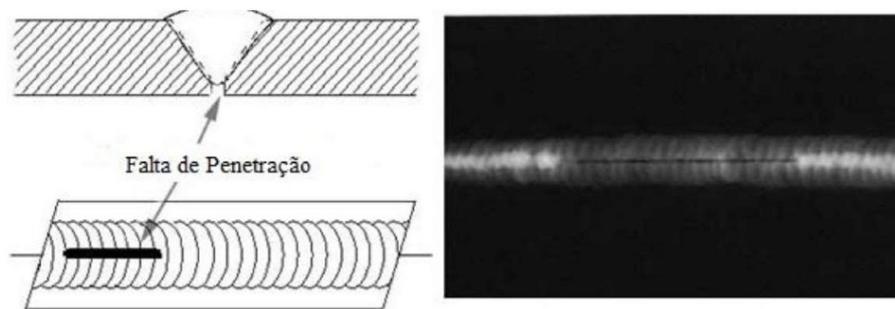
3.1 Defeitos de Soldagem

Descontinuidade é uma interrupção da estrutura típica ou esperada de uma junta soldada, ou seja, a falta de homogeneidade de característica física, mecânica ou metalúrgica do material (BARRA; PEREIRA, 1999). Quando uma descontinuidade compromete o uso de uma peça, para um determinado fim, ela é considerada um defeito e a peça deve ser reparada ou substituída. Três tipos de descontinuidades foram considerados neste trabalho, são elas: falta de penetração, poro e trinca.

3.1.1 Falta de Penetração

Falta de penetração é uma descontinuidade decorrente do preenchimento incompleto da região da raiz de solda com o metal de adição. Isto pode ser decorrente da energia insuficiente do arco para fundir o metal base, da manipulação incorreta do eletrodo ou isolamento da superfície do chanfro de solda. A falta de penetração reduz a seção útil da junta soldada e atua como concentrador de tensões, podendo ser muito prejudicial ao material por facilitar a nucleação e a propagação de trincas. (MODENESI *et al.*, 2005). Este tipo de descontinuidade é ilustrada na figura 1.

Figura 1 – Representação de uma descontinuidade do tipo falta de penetração



Fonte – NDT RESOURCE CENTER (2012).

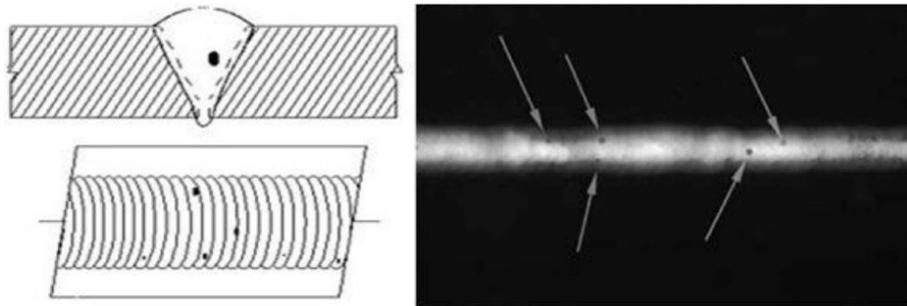
Um projeto adequado e a utilização de um procedimento de soldagem apropriado podem evitar a falta de penetração.

3.1.2 Poro

A descontinuidade do tipo poro é ocasionada pelo aprisionamento de bolhas de gases durante a solidificação do metal (MODENESI *et al.*, 2005). As principais causas desta descontinuidade são procedimentos inadequados de soldagem, variação da composição química entre o metal de base e o metal de adição e a diferença entre a solubilidade do gás nos estados líquido e sólido.

Nem sempre este tipo de descontinuidade é considerada um defeito e, dependendo da quantidade, tamanho e distribuição, ela pode ser aceitável em alguns casos. A representação da descontinuidade do tipo poro está ilustrada na figura 2.

Figura 2 – Representação de uma descontinuidade do tipo poro



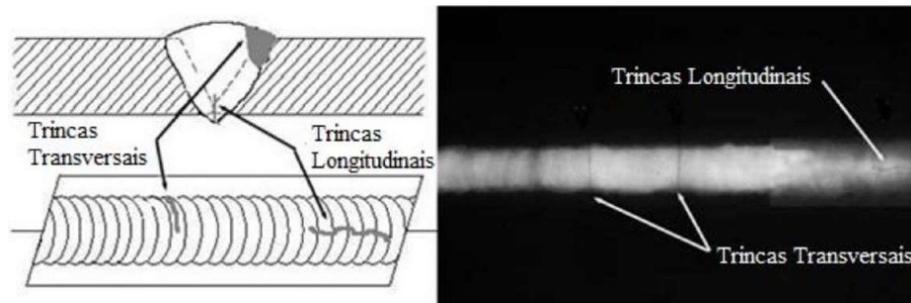
Fonte – NDT RESOURCE CENTER (2012).

3.1.3 Trinca

A trinca é ocasionada pela incapacidade do material em responder às solicitações impostas, localmente, pelas tensões decorrente do processo de soldagem. Por atuar como concentradores de tensão, as trincas são consideradas um dos tipos mais graves de descontinuidades e podem acarretar fratura frágil.

Ela pode ser formada durante a solidificação do material, durante o resfriamento da junta de solda, durante o tratamento térmico para alívio de tensões ou até meses após a soldagem (MODENESI *et al.*, 2005). Desta forma, é importante o uso frequente de técnicas não destrutivas para detectar este tipo de descontinuidade. A figura 3 representa a descontinuidade do tipo trinca.

Figura 3 – Representação de uma descontinuidade do tipo trinca



Fonte – NDT RESOURCE CENTER (2012).

3.2 Ensaio não destrutivo por ultrassom

O ensaio por ultrassom é baseado na geração e propagação de ondas de alta frequência através do material inspecionado. Ao alcançar a interface entre dois meios com impedâncias acústicas diferentes, por exemplo uma descontinuidade ou a superfície oposta, tais ondas são refletidas, podendo alcançar o sensor piezoelétrico e serem registradas. Os sensores, constituídos de cristais com propriedades piezoelétricas, possuem a capacidade de expandir-se ou contrair-se quando submetidos à uma diferença de potencial elétrico, a depender da polaridade. Os cristais possuem ainda a capacidade de produzirem uma diferença de potencial entre suas extremidades quando comprimidos. Desta forma, através da aplicação de um impulso elétrico os cristais se expandem ou se contraem, produzindo ondas que se propagam no interior do material. As ondas ao serem refletidas e atingirem o sensor piezoelétrico expandem ou contraem os cristais do sensor, que transforma essa informação em impulsos elétricos. Informações sobre o tempo do percurso da onda podem então ser obtidos através da análise desses impulsos e, desta forma, torna-se possível a determinação da espessura do material, bem como a detecção e dimensionamento de descontinuidades existentes no material inspecionado (BLITZ; SIMPSON, 1995).

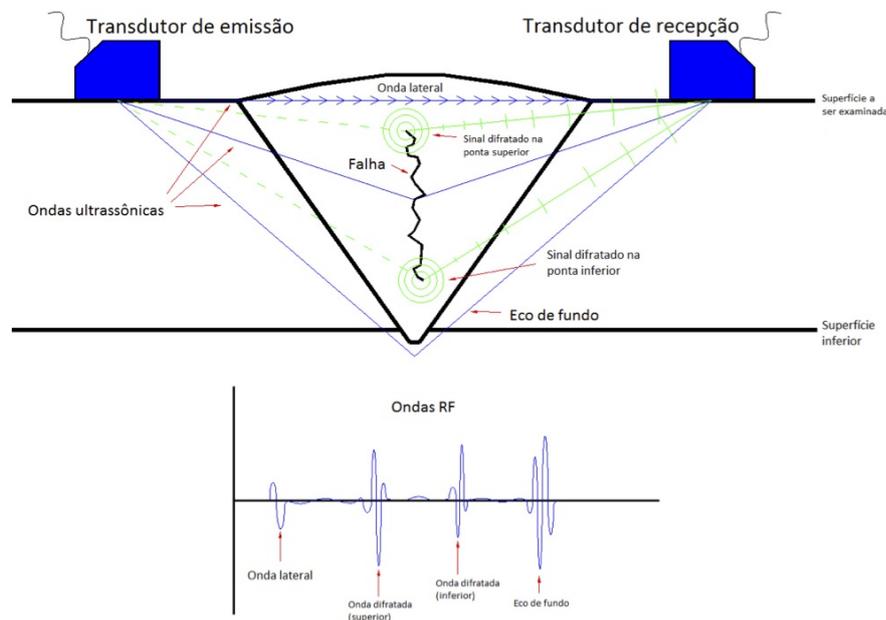
Segundo Mesquita Filho (2005), as ondas ultrassônicas podem ser classificadas em relação à direção de propagação em três tipos: ondas longitudinais, ondas transversais e ondas superficiais. As ondas longitudinais vibram na mesma direção de propagação; as ondas transversais vibram na direção perpendicular ao de propagação e as ondas superficiais vibram com uma combinação das ondas longitudinais e transversais. As ondas superficiais são assim chamadas pois se propagam na superfície dos materiais.

3.2.1 A técnica Técnica do tempo de percurso da onda difratada (TOFD)

A Técnica do Tempo de Percurso de Onda Difrataada (TOFD - *Time Of Flight Diffraction* [do inglês]) descrita por M.G. Silk e B.H. Lidington em 1975 (SILK; LIDINGTON, 1975) é utilizada para localizar descontinuidades através da diferença entre os tempos de percurso dos sinais ultrassônicos que são difratados pelas extremidades (superior e inferior) das mesmas.

A técnica TOFD utiliza um par de transdutores ultrassônicos, sendo um o emissor e o outro o receptor, colocados um de cada lado do cordão de solda, de modo a cobrir toda a região de interesse. A configuração desta técnica é mostrada na figura 4.

Figura 4 – Representação esquemática da técnica TOFD



Fonte – Modificado de Mesquita Filho (2017).

Ondas ultrassônicas são produzidas pelo transdutor de emissão, percorrem o material e são registradas pelo receptor, que transforma a pressão sônica em impulsos elétricos. O registro da variação da pressão sônica no tempo é chamado A-scan. A onda que propaga pela superfície do material percorre a menor distância entre os transdutores e é a primeira a alcançar o receptor. Por outro lado, a onda longitudinal que propaga no interior do material até refletir na superfície oposta à superfície de varredura (por conta da diferença entre as impedâncias acústicas do meio e o ar) percorrerá uma distância maior e produzirá um eco conhecido como eco de fundo. Quaisquer ecos resultantes da reflexão ou da difração (de onde deriva o nome da técnica TOFD) da onda ultrassônica nas extremidades de uma descontinuidade presente no interior do material

será registrado entre as ondas lateral e de fundo.

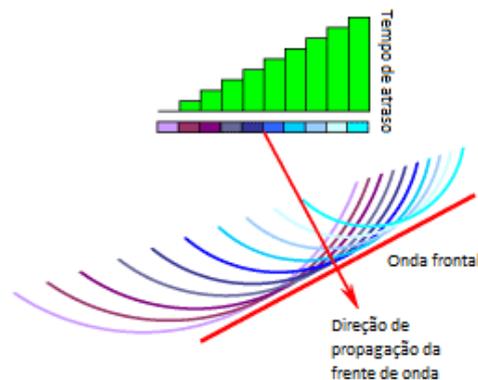
As ondas longitudinais propagam com velocidade maior que as ondas transversais, alcançando primeiro o receptor. Usualmente, são os ecos produzidos pelas ondas longitudinais e superficiais os analisados durante o ensaio com a técnica TOFD.

3.3 O transdutor *Phased Array*

A técnica TOFD utiliza dois transdutores normais para ondas longitudinais montadas sobre cunhas de acrílico de modo a obter um feixe ultrassônico oblíquo. No entanto, modelar tais cunhas significa aumentar o tamanho do sistema e o esforço computacional.

Transdutores Phased Array são compostos por diversos cristais e funcionam baseados em interferências construtivas e destrutivas de ondas produzidas por um ligeiro atraso no tempo de excitação de seus vários elementos (PAO; VARATHARAJULU, 1976). Esse princípio de funcionamento foi empregado neste trabalho para produzir ondas oblíquas sem aumentar o tamanho do sistema modelado (PEREIRA, 2010). Na figura 5 é ilustrado o funcionamento de um transdutor Phased Array.

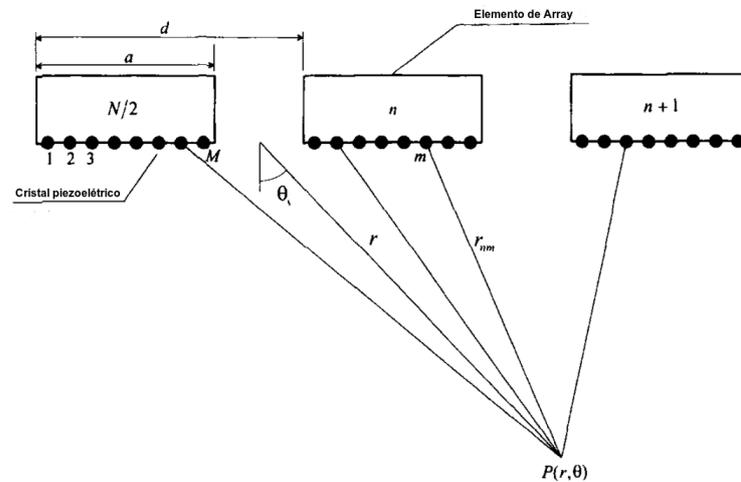
Figura 5 – Direcionamento do feixe ultrassônico



Fonte – Modificado de Kleiner e Bird (2004).

Para obter o direcionamento desejado do feixe ultrassônico é necessário determinar o número N de cristais, o tamanho a de cada elemento e a distância d entre os elementos do transdutor Phased Array. A figura 6, mostra como o transdutor foi simulado. Os retângulos representam os cristais piezoelétricos do transdutor Phased Array, os pontos representam os pontos vibrantes desses cristais, e o θ indica o ângulo de propagação do feixe ultrassônico.

O número de cristais utilizados no direcionamento do feixe é uma variável muito

Figura 6 – Representação do *Phassed Array*

Fonte – Adaptado de Wooh e Shi (1999).

importante, pois quanto maior é esse número, mais estreito e mais bem direcionado será o feixe ultrassônico (WOOH; SHI, 1999). Entretanto, maior também será o esforço computacional necessário à simulação. Desta forma, para reduzir o esforço computacional, otimizar a simulação e produzir um feixe bem direcionado, a escolha adequada do número de cristais é necessária. Na figura 7, está representado o efeito da variação do número de cristais no direcionamento do feixe, onde N é o número de cristais piezoelétricos.

Outra variável fundamental em um transdutor piezoelétrico é a diferença no tempo de vibração de cada cristal, conhecida como *delay*. De acordo com Wooh e Shi (1999), o atraso adequado entre as fontes é dado pela equação 3.1.

$$\Delta t = \frac{d \sin \theta}{v_c} \quad (3.1)$$

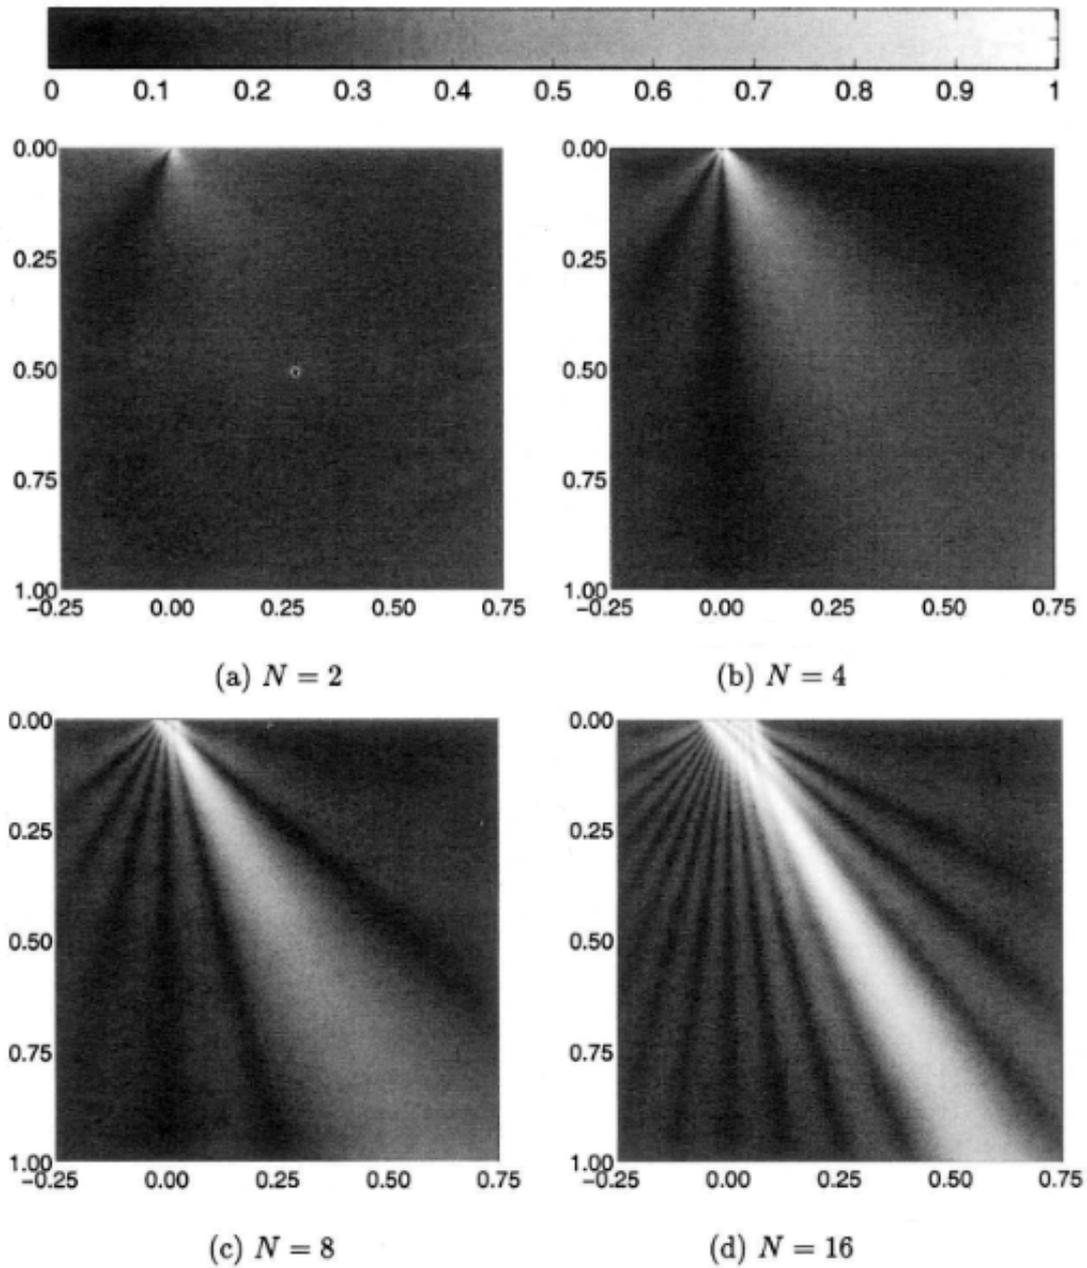
onde d é a distância entre os elementos de *Array*; θ é o ângulo do feixe incidente; e v_c é a velocidade da onda longitudinal no material.

A equação 3.2 é comumente utilizada como fonte em simulações ultrassônica (BAS-KARAN *et al.*, 2007).

$$F(t) = \begin{cases} [1 - \cos(\frac{2\pi ft}{N_c})] \cos(2\pi ft), & \text{se } 0 \leq t \leq \frac{N_c}{f}, \\ 0, & \text{se } t > \frac{N_c}{f}. \end{cases} \quad (3.2)$$

onde f é a frequência de excitação; t é o tempo; e N_c é o número de ciclos.

Figura 7 – Direcionamento do feixe com a variação do número de cristais piezoelétricos.



Fonte – Modificado de Wooh e Shi (1999).

Podemos representar a Equação 3.2 de uma maneira mais generalizada para cada cristal piezoelétrico, como pode ser observado na equação 3.3.

$$F_i(t) = \left[1 - \cos\left(\frac{2\pi f(t + i\Delta t)}{N_c}\right)\right] \cos(2\pi f(t + i\Delta t)), \quad \text{sendo } i = 0, 1, 2, \dots, N_c - 1 \quad (3.3)$$

onde i é o índice correspondente ao cristal.

3.4 Métodos Numéricos

Métodos numéricos constituem um conjunto de ferramentas úteis na obtenção de soluções de inúmeros problemas reais, para os quais a solução analítica é extremamente complexa, impraticável ou que demanda muito tempo. Através dos métodos numéricos é possível entender um problema real e alcançar a solução de um problema com a ajuda de operações elementares.

Os Métodos Numéricos mais comuns são: Método dos Elementos Finitos (MEF), Método das Diferenças Finitas (MDF) e Método dos Volumes Finitos (MVF).

- **Método dos Elementos Finitos:** Divide o domínio em pequenos elementos de geometria simples, sendo cada elemento representado por um conjunto de equações, que descreve o problema original. Utiliza-se a forma integral das equações como ponto de partida e multiplica os elementos por uma função (peso), antes de serem integradas em todo o domínio.
- **Método das Diferenças Finitas:** Assim como o método anterior, o domínio é subdividido em partes finitas, simplificando o entendimento do problema. Para o ponto de partida, utiliza-se as derivadas obtidas através da expansão em série de Taylor ou aproximação polinomial.
- **Método dos Volumes Finitos:** O domínio é subdividido em volumes de controle, que obedecem as leis de conservação e, desta forma, o fluxo de entrada de um determinado volume será idêntico ao fluxo de saída. As equações aproximadas são obtidas a partir da integração das equações diferenciais em um volume de controle conhecido.

A escolha do método numérico baseia-se no tipo de fenômeno a ser simulado, entretanto, quando uma malha adequada é utilizada todos os métodos acima devem ter a mesma solução.

Para assegurar a qualidade dos resultados, a primeira etapa é determinar o tamanho mais adequado da malha. Para isso, o problema é resolvido repetidas vezes enquanto o tamanho da malha é reduzido sucessivamente até que as diferenças observadas na solução não ultrapassem um critério preestabelecido. Esta etapa é chamada refino de malha.

Neste trabalho, foi utilizado o Método dos Volumes Finitos e a malha estruturada quadrangular.

3.5 Equação do Movimento

Segundo Rose (2004), a equação do movimento em um meio bidimensional é dada pela quantidade de movimento, que pode ser expressa pela segunda lei de Newton, como:

$$\rho \frac{\partial^2 u_i}{\partial t^2} = F_i + \frac{\partial \tau_{ij}}{\partial x_j} \quad (3.4)$$

onde ρ é a densidade; u é o vetor de deslocamento; t é o tempo; F é a força por unidade de volume ; τ é a tensão e x é o comprimento.

Neste trabalho, o meio simulado é elástico, podendo ser utilizado a lei de Hooke (RYCHLEWSKI, 1984), dada pela equação 3.5.

$$\tau_{ij} = C_{ijkl} \varepsilon_{kl} \quad (3.5)$$

onde ε_{kl} e C_{ijkl} são, respectivamente, a deformação do material (equação 3.6) e o módulo elástico (equação 3.7).

$$\varepsilon_{kl} = \frac{1}{2} \left(\frac{\partial u_k}{\partial x_l} + \frac{\partial u_l}{\partial x_k} \right) \quad (3.6)$$

$$C_{ijkl} = \lambda \delta_{ij} \delta_{kl} + \mu [\delta_{ik} \delta_{jl} + \delta_{il} \delta_{jk}] \quad (3.7)$$

λ , μ e δ são, respectivamente, o parâmetro de Lamé, o módulo de cisalhamento e o delta de Kronecker.

O material simulado é isotrópico, ou seja, possui propriedades físicas que são independentes da direção, logo a equação 3.6 pode ser expressa pela equação 3.8.

$$\varepsilon_{kl} = \frac{\partial u_k}{\partial x_l} \quad (3.8)$$

Substituindo-se a equação 3.5 e 3.8 na equação 3.4, temos:

$$\rho \frac{\partial^2 u_i}{\partial t^2} = F_i + \frac{\partial}{\partial x_j} \left(C_{ijkl} \frac{\partial u_k}{\partial x_l} \right) \quad (3.9)$$

Os índices i , j , k e l podem assumir os valores de 1 e 2 e são referentes às coordenadas cartesianas x e y (meio bidimensional). Desenvolvendo a equação 3.9, obtêm-se as equações do movimento ao longo de x e y (equações 3.10 e 3.11).

$$\begin{aligned} \rho \frac{\partial^2 u_1}{\partial t^2} = & F_1 + \frac{\partial}{\partial x_1} \left(C_{1111} \frac{\partial u_1}{\partial x_1} \right) + \frac{\partial}{\partial x_1} \left(C_{1112} \frac{\partial u_1}{\partial x_2} \right) + \frac{\partial}{\partial x_1} \left(C_{1121} \frac{\partial u_2}{\partial x_1} \right) + \frac{\partial}{\partial x_1} \left(C_{1122} \frac{\partial u_2}{\partial x_2} \right) \\ & + \frac{\partial}{\partial x_2} \left(C_{1211} \frac{\partial u_1}{\partial x_1} \right) + \frac{\partial}{\partial x_2} \left(C_{1212} \frac{\partial u_1}{\partial x_2} \right) + \frac{\partial}{\partial x_2} \left(C_{1221} \frac{\partial u_2}{\partial x_1} \right) + \frac{\partial}{\partial x_2} \left(C_{1222} \frac{\partial u_2}{\partial x_2} \right) \end{aligned}$$

(3.10)

$$\begin{aligned} \rho \frac{\partial^2 u_2}{\partial t^2} = F_2 + \frac{\partial}{\partial x_1} \left(C_{2111} \frac{\partial u_1}{\partial x_1} \right) + \frac{\partial}{\partial x_1} \left(C_{2112} \frac{\partial u_1}{\partial x_2} \right) + \frac{\partial}{\partial x_1} \left(C_{2121} \frac{\partial u_2}{\partial x_1} \right) + \frac{\partial}{\partial x_1} \left(C_{2122} \frac{\partial u_2}{\partial x_2} \right) \\ + \frac{\partial}{\partial x_2} \left(C_{2211} \frac{\partial u_1}{\partial x_1} \right) + \frac{\partial}{\partial x_2} \left(C_{2212} \frac{\partial u_1}{\partial x_2} \right) + \frac{\partial}{\partial x_2} \left(C_{2221} \frac{\partial u_2}{\partial x_1} \right) + \frac{\partial}{\partial x_2} \left(C_{2222} \frac{\partial u_2}{\partial x_2} \right) \end{aligned} \quad (3.11)$$

O delta de kronecker é uma notação científica onde $\delta_{ij} = \begin{cases} 1, & \text{se } i = j, \\ 0, & \text{se } i \neq j. \end{cases}$ Desenvolvendo a Equação 3.7 obtemos as equações 3.12, 3.13, 3.14 e 3.15.

$$C_{1111} = C_{2222} = \lambda + 2\mu \quad (3.12)$$

$$C_{2211} = C_{1122} = \lambda \quad (3.13)$$

$$C_{1221} = C_{2112} = C_{2121} = C_{1212} = \mu \quad (3.14)$$

$$C_{1222} = C_{2122} = C_{2212} = C_{2221} = C_{2111} = C_{1211} = C_{1121} = C_{1112} = 0 \quad (3.15)$$

Desta forma, substituindo-se os termos da equação 3.15 nas equações 3.10 e 3.11, obtemos as equações 3.16 e 3.17.

$$\rho \frac{\partial^2 u_x}{\partial t^2} = F_x + \frac{\partial}{\partial x} \left(C_{1111} \frac{\partial u_x}{\partial x} \right) + \frac{\partial}{\partial x} \left(C_{1122} \frac{\partial u_y}{\partial y} \right) + \frac{\partial}{\partial y} \left(C_{1221} \frac{\partial u_x}{\partial y} \right) + \frac{\partial}{\partial y} \left(C_{1221} \frac{\partial u_y}{\partial x} \right) \quad (3.16)$$

$$\rho \frac{\partial^2 u_y}{\partial t^2} = F_y + \frac{\partial}{\partial x} \left(C_{1221} \frac{\partial u_x}{\partial y} \right) + \frac{\partial}{\partial x} \left(C_{1221} \frac{\partial u_y}{\partial x} \right) + \frac{\partial}{\partial y} \left(C_{1122} \frac{\partial u_x}{\partial x} \right) + \frac{\partial}{\partial y} \left(C_{1111} \frac{\partial u_y}{\partial y} \right) \quad (3.17)$$

onde F_x e F_y representam a fonte ultrassônica por unidade de volume nas direções x e y, como estão sendo, respectivamente, mostradas nas equações 3.18 e 3.19.

$$F_x = \frac{F \cos \theta}{V} \quad (3.18)$$

$$F_y = \frac{F \sin \theta}{V} \quad (3.19)$$

Thomsen (1986) relacionou os módulos elásticos no centro de cada volume de controle com as velocidades das ondas longitudinais (v_p) e transversais (v_s), como pode ser observado nas equações 3.20 e 3.21.

$$C_{1111} = \rho v_p^2 \quad (3.20)$$

$$C_{1221} = \rho v_s^2 \quad (3.21)$$

Substituindo-se as equações 3.20 e 3.21 nas equações 3.12 e 3.13 e rearranjado-se os termos, obtemos as equações 3.22 e 3.23.

$$\mu = \rho v_s^2 \quad (3.22)$$

$$\lambda = \rho(v_p^2 - 2v_s^2) \quad (3.23)$$

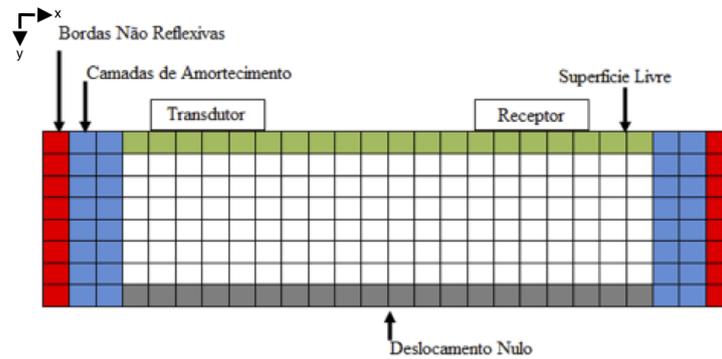
Desta forma, utilizando as equações 3.23 e 3.13 podemos obter a equação 3.24.

$$C_{1122} = \rho(v_p^2 - 2v_s^2) \quad (3.24)$$

3.6 Condições de contorno

Para que uma simulação seja a mais verossímil possível é necessário que um conjunto de restrições adicionais, chamadas de condições de contornos, sejam adequadamente estabelecidas nos limites da peça (CARCIONE, 1994). Tais condições de contorno também tem o objetivo de definir e limitar a porção do espaço sobre o qual a solução da equação da onda é calculada, deixando assim a solução mais próxima daquela obtida quando não há existência de limitações artificiais. Nesse trabalho foram utilizadas as condições de superfície livre, bordas não reflexivas, camadas de amortecimento e deslocamento nulo. Tais condições são ilustradas na figura 8 e brevemente explicadas nas subseções 3.6.1, 3.6.2, 3.6.3 e 3.6.4.

Figura 8 – Representação esquemática das condições de contorno do material



Fonte – Camurça (2014).

3.6.1 Superfície livre

A condição de contorno de superfície livre foi aplicada na superfície superior da peça, onde as tensões normais são nulas. Segundo Landau e Lifshitz (1959, p 96) as equações 3.25 e 3.26 representam o efeito da superfície livre em um material.

$$\frac{\partial u_x}{\partial y} + \frac{\partial u_y}{\partial x} = 0 \quad (3.25)$$

$$v_p^2 \frac{\partial u_y}{\partial y} + (v_p^2 - 2v_s^2) \frac{\partial u_x}{\partial x} = 0 \quad (3.26)$$

Substituindo as Equações 3.20 e 3.24 na equação 3.26 obtemos a equação 3.27.

$$C_{1111} \frac{\partial u_y}{\partial y} + C_{1122} \frac{\partial u_x}{\partial x} = 0 \quad (3.27)$$

A simplificação das equações 3.16 e 3.17 para a superfície superior, combinando as equações 3.25 e 3.27, resulta nas equações 3.28 e 3.29.

$$\rho \frac{\partial^2 u_x}{\partial t^2} = F_x + \frac{\partial}{\partial x} \left(C_{1111} \frac{\partial u_x}{\partial x} \right) + \frac{\partial}{\partial x} \left(C_{1122} \frac{\partial u_y}{\partial y} \right) \quad (3.28)$$

$$\rho \frac{\partial^2 u_y}{\partial t^2} = F_y + \frac{\partial}{\partial x} \left(C_{1221} \frac{\partial u_x}{\partial y} \right) + \frac{\partial}{\partial x} \left(C_{1221} \frac{\partial u_y}{\partial x} \right) \quad (3.29)$$

3.6.2 Bordas não reflexivas

Ondas ultrassônicas sofrem grandes reflexões ao atingirem as bordas laterais do meio por onde propagam devido a enorme diferença de impedância entre o meio e o ar (CATUNDA,

2004). Considerando que nosso sistema representa uma pequena porção de uma chapa metálica, faz-se necessário a aplicação da condição de contorno de bordas não reflexiva, proposta por Reynolds (1978), a fim de evitar reflexões nas extremidades laterais esquerda e direita do sistema.

Essa condição de contorno assume que as bordas laterais estão suficientemente distantes, de modo que podemos considerar as frentes de onda planas nesta região (ANCELME, 2011). A equação acústica da onda é dada pela equação 3.30.

$$\frac{1}{v^2} \frac{\partial^2 u}{\partial t^2} - \frac{\partial^2 u}{\partial x^2} - \frac{\partial^2 u}{\partial y^2} = 0 \quad (3.30)$$

Pode-se fatorar a equação 3.30 (equação 3.31).

$$\left(\frac{1}{v} \frac{\partial}{\partial t} + \frac{\partial}{\partial x} + \frac{\partial}{\partial y} \right) \left(\frac{1}{v} \frac{\partial}{\partial t} - \frac{\partial}{\partial x} - \frac{\partial}{\partial y} \right) u(x, y, t) + 2 \frac{\partial^2 u(x, y, t)}{\partial x \partial y} = 0 \quad (3.31)$$

Como estamos considerando a frente de onda plana nesta região, temos que a derivada parcial de u em relação a y é zero (equação 3.32).

$$\frac{\partial u(x, y, t)}{\partial y} = 0 \Rightarrow \frac{\partial^2 u(x, y, t)}{\partial x \partial y} = 0 \quad (3.32)$$

Substituindo-se a equação 3.32 na equação 3.31, obtemos a equação 3.33.

$$\left(\frac{1}{v} \frac{\partial}{\partial t} + \frac{\partial}{\partial x} \right) \left(\frac{1}{v} \frac{\partial}{\partial t} - \frac{\partial}{\partial x} \right) u(x, y, t) = 0 \quad (3.33)$$

Para que a equação 3.33 seja nula, um dos dois parênteses tem que ser zero. Se o sentido da propagação é dado pelo sinal da equação [(+) para direita e (-) para esquerda], podemos escrever os operadores do campo de onda nas bordas da direita, esquerda respectivamente, pelas equações:

$$\left(\frac{1}{v} \frac{\partial}{\partial t} + \frac{\partial}{\partial x} \right) u(x, y, t) = 0 \quad (3.34)$$

$$\left(\frac{1}{v} \frac{\partial}{\partial t} - \frac{\partial}{\partial x} \right) u(x, y, t) = 0 \quad (3.35)$$

3.6.3 Camadas de amortecimento

As camadas de amortecimentos foram aplicadas nas regiões da malha próximas das bordas laterais da peça, como ilustrado na figura 8. O objetivo desta condição de contorno é evitar

que a onda ultrassônica tenha energia e se propague no material após incidir nas extremidades direita e esquerda da peça.

Segundo Ancelme (2011), a ideia é reduzir gradativamente as amplitudes da onda através da multiplicação do campo de deslocamento por um fator de absorção exponencial, que se inicia em um determinado ponto da malha e aumenta em direção das bordas do modelo, de modo que ao atingir as extremidades da peça a amplitude da onda seja nula.

O fator de atenuação, proposto por Cerjan *et al.* (1985), é dado pela equação 3.36, para a extremidade esquerda do modelo e pela equação 3.37, para a extremidade direita do modelo.

$$W(k) = \exp(-[fat[Na - k]]^2) \quad (3.36)$$

$$W(k) = \exp(-[fat[k - (N_x - Na)]]^2) \quad (3.37)$$

onde $W(k)$ é o fator de atenuação; f_{at} é o fator de amortecimento; N_a é o número de volumes utilizados para atenuar a onda; k é o índice do volume da malha e N_x é o número de volumes na direção x.

3.6.4 Deslocamento nulo

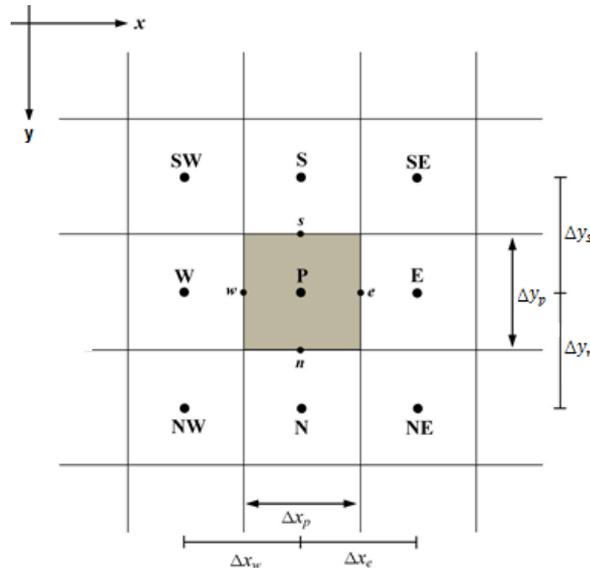
Devido à grande diferença de impedância entre o metal e o ar, uma onda é quase completamente refletida e tem sua fase invertida ao alcançar os limites de uma peça metálica. Para evitar aumentar os esforços computacionais com a adição do ambiente externo ao nosso sistema, aplica-se a condição de contorno deslocamento nulo à superfície oposta. Segundo Camurça (2014), a equação 3.38 garante a reflexão total da onda na superfície inferior do material.

$$u_x = u_y = 0 \quad (3.38)$$

3.7 Obtenção das ondas discretizadas pelo MVF

O Método de Volumes Finitos foi utilizado para discretizar a equação do movimento da onda neste trabalho. A figura 9, mostra a esquematização da malha cartesiana utilizada.

Figura 9 – Esquematização da malha bidimensional



Fonte – Modificado de Camurça (2014).

Conforme Camurça (2014), as derivadas diretas para a componente x e y do deslocamento, utilizando aproximação numérica por série de Taylor é dada por:

$$\left. \frac{\partial u_x}{\partial t} \right|_P^{t+\Delta t} = \frac{u_{xP}^{t+\Delta t} - u_{xP}^t}{\Delta t} \qquad \left. \frac{\partial u_y}{\partial t} \right|_P^{t+\Delta t} = \frac{u_{yP}^{t+\Delta t} - u_{yP}^t}{\Delta t} \quad (3.39)$$

$$\left. \frac{\partial u_x}{\partial t} \right|_P^t = \frac{u_{xP}^t - u_{xP}^{t-\Delta t}}{\Delta t} \qquad \left. \frac{\partial u_y}{\partial t} \right|_P^t = \frac{u_{yP}^t - u_{yP}^{t-\Delta t}}{\Delta t} \quad (3.40)$$

$$\left. \frac{\partial u_x}{\partial x} \right|_e^t = \frac{u_{xE}^t - u_{xP}^t}{\Delta x_e} \qquad \left. \frac{\partial u_y}{\partial x} \right|_e^t = \frac{u_{yE}^t - u_{yP}^t}{\Delta x_e} \quad (3.41)$$

$$\left. \frac{\partial u_x}{\partial x} \right|_w^t = \frac{u_{xP}^t - u_{xW}^t}{\Delta x_w} \qquad \left. \frac{\partial u_y}{\partial x} \right|_w^t = \frac{u_{yP}^t - u_{yW}^t}{\Delta x_w} \quad (3.42)$$

$$\left. \frac{\partial u_x}{\partial y} \right|_n^t = \frac{u_{xN}^t - u_{xP}^t}{\Delta y_n} \qquad \left. \frac{\partial u_y}{\partial y} \right|_n^t = \frac{u_{yN}^t - u_{yP}^t}{\Delta y_n} \quad (3.43)$$

$$\left. \frac{\partial u_x}{\partial y} \right|_s^t = \frac{u_{xP}^t - u_{xS}^t}{\Delta y_s} \qquad \left. \frac{\partial u_y}{\partial y} \right|_s^t = \frac{u_{yP}^t - u_{yS}^t}{\Delta y_s} \quad (3.44)$$

e as derivadas cruzadas:

$$\frac{\partial u_x}{\partial x} \Big|_n^t = \frac{u_{xNE}^t + u_{xE}^t - u_{xNW}^t - u_{xW}^t}{2(\Delta x_w + \Delta x_e)} \quad \frac{\partial u_y}{\partial x} \Big|_n^t = \frac{u_{yNE}^t + u_{yE}^t - u_{yNW}^t - u_{yW}^t}{2(\Delta x_w + \Delta x_e)} \quad (3.45)$$

$$\frac{\partial u_x}{\partial x} \Big|_s^t = \frac{u_{xE}^t + u_{xSE}^t - u_{xW}^t - u_{xSW}^t}{2(\Delta x_w + \Delta x_e)} \quad \frac{\partial u_y}{\partial x} \Big|_s^t = \frac{u_{yE}^t + u_{ySE}^t - u_{yW}^t - u_{ySW}^t}{2(\Delta x_w + \Delta x_e)} \quad (3.46)$$

$$\frac{\partial u_x}{\partial y} \Big|_e^t = \frac{u_{xNE}^t + u_{xN}^t - u_{xSE}^t - u_{xS}^t}{2(\Delta x_s + \Delta x_n)} \quad \frac{\partial u_y}{\partial y} \Big|_e^t = \frac{u_{yNE}^t + u_{yN}^t - u_{ySE}^t - u_{yS}^t}{2(\Delta x_s + \Delta x_n)} \quad (3.47)$$

$$\frac{\partial u_x}{\partial y} \Big|_s^t = \frac{u_{xN}^t + u_{xNW}^t - u_{xS}^t - u_{xSW}^t}{2(\Delta x_s + \Delta x_n)} \quad \frac{\partial u_y}{\partial y} \Big|_s^t = \frac{u_{yN}^t + u_{yNW}^t - u_{yS}^t - u_{ySW}^t}{2(\Delta x_s + \Delta x_n)} \quad (3.48)$$

A equação da fonte (equação 3.3) integrada é chamada de F_i , como podemos observar na equação 3.49.

$$F_i = \int_0^t F(t) dt = \frac{\text{sen}(2\pi f t)}{2\pi f} - \frac{N_c \text{sen}\left(\left(2\pi f + \frac{2\pi f}{N_c}\right)t\right)}{4\pi f(N_c + 1)} - \frac{N_c \text{sen}\left(\left(2\pi f - \frac{2\pi f}{N_c}\right)t\right)}{4\pi f(N_c - 1)} \quad (3.49)$$

3.7.1 Equação do volume interno do modelo

Primeiramente, para encontrar a equação do volume interno do deslocamento em x e em y , deve-se integrar as equações 3.16 e 3.17. As equações devem ser integradas em relação ao tempo e ao espaço como está sendo mostrada na equação 3.50 e 3.51.

$$\begin{aligned} & \int_s^n \int_w^e \int_t^{t+\Delta t} \left[\rho \frac{\partial^2 u_x}{\partial t^2} \right] dt dx dy = \int_t^{t+\Delta t} \int_s^n \int_w^e [F_x] dx dy dt \\ & + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{1111} \frac{\partial}{\partial x} \left(\frac{\partial u_x}{\partial x} \right) \right] dx dy dt + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{1122} \frac{\partial}{\partial x} \left(\frac{\partial u_y}{\partial y} \right) \right] dx dy dt \\ & + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{1221} \frac{\partial}{\partial y} \left(\frac{\partial u_x}{\partial y} \right) \right] dy dx dt + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{1221} \frac{\partial}{\partial y} \left(\frac{\partial u_y}{\partial x} \right) \right] dy dx dt \end{aligned} \quad (3.50)$$

$$\begin{aligned} & \int_s^n \int_w^e \int_t^{t+\Delta t} \left[\rho \frac{\partial^2 u_y}{\partial t^2} \right] dt dx dy = \int_t^{t+\Delta t} \int_s^n \int_w^e [F_y] dx dy dt \\ & + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{1221} \frac{\partial}{\partial x} \left(\frac{\partial u_x}{\partial y} \right) \right] dx dy dt + \int_t^{t+\Delta t} \int_s^n \int_w^e \left[C_{1221} \frac{\partial}{\partial x} \left(\frac{\partial u_y}{\partial x} \right) \right] dx dy dt \\ & + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{1122} \frac{\partial}{\partial y} \left(\frac{\partial u_x}{\partial x} \right) \right] dy dx dt + \int_t^{t+\Delta t} \int_w^e \int_s^n \left[C_{1111} \frac{\partial}{\partial y} \left(\frac{\partial u_y}{\partial y} \right) \right] dy dx dt \end{aligned}$$

$$(3.51)$$

Desenvolvendo as integrais das equações 3.50 e 3.51 e utilizando-se a formulação explícita, onde todos os deslocamentos são avaliados no instante anterior, tem-se a equação 3.52 e 3.53.

$$\begin{aligned} \rho \int_s^n \int_w^e \left[\frac{\partial u_x}{\partial t} \Big|_P^{t+\Delta t} - \frac{\partial u_x}{\partial t} \Big|_P^t \right] dx dy &= \int_t^{t+\Delta t} \int_s^n \int_w^e [F_x] dx dy dt \\ + \int_t^{t+\Delta t} \int_s^n \left[C_{1111}^e \frac{\partial u_x}{\partial x} \Big|_e^t - C_{1111}^w \frac{\partial u_x}{\partial x} \Big|_w^t \right] dy dt &+ \int_t^{t+\Delta t} \int_s^n \left[C_{1122}^e \frac{\partial u_y}{\partial y} \Big|_e^t - C_{1122}^w \frac{\partial u_y}{\partial y} \Big|_w^t \right] dy dt \\ + \int_t^{t+\Delta t} \int_w^e \left[C_{1221}^n \frac{\partial u_x}{\partial y} \Big|_n^t - C_{1221}^s \frac{\partial u_x}{\partial y} \Big|_s^t \right] dx dt &+ \int_t^{t+\Delta t} \int_w^e \left[C_{1221}^n \frac{\partial u_y}{\partial x} \Big|_n^t - C_{1221}^s \frac{\partial u_y}{\partial x} \Big|_s^t \right] dx dt \end{aligned} \quad (3.52)$$

$$\begin{aligned} \rho \int_s^n \int_w^e \left[\frac{\partial u_y}{\partial t} \Big|_P^{t+\Delta t} - \frac{\partial u_y}{\partial t} \Big|_P^t \right] dx dy &= \int_t^{t+\Delta t} \int_s^n \int_w^e [F_y] dx dy dt \\ + \int_t^{t+\Delta t} \int_s^n \left[C_{1221}^e \frac{\partial u_x}{\partial y} \Big|_e^t - C_{1221}^w \frac{\partial u_x}{\partial y} \Big|_w^t \right] dy dt &+ \int_t^{t+\Delta t} \int_s^n \left[C_{1221}^e \frac{\partial u_y}{\partial x} \Big|_e^t - C_{1221}^w \frac{\partial u_y}{\partial x} \Big|_w^t \right] dy dt \\ + \int_t^{t+\Delta t} \int_w^e \left[C_{1122}^n \frac{\partial u_x}{\partial x} \Big|_n^t - C_{1122}^s \frac{\partial u_x}{\partial x} \Big|_s^t \right] dx dt &+ \int_t^{t+\Delta t} \int_w^e \left[C_{1111}^n \frac{\partial u_y}{\partial y} \Big|_n^t - C_{1111}^s \frac{\partial u_y}{\partial y} \Big|_s^t \right] dx dt \end{aligned} \quad (3.53)$$

No volume interno, o termo fonte é nulo, pois a mesma só atua na superfície do material e como a malha utilizada é a estruturada quadrática, temos que para os volumes internos:

$$\Delta F_x = 0 \quad (3.54)$$

$$\Delta F_y = 0 \quad (3.55)$$

$$\Delta x_e = \Delta x_w \quad (3.56)$$

$$\Delta y_n = \Delta y_s \quad (3.57)$$

Substituindo-se as equações 3.39 à 3.48, nas equações 3.52 e 3.53, desenvolvendo as integrais e rearranjando os termos, obtemos a expressão utilizada para o cálculo do deslocamento em x e y, no volume de controle interno, que estão, respectivamente, sendo mostrados nas equações 3.58 e 3.59.

$$\begin{aligned}
u_{xP}^{t+\Delta t} &= 2u_{xP}^t - u_{xP}^{t-\Delta t} + \frac{\Delta t^2}{\rho \Delta x^2} [C_{1111}^e (u_{xE}^t - u_{xP}^t) - C_{1111}^w (u_{xP}^t - u_{xW}^t)] \\
&+ \frac{\Delta t^2}{\rho \Delta y^2} [C_{1221}^n (u_{xN}^t - u_{xP}^t) - C_{1221}^s (u_{xP}^t - u_{xS}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1122}^e (u_{yNE}^t + u_{yNW}^t - u_{ySE}^t - u_{yS}^t) - C_{1122}^w (u_{yN}^t + u_{yNW}^t - u_{yS}^t - u_{ySW}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1221}^n (u_{yNE}^t + u_{yE}^t - u_{yNW}^t - u_{yW}^t) - C_{1221}^s (u_{yE}^t + u_{ySE}^t - u_{yW}^t - u_{ySW}^t)]
\end{aligned} \tag{3.58}$$

$$\begin{aligned}
u_{yP}^{t+\Delta t} &= 2u_{yP}^t - u_{yP}^{t-\Delta t} + \frac{\Delta t^2}{\rho \Delta x^2} [C_{1221}^e (u_{yE}^t - u_{yP}^t) - C_{1221}^w (u_{yP}^t - u_{yW}^t)] \\
&+ \frac{\Delta t^2}{\rho \Delta y^2} [C_{1111}^n (u_{yN}^t - u_{yP}^t) - C_{1111}^s (u_{yP}^t - u_{yS}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1221}^e (u_{xNE}^t + u_{xNN}^t - u_{xSE}^t - u_{xS}^t) - C_{1221}^w (u_{xN}^t + u_{xNW}^t - u_{xS}^t - u_{xSW}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1122}^n (u_{xNE}^t + u_{xE}^t - u_{xNW}^t - u_{xW}^t) - C_{1122}^s (u_{xE}^t + u_{xSE}^t - u_{xW}^t - u_{xSW}^t)]
\end{aligned} \tag{3.59}$$

As equações 3.20, 3.21 e 3.23 referem-se aos módulos elásticos no centro de cada volume de controle, como vimos na seção 3.4. Entretanto, os módulos elásticos necessários na equação do movimento integrada são referentes aos módulos elásticos da interface de cada volume de controle. De acordo com Patankar (1980), podemos encontrar o valor desse módulo elástico, através do cálculo da média harmônica dos módulos elásticos no interior dos dois volumes adjacentes.

3.7.2 Equação da superfície do modelo

A condição de contorno de superfície livre foi aplicada no extremo superior da peça, desta forma, para encontrar a equação utilizada na superfície, é necessário integrar as Equações 3.28 e 3.29. Após a integração no tempo e no espaço das expressões e rearranjar os termos,

obtemos as equações 3.60 e 3.61.

$$\begin{aligned}
u_{xP}^{t+\Delta t} &= 2u_{xP}^t - u_{xP}^{t-\Delta t} + \frac{\Delta t F_{ii}}{\rho \Delta x \Delta y} \cos \theta + \frac{\Delta t^2}{\rho \Delta x^2} [C_{1111}^e (u_{xE}^t - u_{xP}^t) - C_{1111}^w (u_{xP}^t - u_{xW}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1122}^e (u_{yNE}^t + u_{yNN}^t - u_{ySE}^t - u_{yS}^t) - C_{1122}^w (u_{yN}^t + u_{yNW}^t - u_{yS}^t - u_{ySW}^t)]
\end{aligned} \tag{3.60}$$

$$\begin{aligned}
u_{yP}^{t+\Delta t} &= 2u_{yP}^t - u_{yP}^{t-\Delta t} + \frac{\Delta t F_{ii}}{\rho \Delta x \Delta y} \sen \theta + \frac{\Delta t^2}{\rho \Delta x^2} [C_{1221}^e (u_{yE}^t - u_{yP}^t) - C_{1221}^w (u_{yP}^t - u_{yW}^t)] \\
&+ \frac{\Delta t^2}{4\rho \Delta x \Delta y} [C_{1221}^e (u_{xNE}^t + u_{xNN}^t - u_{xSE}^t - u_{xS}^t) - C_{1221}^w (u_{xN}^t + u_{xNW}^t - u_{xS}^t - u_{xSW}^t)]
\end{aligned} \tag{3.61}$$

onde $F_{ii} = \begin{cases} F_i, & \text{na posição do transdutor,} \\ 0, & \text{fora do transdutor.} \end{cases}$. F_i é dado pela equação 3.49.

3.7.3 Equação das bordas laterais do modelo

Nas bordas laterais direita e esquerda da peça foi aplicado a condição de contorno de bordas não reflexivas, como foi visto na seção 3.6.2.

Para encontrarmos a equação da borda lateral esquerda, temos que integrar no tempo e no espaço a equação 3.34.

$$\int_s^n \int_w^e \int_t^{t+\Delta t} \frac{1}{v} \frac{\partial u_x}{\partial t} dt dx dy + \int_s^n \int_w^e \int_t^{t+\Delta t} \frac{\partial u_x}{\partial x} dt dx dy = \int_s^n \int_w^e \int_t^{t+\Delta t} 0 dt dx dy \tag{3.62}$$

$$\frac{1}{v} (u_{xP}^{t+\Delta t} - u_{xP}^t) \Delta x \Delta y + (u_{xE}^t - u_{xP}^t) \Delta t \Delta y = 0 \tag{3.63}$$

Rearranjando os termos da equação 3.63, obtemos a Equação 3.64, que é a utilizada, no Método dos Volumes Finitos, na borda lateral esquerda do material.

$$u_{xP}^{t+\Delta t} = u_{xP}^t + (u_{xP}^t - u_{xE}^t) \frac{v \Delta t}{\Delta x} \tag{3.64}$$

Para encontrarmos a equação da borda lateral direita, temos que integrar no tempo e no espaço a equação 3.35.

$$\int_s^n \int_w^e \int_t^{t+\Delta t} \frac{1}{v} \frac{\partial u_x}{\partial t} dt dx dy - \int_s^n \int_w^e \int_t^{t+\Delta t} \frac{\partial u_x}{\partial x} dt dx dy = \int_s^n \int_w^e \int_t^{t+\Delta t} 0 dt dx dy \tag{3.65}$$

$$\frac{1}{v}(u_{xP}^{t+\Delta t} - u_{xP}^t)\Delta x\Delta y - (u_{xP}^t - u_{xW}^t)\Delta t\Delta y = 0 \quad (3.66)$$

Rearranjando os termos da equação 3.66, obtemos a equação 3.67, que é a utilizada, no Método dos Volumes Finitos, na borda lateral direita do material.

$$u_{xP}^{t+\Delta t} = u_{xP}^t + (u_{xP}^t - u_{xW}^t)\frac{v\Delta t}{\Delta x} \quad (3.67)$$

onde v é a velocidade transversal do material (v_s)

3.7.4 Equação das regiões próximas as bordas do modelo

As camadas de amortecimento foram aplicadas na região próxima as bordas da peça. Após encontrar o deslocamento em x e y dado, respectivamente, pelas equações 3.58 e 3.59, é necessário multiplicar o deslocamento pelo fator de atenuação.

As equações 3.68 e 3.69 mostram como são calculados o campo do deslocamento em x e y nessa região.

$$u_x = W(k)u_x \quad (3.68)$$

$$u_y = W(k)u_y \quad (3.69)$$

3.7.5 Equação da extremidade inferior do modelo

A condição de contorno aplicado nessa região é de deslocamento nulo, garantindo assim a reflexão total na extremidade inferior (equação 3.38). Desta forma, o deslocamento em x e em y , no tempo, será dado pelas equações 3.70 e 3.71.

$$u_x^t = u_x^{t+\Delta t} = 0 \quad (3.70)$$

$$u_y^t = u_y^{t+\Delta t} = 0 \quad (3.71)$$

3.8 Análise de Componentes Principais

A Análise de Componentes Principais (Principal Components Analysis [do inglês] - PCA) é uma técnica estatística multivariada, que utiliza uma transformação ortogonal para

converter um conjunto de dados possivelmente correlacionados, a um conjunto de dados linearmente descorrelacionados, de dimensão igual ou superior que descrevam a variação dos dados (VARELLA, 2008).

Geometricamente, de acordo com Webb (2003), a Análise de Componentes Principais pode ser definida como uma rotação dos eixos do sistema de coordenadas original para um novo conjunto de eixos ortogonais. O novo conjunto de eixos é ordenado de tal forma, que o primeiro eixo principal tem a maior variância, o segundo eixo principal tem a segunda maior variância e assim, sucessivamente, até que o último eixo principal que possui a menor variância.

O primeiro passo para o cálculo da PCA é a organização dos dados em forma de uma matriz 'n x p', onde 'n' é o número de dados amostrais e 'p' é o número de atributos, como pode ser visualizado na equação 3.72. Em cada linha é colocado um sinal ultrassônico e cada coluna representa a pressão sonora num determinado instante de tempo.

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1p} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2p} \\ x_{31} & x_{32} & x_{33} & \cdots & x_{3p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & x_{n3} & \cdots & x_{np} \end{bmatrix} \quad (3.72)$$

O segundo passo é a padronização dos dados, que neste trabalho, teve a média igual a 0 e a variância igual a 1, obtida a partir da equação 3.73.

$$x'_{ij} = \frac{x_{ij} - \bar{x}_j}{s(x_j)}, \quad i = 1, 2, \dots, n \quad e \quad j = 1, 2, \dots, p \quad (3.73)$$

onde, \bar{x}_j e $s(x_j)$ são, respectivamente, a estimativa da média e o desvio padrão da característica j, dadas pelas equações 3.74 e 3.75.

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (3.74)$$

$$s(x_j) = \sqrt{\sum_{i=1}^n \frac{(x_{ij} - \bar{x}_j)^2}{n-1}}, \quad j = 1, 2, \dots, p \quad (3.75)$$

Fazemos esse cálculo para cada dado e obtemos a matriz $X'_{n \times p}$. Em seguida, é necessário calcular a matriz de covariância Σ , dada pela equação ???. A matriz Σ é simétrica e de ordem 'p x p'.

Onde,

$$\hat{V}ar(x'_k) = \sum_{i=1}^k \frac{(x'_{ik} - \bar{x}_k)^2}{k} \quad (3.77)$$

e

$$\hat{C}ov(x'_k x'_m) = \sum_{i=1}^n \frac{(x'_{ik} - \bar{x}_k)(x'_{im} - \bar{x}_m)}{k} \quad (3.78)$$

Após construída a matriz de covariância, faz-se necessário calcular os seus autovalores e autovetores. De acordo com Boldrini *et al.* (1980), os p autovalores λ da matriz ($p \times p$) são as raízes da equação 3.79.

$$\|\Sigma - \lambda \mathbf{I}_p\| = 0 \quad (3.79)$$

onde \mathbf{I}_p é a matriz identidade 'p x p'.

Neste cálculo, encontraremos p autovalores, já que a matriz Σ tem dimensão 'p x p'. Para cada autovalor λ_i existe um autovetor \mathbf{v}_i associado, que é a solução da equação 3.80.

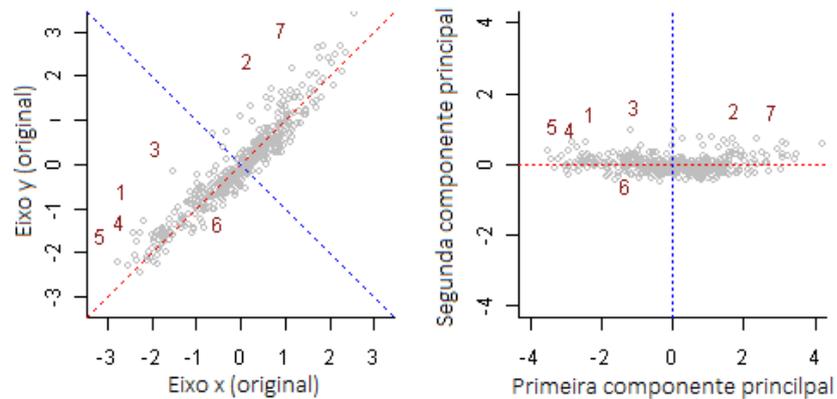
$$\Sigma \mathbf{v}_i = \lambda_i \mathbf{v}_i, \quad i = 1, 2, \dots, p \quad (3.80)$$

Em seguida, para a construção da matriz de transformação \mathbf{T} , arranja-se em forma de matriz os p autovetores, de modo decrescentes, de acordo com os valores dos p autovalores associados. Desta forma, a primeira coluna da matriz de transformação será o autovetor \mathbf{v}_1 correspondente ao maior autovalor λ_1 , a segunda coluna da matriz de transformação será o autovetor \mathbf{v}_2 correspondente ao segundo maior autovalor λ_2 e assim, sucessivamente, de modo que a última coluna da matriz de transformação será o autovetor \mathbf{v}_p correspondente ao menor autovalor λ_p .

Multiplicando-se os dados de entrada (\mathbf{X}') normalizados pela matriz de transformação (\mathbf{T}), obtemos a matriz de componentes principais. Se quisermos utilizar apenas k componentes principais, basta utilizar somente as k primeiras colunas da matriz de componentes principais. De acordo com Varella (2008), conseguimos obter a proporção de dados explicados pelas k primeiras componentes, quando dividimos a soma dos k maiores autovalor pelo valor da soma de todos os p autovalores.

A figura 10 mostra um exemplo da técnica PCA aplicada a um conjunto de dados bidimensionais.

Figura 10 – Representação dos dados antes e depois do PCA.



Fonte – Modificado de Farrar (2017).

3.9 Reconhecimento de padrões

O reconhecimento de padrões é uma área da ciência que tem por objetivo a classificação/agrupamento de objetos em um número de categorias, através da utilização de algoritmos de classificação, que observam padrões a partir de um conjunto de propriedades ou características (THEODORIDIS; KOUTROUMBAS, 1999).

Segundo Kaufman e Rousseeuw (2009), existem dois tipos de algoritmos de classificação: o supervisionado e o não supervisionado. Algoritmos supervisionados apresentam uma etapa em que a classificação real dos dados é informada, ou seja, pares de entrada e saída desejadas são apresentadas, e o algoritmo tem como objetivo aprender uma regra geral que relaciona corretamente entradas e saídas. Esta etapa é conhecida como treinamento. Já para o classificador não supervisionado, nenhuma informação é dada ao algoritmo que deve encontrar a melhor forma de classificar ou agrupar os dados de modo independente.

Neste trabalho, foram utilizados o K-vizinhos mais próximos, a Rede neural artificial e o K-médias para a classificação dos sinais. O K-vizinhos mais próximos é um algoritmo de aprendizado supervisionado, o k-média é um algoritmo de aprendizado não supervisionado e a Rede neural artificial pode ser tanto supervisionada quanto não supervisionada. A rede neural supervisionada foi a utilizada neste trabalho.

3.9.1 *k*-vizinhos mais próximos

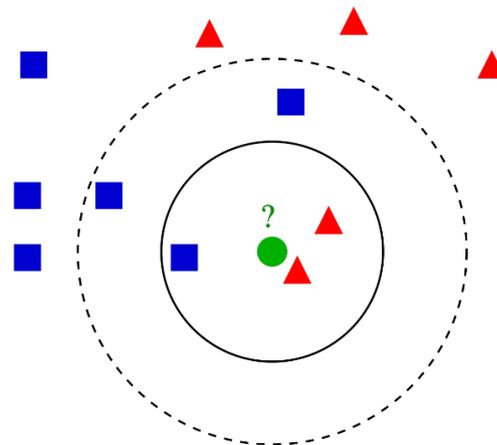
O k-vizinhos mais próximos (K-NN - K-nearest neighbor [do inglês]) é um dos algoritmos de classificação mais simples. Ele é dividido em duas fases: a de treinamento e a de

teste. Na fase de treinamento, os dados, e sua correta classificação, são fornecidos ao algoritmo. Em seguida, na fase de teste, dados não apresentados ao algoritmo durante o treinamento são apresentados ao algoritmo treinado, que retorna a classe sugerida correspondente.

Inicialmente, mapeia-se a região a ser estudada com uma malha quadrangular de comprimento h . Em seguida, calcula-se a distância entre cada vértice da malha a todos os padrões de treinamento. Verifica-se a quais classes pertencem os k dados mais próximos e a classificação é feita associando-se a região que compreende os k dados à classe que for predominante (BISHOP, 2006).

Na Figura 11 temos um exemplo desse algoritmo, onde os dados azuis e vermelhos são dados de treino e o dado verde é o dado de teste que desejamos classificar. Para k igual a 3 o dado verde será classificado como pertencente a classe dos vermelhos. Já para k igual a 5, o dado verde será classificado como pertencente a classe azul.

Figura 11 – Exemplo da técnica K-NN



Fonte – Ajank (2007).

A distância euclidiana, dada pela Equação 3.81, foi utilizada neste trabalho.

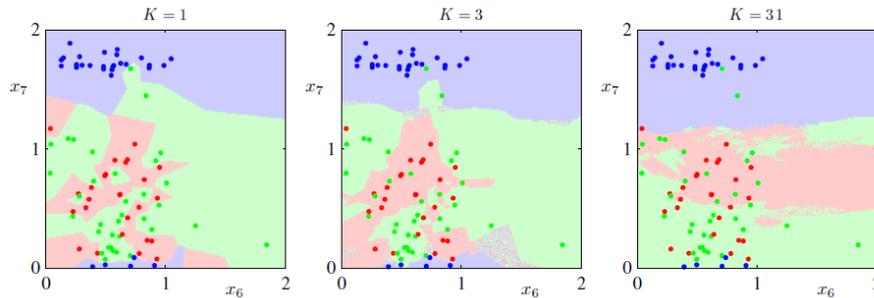
$$D_e = \sqrt{\sum_{i=1}^p (x_i - y_i)^2} \quad (3.81)$$

onde p é a dimensão dos dados; x_i e y_i são as coordenadas de \mathbf{x} e \mathbf{y} na dimensão i .

O parâmetro k é determinado pelo usuário e é uma variável muito importante à classificação dos dados. A figura 12 mostra o resultado da fase de treinamento aplicando o algoritmo k -vizinhos mais próximos à um conjunto de 200 pontos para diferentes valores de k , onde regiões de diferentes classes são coloridas com diferentes cores. Pode ser verificado, que k

controla o grau de suavização da estimativa. Pequenos valores de k produzem pequenas regiões de cada classe, altos valores de k produzem maiores regiões.

Figura 12 – Mudança no mapeamento de regiões com a variação do k



Fonte – Bishop (2006).

Após a fase de treinamento temos a fase de teste, que consiste em fornecer ao algoritmo os dados de teste e verificar quais deles pertencem a uma região de mesma classificação original. Com essas informações obtemos a matriz de confusão.

3.9.2 Redes Neurais Artificiais

As redes neurais artificiais foram inspiradas na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência.

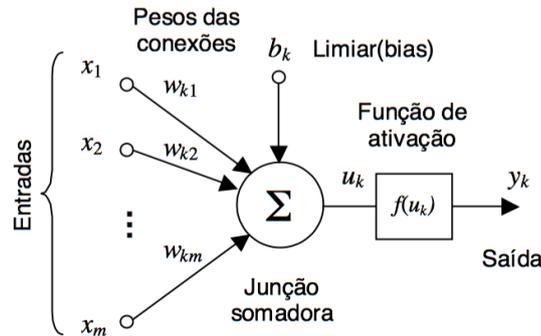
O primeiro neurônio artificial, criado em 1943, era um dispositivo binário que tinha como entrada ganhos arbitrários e que podiam ser excitatórias (sinal positivo) ou inibitórias (sinal negativo). A média ponderada das entradas eram calculadas, de acordo com o seu fator de ponderação, e se esse resultado fosse maior ou igual a um certo valor, a saída do neurônio era pulso, se fosse menor, a saída do neurônio era não pulso. Este neurônio ficou conhecido como McCulloch (MCCULLOCH; PITTS, 1943).

Baseado no modelo de McCulloch, outros modelos de neurônios foram criados. A representação de um desses neurônio é ilustrada na figura 13, onde (x_1, x_2, \dots, x_m) são as características de entrada; $(w_{k1}, w_{k2}, \dots, w_{km})$ são os ganhos associados a cada vetor de entrada (pesos das conexões); b_k é o limiar; u_k é a saída do somatório; $f(u_k)$ é a função de ativação; y_k é a saída do neurônio.

Desta forma, a saída do neurônio é dada por:

$$y_k = f(u_k) = f\left(\sum_{i=1}^m x_i w_{ki} + b_k\right) \quad (3.82)$$

Figura 13 – Modelo matemático de um neurônio artificial



Fonte – Zuben (2017).

A função de ativação $f(u_k)$ avalia o potencial de ativação u_k e define a saída do neurônio. Segundo Haykin (2007), podemos identificar três tipos básicos de funções de ativação:

- **Função de Limiar:** Nesta função a saída do neurônio assume o valor 1, se o campo induzido do neurônio é positivo, e 0 caso contrário, como podemos observar na equação 3.83. Esta é a função do modelo de McCulloch, descrito anteriormente.

$$y_k = \begin{cases} 1, & \text{se } u_k \geq 0, \\ 0, & \text{se } u_k < 0. \end{cases} \quad (3.83)$$

- **Função Linear por Partes:** Nesta função a saída do neurônio pode assumir valores de 0 a 1, como pode ser observado na equação 3.84.

$$y_k = \begin{cases} 1, & \text{se } u_k \geq 1, \\ u_k, & \text{se } 1 > u_k > 0, \\ 0, & \text{se } u_k \leq 0. \end{cases} \quad (3.84)$$

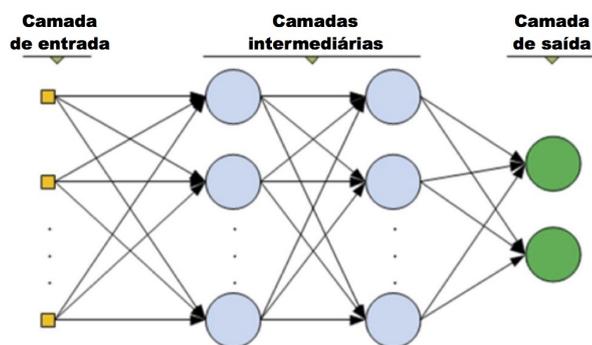
- **Função Sigmóide:** É a função mais utilizada em redes neurais, uma função monotônica crescente que apresenta propriedades assintóticas e de suavidade. Um exemplo de função sigmóide é a função logística, que está sendo apresentada na equação 3.85, onde a é o parâmetro de inclinação da função.

$$y_k = \frac{1}{1 + \exp(-au_k)} \quad (3.85)$$

Para resolver problemas mais complexos, os quais não podem ser resolvidos por um único neurônio, foi criado o modelo de multicamadas. O modelo é composto por alguns neurônios, organizados em três ou mais camadas. A primeira camada é a de entrada, onde os

dados são apresentados ao algoritmo. As camadas intermediárias são as camadas ocultas, que tornam a rede capaz de extrair estatísticas de ordem elevada e a última camada é a de saída, que é a resposta da rede para o usuário. Os sinais de saída da primeira camada são utilizados como entrada para a segunda camada, que são processados pela segunda camada e utilizados como entrada para a terceira camada, e assim por diante para o resto da rede. Desta forma, temos uma rede totalmente conectada, onde cada nó em uma camada se conecta, com um certo peso, em um nó da camada seguinte. Na figura 14, temos um exemplo desse tipo de rede neural.

Figura 14 – Modelo matemático de um neurônio artificial



Fonte – Modificado de Caparrini (2017).

A rede neural pode aprender a reconhecer padrões e ser utilizada na classificação de dados, ela pode ser de dois tipos: não supervisionada ou supervisionada. Neste trabalho, utilizamos uma rede neural supervisionada.

Em uma rede neural supervisionada, o algoritmo é dividido em duas fases, a fase de treino e a de teste. Na fase de treino, uma parte dos dados é utilizada para o aprendizado do algoritmo. Desta forma, são apresentados os dados e as suas respectivas classificações ao programa, que tem como objetivo ajustar os ganhos e o limiar, até obter a maior taxa média de acerto na classificação desses dados. Já na fase de teste, é verificado se o algoritmo aprendeu a classificar os dados corretamente. A entrada é um conjunto dos dados que não foram utilizados anteriormente, e os ganhos e o limiar da rede são aqueles obtidos na fase de teste. Nesta fase, os dados são processados e uma classificação para cada dado é obtida.

O ganho inicial e o limiar é escolhido aleatoriamente e, depois, o ganho é ajustado na fase de treinamento do algoritmo. De acordo com Hebb (2005), os ganhos devem ser ajustado para cada camada da rede, começando da camada de saída e seguindo em direção a camada de

entrada, da seguinte forma:

$$w_{ki}^{novo} = w_{ki}^{velho} + \alpha \delta_k y_i \quad (3.86)$$

onde o parâmetro α é definido como taxa de aprendizado, que é informada pelo o usuário e δ_k é o gradiente local, dado por:

$$\delta_k = (y_k^d - y_k) \phi_k' \quad (3.87)$$

onde ϕ_k' é a derivada da função de ativação e y_k^d é a saída desejada.

Quando o ajuste de todos os ganhos é realizado em uma rede neural dizemos que ocorreu uma "época". Esse ajuste é repetido até que o critério de parada é alcançado. O critério de parada utilizado neste trabalho foi o número de "épocas". Após obtermos os valores do limiar e ajustarmos os valores dos ganhos, começa a fase de teste. Os dados de teste são processados e uma matriz de confusão é obtida.

3.9.3 K-médias

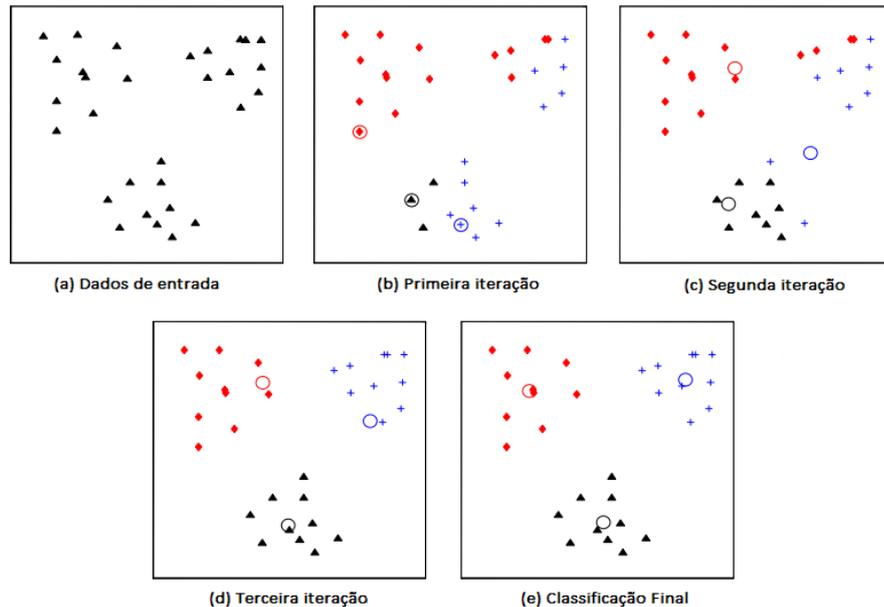
O k-médias é um algoritmo de agrupamento que classifica os dados de acordo com a similaridade entre os elementos. Diferentemente do K-NN, ele é um classificador não supervisionado e possui somente a fase de teste.

Utilizando critérios de agrupamento baseados em distância entre os dados, esse algoritmo experimenta dividir os dados de entrada em um número k de classes. Para sabermos em quantas classes é melhor agrupar os dados, variamos k entre dois e a raiz quadrada do número total de dados de entrada e usamos alguns critérios de agrupamento para verificar em quantas classes é melhor agrupar os dados e a que classe pertence cada dado.

Inicialmente, escolhe-se aleatoriamente k centroides. Em seguida, é calculada a distância euclidiana entre cada dado de entrada e todos os k centroides, mostrada na Equação 3.81. O dado é, então, associado à classe do centroide que possui a menor dessas distâncias.

Posteriormente, a posição dos k centroides é recalculada utilizando-se a média dos dados de cada classe resultantes do passo anterior. Os mesmos procedimentos de associação do dado ao centroide mais próximo e o cálculo da posição dos k centroides são repetidos, até que a mudança nas posições dos centroides seja menor do que um certo valor, ou até que o número de iterações predefinidas sejam atingidas (JAIN, 2010). Na Figura 15, temos um exemplo de funcionamento do algoritmo para k=3.

Figura 15 – Representação do funcionamento do k-médias



Fonte – Modificado de Jain (2010).

Modificando-se o número de grupos k e utilizando-se alguns índices, tais como Silhueta e Davies Bouldin, descritos a seguir, o algoritmo sugere um número ótimo de agrupamentos.

O critério Silhueta verifica quão próximo os elementos estão do mesmo conjunto e quão longe os elementos estão do grupo mais próximo. Para obter este índice, é necessário calcular a distância média do elemento i para todos os elementos do mesmo grupo (a_i) e a distância média do elemento i para todos os elementos do grupo mais próximo (b_i). A equação 3.88 mostra o cálculo desse índice.

$$S = \sum_{i=1}^n \frac{b_i - a_i}{\max(a_i, b_i)} \quad (3.88)$$

Para obter o índice Davies Bouldin, calculam-se todas as k distâncias entre o centroide do cluster i para todos os elementos do grupo i (chamadas de d_i). Em seguida, calcula-se a distância entre cada par de centroides i e j . (chamadas de $d(c_i, c_j)$). O índice é dado pela equação 3.89.

$$DB = \frac{1}{k} \sum_{i=k, i \neq j}^n \max\left(\frac{d_i + d_j}{d(c_i, c_j)}\right) \quad (3.89)$$

De acordo com Petrovic (2006), a qualidade do agrupamento é tão melhor quanto mais próximo da unidade for o índice Silhueta, e/ou quanto mais próximo de zero for o índice Davies Bouldin.

4 MATERIAIS E MÉTODOS

A modelagem de um meio bidimensional e isotrópico contendo uma descontinuidade interna e a simulação numérica do ensaio ultrassônico foram realizadas utilizando-se a linguagem de programação FORTRAN. A cada simulação, o tipo, o tamanho e a posição da descontinuidade são alterados, e um sinal da variação da pressão sônica no tempo, lida na posição do receptor, é produzido. O meio modelado reproduz as propriedades de juntas soldadas em aço carbono que foram inspecionadas no Centro de Ensaios não Destrutivos (CENDE) da Universidade Federal do Ceará (UFC) com o intuito de produzir um conjunto de sinais experimentais para a validação da simulação numérica. Descontinuidades como poro, trinca e falta de penetração foram intencionalmente inseridas ao material durante o processo de soldagem. A análise de componentes principais e algoritmos de reconhecimento de padrões foram aplicados aos sinais simulados e sinais experimentais para verificar como esses dados são classificados.

4.1 Definição de parâmetros do modelo

Para modelar o sistema, e durante a simulação da propagação da onda, foram utilizadas as propriedades do aço carbono que são apresentadas na Tabela 1.

Tabela 1 – Propriedades do material

Propriedades	Valores Estabelecidos
Velocidade da onda longitudinal	5900 m/s
Velocidade da onda transversal	3200 m/s
Densidade	7900 kg/m ³

Fonte – Tabela do próprio autor.

A geometria do sistema foi definida como sendo um retângulo de comprimento igual a 80 mm e largura (espessura) igual a 19 mm.

4.2 Definição de parâmetros da fonte

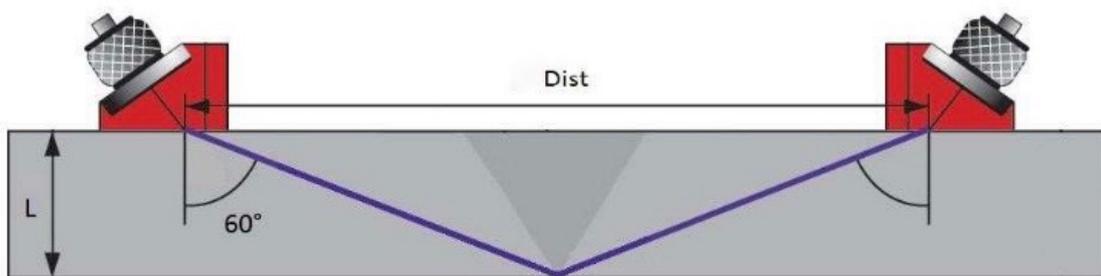
Na prática, quando se trabalha com a técnica TOFD, utiliza-se um par de transdutores montados sobre cunhas para produzir feixes ultrassônicos angulares. A inclinação do feixe ultrassônico desejada pode ser obtida com base na lei de Snell. O feixe ultrassônico oblíquo também pode ser obtida com base no princípio da sobreposição de Huygen. Esse tipo de direcionamento do feixe ultrassônico é comum em aparelhos com múltiplos elementos (chamados

phased array), onde um atraso apropriado no sinal de excitação aplicado aos diferentes cristais é utilizado para direcionar o feixe ultrassônico. Nesse trabalho, utilizou-se uma fonte excitadora constituída por um *Array* de 8 elementos piezoelétricos, em que cada um desses elementos possui 8 pontos vibrantes. A velocidade de propagação da onda, a distância entre os elementos piezoelétricos que compõem a fonte, o atraso temporal no acionamento de cada elemento e o ângulo de incidência do feixe sônico estão relacionados de acordo com a equação 3.1. O ângulo foi escolhido como 60° por ser, de acordo com Temple (1986), o ângulo de melhor desempenho na inspeção de juntas soldadas pela técnica TOFD.

A frequência f do transdutor foi definida como 5,0 MHz, e o comprimento de onda, λ , obtido pela divisão da velocidade longitudinal pela a frequência, é 1,18 mm. De acordo com Wooh e Shi (1999), o tamanho adequado de cada elemento a e o espaçamento d entre os elementos é igual a $\lambda/2$. Desta maneira, como há 8 cristais em cada elemento, o espaçamento entre os cristais é $\lambda/14$ (Tamanho do elemento dividido por $(N_c - 1)$).

A distância entre os dois transdutores pode ser calculada por uma simples relação trigonométrica. Sendo o ângulo de incidência 60° , o espaçamento adequado entre os transdutores $Dist$ é dado por $2L \text{tg}(60^\circ)$, onde L é a espessura da peça, como mostrado na figura 16.

Figura 16 – Distância entre os transdutores na técnica TOFD



Fonte – Modificado de NDT RESOURCE CENTER (2011).

Dadas a frequência e a velocidade de propagação da onda ultrassônica no aço e o espaçamento entre os elementos do transdutor, o atraso na excitação desses elementos da fonte necessário para produzir um feixe com ângulo de incidência de 60° é de 86,6 ns. O tempo total de propagação foi de $15,2 \mu s$.

A direção do feixe pode ser melhorada aumentando o espaçamento entre elementos,

d_{el} . Um valor ótimo é dado pela equação 4.1.

$$d_{el} = \frac{\lambda}{1 + \text{sen}(\theta)_{max}} \quad (4.1)$$

o θ_{max} é o ângulo que vai permitir varrer toda a peça, no nosso trabalho o ângulo de 90° permite essa varredura e será o nosso θ_{max} .

Na tabela 2 temos os valores dessas variáveis, que são importantes propriedades para o funcionamento adequado da fonte.

Tabela 2 – Parâmetros e dimensões referentes ao transdutor

Descrição	Valor
Ângulo de incidência	60°
Número de pontos vibrantes	8
Número de cristais em cada elemento	8
Comprimento de onda	$1,180e-3$ m
Frequência da onda	$5,0e6$ Hz
Distância entre os cristais	$8,43e-5$ m
Espaçamento entre os elementos de <i>Array</i>	$5,9e-4$ m
Espaçamento entre os transdutores	$6,93e-2$ m
O atraso de excitação entre as fontes	$8,66e-8$ s
Tempo total de excitação das fontes	$1,52e-5$ s

Fonte – Tabela do próprio autor.

4.3 Avanço temporal

De acordo com Maliska (1994), coeficientes negativos na equação do movimento da onda discretizada aumentam a probabilidade da solução convergir para valores inconsistentes. Portanto, é necessário utilizar um avanço temporal (Δt), que permita que o maior número de coeficientes da equação sejam positivos.

Desta forma, analisando as equações integradas, verifica-se que o avanço temporal interfere somente no sinal do coeficiente de u'_{xP} e para o mesmo ser positivo, Δt tem que obedecer a Equação 4.2.

$$\Delta t < \sqrt{\frac{\Delta x^2}{v_p^2 + v_s^2}} \quad (4.2)$$

O avanço temporal utilizado neste trabalho é 1×10^{-9} s. O Δx foi obtido após o estudo do refino de malha, que é mostrado na seção 4.4.

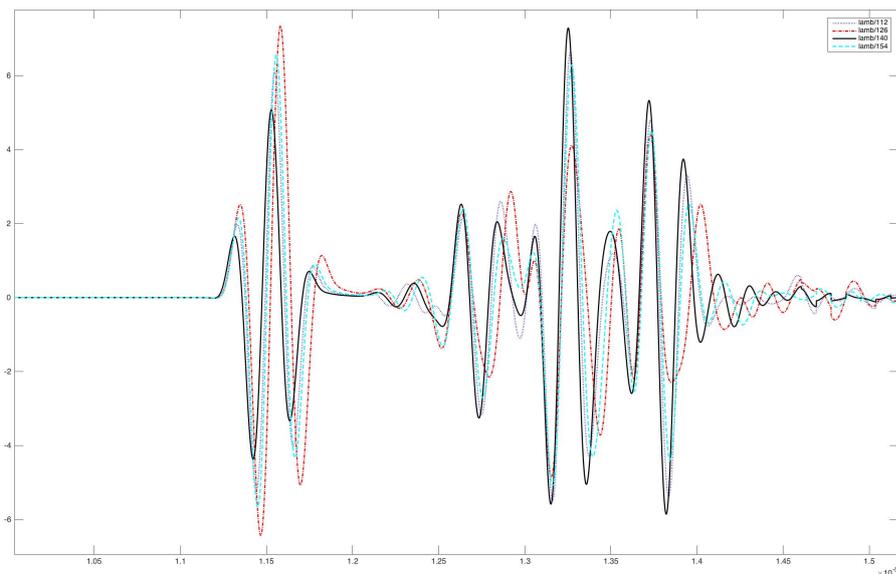
4.4 Tamanho da malha

O tamanho da malha é uma das variáveis mais importantes na solução de problemas utilizando os métodos numéricos. Quanto mais refinada é a malha menores são os erros de truncamento associados ao problema. Entretanto, maiores serão os esforços computacionais necessários à obtenção da solução numérica.

Para a escolha do comprimento de malha adequado foi realizado um estudo de refino de malha. Vale ressaltar que o tamanho da malha deve ser submúltiplo da distância entre os cristais piezoelétricos, que é $\lambda/14$, para que o cristal esteja sobre o nó da malha. Foram realizados experimentos com malhas cartesianas estruturadas com comprimento de $\lambda/112$, $\lambda/126$, $\lambda/140$ e $\lambda/154$. Todas as outras variáveis do sistema foram mantidas, sendo portanto, o tamanho da malha a única distinção entre elas.

A figura 17 mostra o resultado da simulação para as diferentes malhas. A malha escolhida é aquela que quando comparada com uma malha mais refinada a solução tem uma variação pequena. A comparação foi feita utilizando o erro quadrático médio. Para essa simulação $\lambda/140$ foi o comprimento de malha utilizado.

Figura 17 – Estudo do refino de malha



Fonte – Figura do próprio autor.

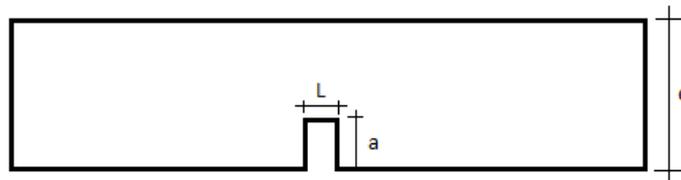
4.5 Modelagem da descontinuidade

Neste trabalho, foram modelados três tipos de descontinuidades comumente encontradas em juntas soldadas: poro, trinca e falta de penetração. Foram realizadas 36 simulações para cada tipo de descontinuidade, variando, dependendo do tipo, sua posição e suas dimensões. Na região de cada descontinuidade os módulos elásticos foram considerados nulos.

4.5.1 Falta de penetração

Como apresentado na seção 3.3.1, falta de penetração é um tipo de descontinuidade que ocorre exclusivamente no centro do cordão de solda. Esse defeito de soldagem foi modelado como uma descontinuidade aberta à superfície inferior e sempre posicionada equidistante às superfícies laterais do modelo. Assim, somente sua largura e altura foram alteradas. Uma simulação foi executada para diferentes combinações de largura e altura. A largura variou de 1.0 mm a 6.0 mm, com incremento de 1.0 mm. A altura variou de 3.0 mm a 8.0 mm, com incremento de 1.0 mm. A combinação de larguras e alturas totalizou 36 simulações. A Figura 18 ilustra como esse defeito foi modelado na peça.

Figura 18 – Representação esquemática de uma descontinuidade do tipo Falta de Penetração



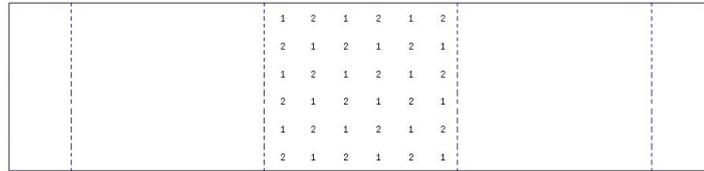
Fonte – Figura do próprio autor.

4.5.2 Poro

Esse tipo de descontinuidade é geralmente esférica. Entretanto, o uso da malha cartesiana impõe restrições à modelagem dessa geometria. Por isso, os poros modelados foram todos quadrangulares. A descontinuidade do tipo poro pode ocorrer em qualquer local ao longo do cordão de solda. Nesse trabalho, poros foram adicionados a uma região, correspondente ao cordão de solda, que está localizada na terça parte da área do modelo equidistante aos transdutores. A Figura 19 mostra esquematicamente como os poros foram posicionados, onde os números 1 indicam a posição dos poros de 1.0 mm x 1.0 mm e os números 2 representam o

posicionamento dos poros de 2.0 mm x 2.0 mm.

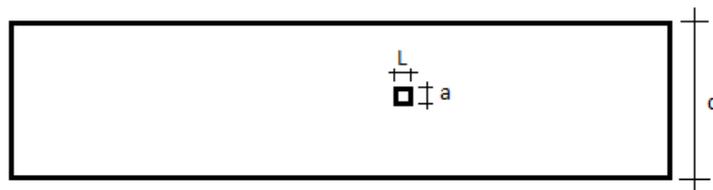
Figura 19 – Representação esquemática do posicionamento das descontinuidades do tipo Poro



Fonte – Figura do próprio autor.

Foram modelados 18 descontinuidades do tipo poro com dimensões de 1.0 mm x 1.0 mm e outras 18 com dimensões de 2.0 mm x 2.0 mm, totalizando-se 36 simulações. A Figura 20 mostra uma dessas descontinuidades.

Figura 20 – Representação esquemática de uma descontinuidade do tipo Poro



Fonte – Figura do próprio autor.

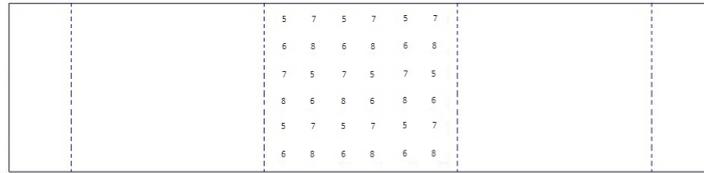
4.5.3 Trinca

Assim como a descontinuidade do tipo poro, a trinca também pode ocorrer em qualquer local ao longo do cordão de solda.

Foram simuladas descontinuidades de 5.0 mm a 8.0 mm de altura, com incremento de 1.0 mm. A largura da trinca corresponde sempre a 10% de sua altura. Para cada um dos 4 tamanhos possíveis de trinca foram modeladas 9 delas, em diferentes posições, totalizando-se 36 descontinuidades. A Figura 21 revela onde cada uma das trincas foi posicionada, e os valores apresentados nessa Figura 21 indicam a dimensão da altura da trinca. Ou seja, os números 5 indicam a posição das trincas de 0.5 mm x 5.0 mm, e assim por diante.

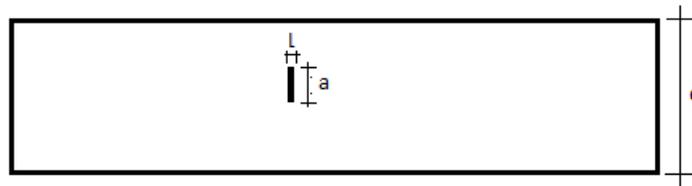
A Figura 22 mostra uma descontinuidade do tipo trinca. Uma simulação de propagação de onda foi executada para cada uma das descontinuidades modeladas, individualmente.

Figura 21 – Representação esquemática do posicionamento das descontinuidades do tipo Trinca



Fonte – Figura do próprio autor.

Figura 22 – Representação esquemática de uma descontinuidade do tipo Trinca



Fonte – Figura do próprio autor.

4.6 Sinais capturados experimentalmente

Um conjunto de sinais capturados durante a inspeção por ultrassom de juntas soldadas contendo descontinuidades semelhantes às modeladas foi utilizado para avaliar o treinamento dos algoritmos de reconhecimento de padrões e validar a simulação numérica.

Os sinais experimentais utilizados nesse trabalho são os mesmos empregados nos trabalhos de Moura *et al.* (2004), Moura *et al.* (2005a), Moura *et al.* (2005b). Esses sinais foram obtidos utilizando a técnica TOFD em 12 corpos de prova confeccionados em chapas de aço AISI 1020, com 20 mm de espessura, 300 mm de comprimento, chanfro em V com inclinação de 50°, uma raiz de 2 mm e soldada pelo processo de eletrodo revestido (Shielded Metal Arc Welding – SMAW).

Diferentes tipos de defeitos, tais como: falta de fusão, falta de penetração e porosidade foram intencionalmente adicionados aos corpos de prova durante o processo de soldagem, criando padrões de defeito. A posição, o tipo e o tamanho de cada um dos defeitos inseridos foram reconhecidos usando testes ultrassônicos convencionais e testes radiográficos.

A falta de fusão orientada verticalmente se assemelha a uma trinca longitudinal. A descontinuidade do tipo trinca modelada nesse trabalho se assemelha a uma falta de fusão orientada verticalmente para poder aproveitar o banco de sinais experimentais existente.

O equipamento de inspeção automatizada empregado na captura dos sinais experimentais era composto por um programa de controle instalado em um computador conectado

ao equipamento de ultrassom e ao sistema mecânico (robô) através de um sistema eletrônico (driver). O sistema mecânico (robô) é responsável pelo transporte dos transdutores ultrassônicos, e por garantir o melhor contato possível entre os transdutores e a superfície da região inspecionada, é dotados de rodas magnéticas para permitir a inspeção de tubos, chapas e estruturas ferromagnéticas em geral, em todas as posições, inclusive de cabeça para baixo.

Foi utilizado um equipamento ultrassônico convencional conectado a uma placa A/D. Os transdutores eram do tipo normal (90°), de onda longitudinal, modelo MSW/QC/PC, com 6 mm de diâmetro, e com uma frequência central de 5.0 MHz. Para obter as ondas longitudinais nos ângulos desejados, utilizaram-se cunhas para ondas longitudinais com um ângulo de incidência de 60° em aço. O scanner e o aparelho ultrassônico foram conectados a um microcomputador com um programa responsável por controlar as posições dos transdutores e armazenar os sinais. Todos os A-scans foram adquiridos a uma taxa de amostragem de 100 MSamples/s, com 512 pontos, durante o movimento lateral do par de transdutores (a cada milímetro) ao longo da solda.

Após a inspeção ultrassônica por TOFD dos 12 corpos de prova, e usando o resultado de inspeções radiográficas como gabarito, 60 sinais (A-scan) de cada uma das três classes - falta de fusão, falta de penetração e porosidade - foram selecionados para a etapa de classificação.

Vale lembrar que esses sinais experimentais são os mesmos empregados no trabalhos de Moura *et al.* (2004), Moura *et al.* (2005a), Moura *et al.* (2005b). Além da validação da modelagem e da simulação numérica, a utilização desse conjunto de sinais em especial permitirá a realização de uma boa comparação dos resultados.

4.7 Pré-processamento dos sinais

Na tentativa de alcançar melhores taxas de acerto pelos algoritmos de reconhecimento de padrões, realizou-se um estudo comparativo do efeito da aplicação de diferentes tipos de pré-processamento de sinais aplicado aos sinais ultrassônicos (simulados e experimentais).

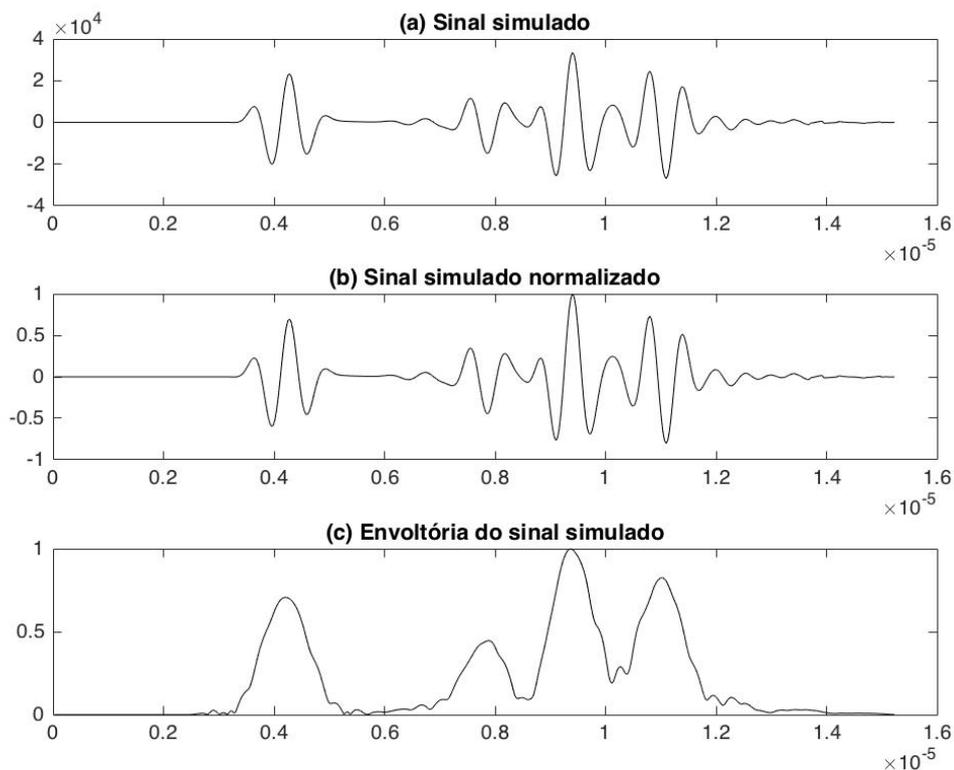
De acordo com Moura *et al.* (2005b), o cálculo da envoltória do sinal de TOFD melhora a taxa de acerto na classificação dos dados. Desta forma, experimentou-se o uso da envoltória dos sinais ultrassônicos aos dados apresentados aos algoritmos de classificação. A envoltória foi obtida pela aplicação do filtro Savitzky-Golay.

Outra técnica de pré-processamento foi a normalização dos dados. O sinal ultrassônico foi normalizado pelo valor máximo absoluto.

Desta forma, foram analisados três conjuntos de sinais: os sinais originais (com

nenhum pré-processamento), os sinais normalizados e a envoltória dos sinais. Na Figura 23, mostra-se um exemplo do (a) Sinal simulado, (b) Sinal simulado normalizado e (c) Envoltória do sinal simulado de uma peça com descontinuidade do tipo falta de penetração, com altura de 3.0 mm e largura de 1.0 mm.

Figura 23 – (a) Sinal simulado, (b) Sinal simulado normalizado e (c) Envoltória do sinal simulado de uma descontinuidade do tipo falta de penetração ($h = 3.0$ mm e $l = 1.0$ mm)



Fonte – Figura do próprio autor.

4.8 Análise de Componentes Principais

Neste trabalho, foram simulados 108 sinais ultrassônicos. Cada simulação produziu um sinal com 512 pontos que precisa ser analisado. Para tornar o conjunto de dados fácil de se explorar e visualizar, foi utilizada a técnica de Análise de Componentes Principais (PCA).

Foi realizado um estudo do número ótimo de componentes principais a serem utilizadas nos algoritmos de reconhecimento de padrões, ou seja, variou-se o número de componentes principais e verificou com quantas componentes temos uma melhor classificação dos dados

de teste. A sintetização da técnica de Análise de Componentes Principais é apresentada no Algoritmo 1.

Algoritmo 1: Análise de Componentes Principais

Entrada: Dados

Saída: Matriz de componentes principais

início

Organizar os dados de entrada em forma de uma matriz 108x512;

Normalizar os dados;

Calcular a matriz de covariância;

Encontrar os autovetores e autovalores da matriz de covariância;

Construir a matriz de transformação;

Multiplicar os dados de entrada normalizados pela matriz de transformação e obter a matriz de componentes principais;

fim

4.9 Reconhecimento de Padrões

As técnicas de reconhecimento de padrões K-NN, Redes neurais artificiais e K-médias foram utilizadas na classificação de diferentes conjuntos de dados produzidos a partir dos sinais a-scan, são eles: sinais simulados, sinais simulados normalizados, envoltória dos sinais simulados, componentes principais dos sinais simulados, sinais experimentais, sinais experimentais normalizados, envoltória dos sinais experimentais e componentes principais dos sinais experimentais.

4.9.1 *k*-vizinhos mais próximos

O algoritmo *k*-vizinhos mais próximos (*k*-NN) possui duas fases: a de treinamento e a de teste. Dos 36 sinais simulados para cada tipo de descontinuidade, 29 sinais (80% dos dados, aproximadamente) foram usados para treino e 7 sinais (20% restantes) para teste.

Os dados de teste e de treino foram separados aleatoriamente. Para garantir a precisão dos resultados e reduzir possíveis efeitos provocados pela escolha de qualquer certo conjunto de sinais em particular, o algoritmo foi repetido 100 vezes e foi considerado somente a taxa média de acerto na classificação desses dados.

Como visto na seção 3.9.1, o comprimento de malha h e o número k de vizinhos mais próximos a serem considerados são os parâmetros mais importantes no algoritmo k-NN. neste trabalho, utilizou-se h igual à 0,05 e vários testes foram realizados para determinar o valor ótimo de k para cada grupo de dados. um resumo da técnica k-NN é apresentada pelo algoritmo 2.

Algoritmo 2: K-vizinhos mais próximos

Entrada: Dados,k,h

Saída: Matriz de confusão

início

para $i=1:100$ **faça**

 A separação aleatória de 80% dos dados para treino e de 20% dos dados de teste;

 A construção de uma malha quadrangular de comprimento h ;

para *cada vértice da malha* **faça**

 O cálculo da distância entre o vértice e todos os dados de treinamento;

 A verificação de quais classes pertencem os k elementos mais próximos;

 A associação da região que compreende os k elementos a classe predominante;

fim

 Plote as regiões classificadas;

para *cada dado de teste* **faça**

 A verificação se ele pertence a uma região de mesma classificação original;

fim

 A construção de uma matriz de confusão;

fim

 Faça o cálculo da média das 100 matrizes de confusões e encontrar a matriz de confusão final;

fim

4.9.2 Redes neurais artificiais

A rede neural utilizada nesse trabalho também apresenta aprendizado supervisionado, e também foi executada uma centena de vezes empregando o mesmo método descrito na seção 3.9.1 para selecionar os dados as fases de treinamento e teste.

Assim como para o algoritmo K-NN, na rede neural os dados de teste e de treino

foram separados aleatoriamente e o algoritmo foi repetido 100 vezes.

Antes do uso das redes neurais foram realizados vários testes preliminares com o objetivo de determinar valores adequados para a taxa de aprendizado α e o número de épocas, descritas na seção 3.9.2., para cada um dos conjuntos de dados analisados.

A escolha do número de neurônios da camada oculta seguiu uma heurística do valor médio entre o número de atributos dos dados de entrada e o número de neurônios da camada de saída, igual ao número de classes. Todos os sinais utilizados nesse trabalho, simulados ou capturados, possuem 512 pontos (512 atributos), e o número de classes é igual a 3 (falta de penetração, poro e trinca). Desta forma, o número de neurônios na camada intermediária da rede utilizada na classificação dos sinais é igual à 257. Quando os dados de entrada são as componentes principais dos sinais, o número de neurônios da camada oculta muda em função do número de componentes utilizadas. Um resumo da rede neural artificial é apresentado pelo algoritmo 3.

4.9.3 *k*-médias

Para determinar o número ótimo k de grupos, o algoritmo testou todos os valores entre dois (considerando que não faz sentido criar um único grupo com todos o conjunto de dados) e a raiz quadrada do tamanho do conjunto de entrada. Neste trabalho, foram simulados 108 sinais, assim, o algoritmo analisou a maneira de agrupar o conjunto de dados de 1 até 11 classes para o conjunto de dados simulados. Quando agrupamos os dados simulados com os experimentais, o total de sinais é 288. Então, o k -médias analisou a maneira de agrupar os dados de 1 até 17 classes.

O algoritmo é executado 100 vezes de modo a reduzir os efeitos decorrentes da escolha inicial dos k centroides e para garantir a precisão dos resultados. Em cada uma das 100 execuções verifica-se o número de agrupamentos sugeridos pelos índices Silhouette e Davies-bouldin, e o número ótimo de agrupamento é escolhido como sendo o menor valor entre os sugeridos por esses índices. Um resumo da técnica k -médias é apresentada no algoritmo 4.

Algoritmo 3: Redes Neurais Artificiais

Entrada: Dados, Número de épocas e α

Saída: Matriz de confusão

início

para $i=1:100$ **faça**

 A separação aleatória de 80% dos dados para treino e de 20% dos dados de teste;
 A escolha aleatória de todos os ganhos e dos limiares que serão utilizados na rede;

para $int=1:Número\ de\ épocas$ **faça**

para *cada sinal* **faça**

 O processamento do sinal;

 Se a saída for incorreta, ajuste o peso através do algoritmo de propagação
 backpropagation;

fim

fim

para *cada dado de teste* **faça**

 O processamento com os ganhos obtidos na fase de treino ;

fim

 A construção de uma matriz de confusão;

fim

Faça o cálculo da média das 100 matrizes de confusões e encontrar a matriz de confusão final;

fim

Algoritmo 4: K-médias

Entrada: Dados**Saída:** Número de agrupamentos sugerido e matriz com o agrupamento**início****para** $i=1:100$ **faça****para** $k=1:raiz(tamanho\ do\ conjunto\ de\ entrada)$ **faça**

Escolha aleatória de k centroides;

para $distância(novos\ centroides - centroides) > critério$ **faça****para** cada dado **faça**

O cálculo da distância entre o dado e os k centroides;

A associação do dado ao centroide mais próximo

fim

O cálculo da posição dos k centroides

fim

O cálculo do índice Silhueta;

O cálculo do índice Davies Bouldin;

fim

Faça o cálculo do número de agrupamentos ótimo

fim

O estudo do número de classe sugerido nas 100 repetições, o valor que aparecer mais vezes será o número k de conjuntos utilizados para agrupar os sinais;

Faça 100 vezes a separação dos dados em k classe e coloque em uma matriz como os dados foram agrupados;

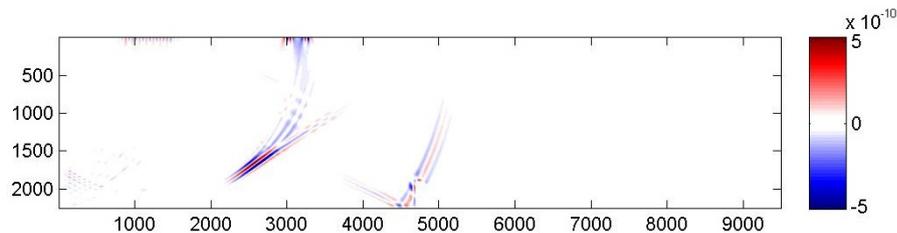
fim

5 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

5.1 Simulação

Sinais foram produzidos pela simulação da propagação de ondas ultrassônicas em um meio bidimensional modelado que representa uma peça de aço carbono comum contendo uma das discontinuidades descritas na seção 4.5. Cada simulação produz centenas de campos de deslocamentos e um sinal A-scan. Um campo de deslocamento (ou pressão) exhibe o valor do deslocamento das partículas (ou pressão) ao longo do meio de propagação em um certo instante. Na figura 24, tem-se o campo de deslocamento no instante que a frente de onda longitudinal alcança uma descontinuidade do tipo falta de penetração com altura de 3,0 mm e largura de 1,0 mm.

Figura 24 – Campo de deslocamento gerado no instante em que a onda encontra uma descontinuidade do tipo falta de penetração ($h = 3,0$ mm e $l = 1,0$ mm).



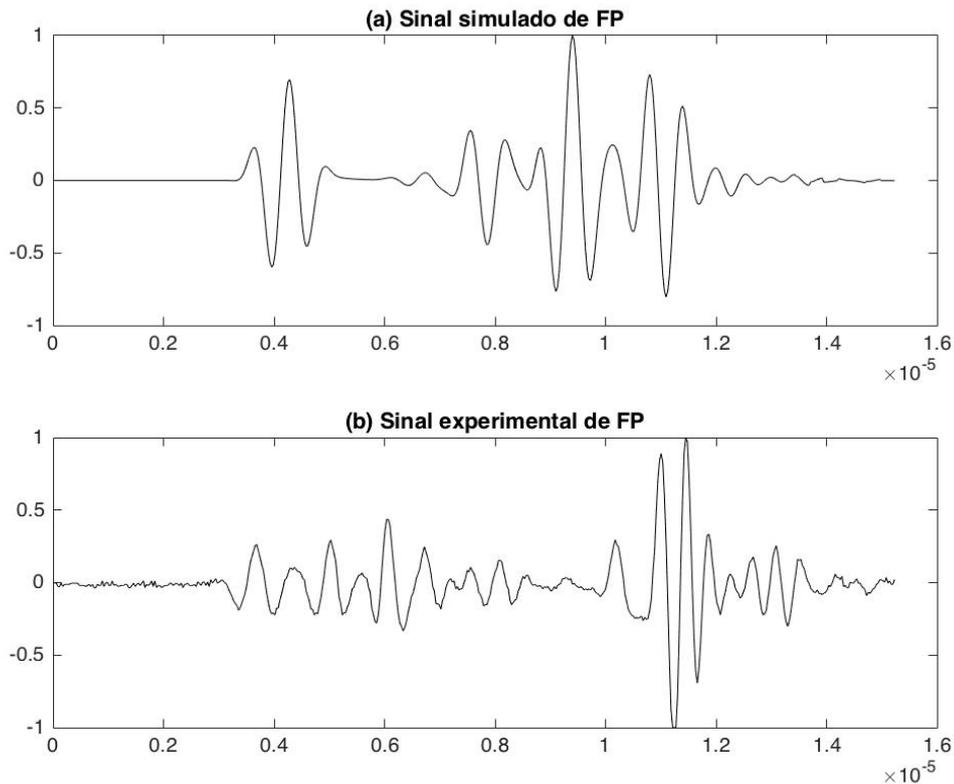
Fonte – Figura do próprio autor.

O A-scan armazena informações sobre a variação temporal da amplitude sônica medida em um ponto (na posição do transdutor receptor). Conhecida a espessura do material e o ângulo de incidência do feixe sônico é possível localizar e dimensionar descontinuidades através do tempo do percurso das ondas.

A figura 25, exhibe o (a) A-scan normalizado gerado em uma peça simulada com uma descontinuidade do tipo falta de penetração, com altura de 3,0 mm e comprimento de 1,0 mm e (b) A-scan normalizado gerado em uma peça real com a descontinuidade do tipo falta de penetração. Os sinais possuem naturezas diferentes, por isso normalizamos os mesmos com máximo ou mínimo igual a 1. O sinal capturado experimentalmente possui mais ruídos do que o sinal simulado, porém podemos observar que os picos estão localizados em posições parecidas. Veremos que isso é suficiente para que os algoritmos de reconhecimento de padrões consigam observar semelhanças nos sinais capturados experimentalmente e simulados (seção 5.3.7 até

5.3.12).

Figura 25 – A-scan gerado por um modelo contendo uma descontinuidade do tipo falta de penetração: (a) sinal simulado e (b) sinal obtido experimentalmente



Fonte – Figura do próprio autor.

Produziu-se 36 sinais de A-scan para cada tipo de descontinuidade, totalizando 108 sinais, como vimos na secção 4.5. Esses são os sinais que serão pré-processados e, posteriormente, utilizados nos algoritmos de reconhecimento de padrões.

5.2 Pré-processamento dos sinais

Pré-processamento de sinais foram aplicados tanto aos sinais simulados quanto aos obtidos experimentalmente com o intuito de verificar um possível aumento na taxa de acerto na classificação. Sinais originais (com nenhum tratamento), sinais normalizados, envoltória dos sinais e as componentes principais dos sinais foram estudados.

5.3 Reconhecimento de Padrões

Sinais simulados foram utilizados no treinamento de algoritmos de reconhecimento de padrões posteriormente empregados na classificação dos sinais ultrassônicos capturados experimentalmente. Três algoritmos de reconhecimento de padrões foram utilizados: o K -vizinhos mais próximos, rede neural artificial e o K -médias.

O k -vizinhos mais próximos (k -NN) é um algoritmo simples que classifica os dados desconhecidos (dados de teste) de acordo com a classificação dos k dados conhecidos mais próximos (exemplos de treinamento). Portanto, a determinação do número k de vizinhos mais próximos mais adequado à classificação de cada conjunto de dados de teste é uma das principais etapas do algoritmo e a primeira ser executada. Nesse trabalho, k variou de 1 a 25.

Para o classificador baseado na rede neural artificial foram testadas diferentes funções de ativações, taxas de aprendizagens e número de épocas de treinamento durante o processamento dos sinais ultrassônicos simulados e capturados experimentalmente. Os melhores resultados foram obtidos com a função de ativação do tipo sigmóide e uma taxa de aprendizagem igual a $\alpha = 0,001$.

Os resultados obtidos pelo k -vizinhos mais próximos e rede neural artificial são apresentados como matrizes de confusões nas quais cada coluna informa o tipo de descontinuidade que foi analisada, e cada linha informa como cada descontinuidade foi classificada. Consequentemente, as células da diagonal principal da matriz de confusão mostram o percentual de acerto da classificação da classe correspondente à coluna, enquanto aquelas fora da diagonal principal mostram o percentual de confusão com outra classe. A média dos valores da diagonal principal fornece a taxa média de acerto na classificação dos dados de teste.

Inicialmente, os sinais simulados foram separados aleatoriamente em dois conjuntos: 80% para treino e 20% para teste. O algoritmo foi executado e uma matriz de confusão com a classificação resultante dos dados de teste foi obtida. Como a separação dos dados é aleatória, a taxa média de acerto muda dependendo de quais dados são sorteados para treino e para teste. Para que isso não influencie no resultado, o algoritmo foi repetido 100 vezes e uma matriz de confusão média foi calculada sobre as 100 matrizes produzidas. Os resultados obtidos para cada um dos conjuntos dos sinais, com diferentes tratamentos, são apresentados das seções 5.3.1 até 5.3.6.

Em seguida, sinais capturados experimentalmente foram utilizados para testar o aprendizado dos algoritmos previamente treinados com sinais simulados. A classificação obtida

para cada um dos conjuntos de sinais capturados experimentalmente, e submetidos aos diferentes pré-processamentos, estão apresentados como matrizes de confusão nas seções 5.3.7 até 5.3.12.

O k-médias analisou diferentes maneiras de agrupar sinais ultrassônicos simulados e experimentais. Para os sinais simulados. O algoritmo testou todos os números de agrupamentos entre 2 e 11 grupos (11 é aproximadamente igual a $\sqrt{3*36} = 10,39$). Para o conjunto formado pela união dos sinais ultrassônicos simulados e sinais experimentais, foram analisados entre 2 e 17 agrupamentos ($16,97 = \sqrt{(3*36)+(3*60)}$). O algoritmo foi repetido 100 vezes para reduzir possíveis erros ocasionados pela escolha inicial aleatória dos k centroides. O número de agrupamentos considerado ótimo é dado pelo menor valor entre os sugeridos pelos índices Silhouette e Davies-Bouldin.

O número de grupos e o modo como o agrupamento foi sugerido pela análise k-médias, para cada um dos conjuntos de dados, são apresentados das seções 5.3.1 à 5.3.12.

5.3.1 Sinais ultrassônicos simulados

Os sinais ultrassônicos simulados foram processados pelo algoritmo k -NN e a melhor classificação, obtida com apenas um vizinho mais próximo ($k = 1$), é apresentada pela matriz de confusão mostrada na tabela 3. Observa-se que 99,85% dos dados associados à falta de penetração foram corretamente classificados como falta de penetração. Aproximadamente 73% dos dados pertencentes a classe poro foram reconhecidos como poro, e que cerca de 79% dos dados referentes às trincas foram corretamente identificados como trincas. A taxa média de acerto na classificação foi de 83,86%.

Tabela 3 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais ultrassônicos simulados.

	Falta de Penetração (FP)	Poro (PO)	Trinca (TR)
Classificado como FP	99,85 %	8,57 %	8,14 %
Classificado como PO	0,15 %	72,58 %	12,71 %
Classificado como TR	0 %	18,85 %	79,15 %

No processamento desses sinais pela rede neural artificial, foi obtida a melhor classificação após 1000 épocas de treinamento, resultando na matriz de confusão mostrada na tabela 4. 96,72% dos dados associados à falta de penetração foram corretamente classificados como falta de penetração. As classes poro e trinca tiveram cerca de 75% de acerto na identificação. A taxa média de acerto obtida na classificação foi de 82,33%. Resultados similares foram

e 6 reúnem, respectivamente, os sinais de falta de penetração com 3.0, 4.0, 5.0, 6.0, 7.0 e 8.0 mm de profundidade. Os sinais de poro e trinca não apresentaram um padrão no seu agrupamento.

Tabela 5 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos simulados sugerida pela k-médias.

	Falta de Penetração	Poro	Trinca
Grupo 1	7	1	1
Grupo 2	6	0	0
Grupo 3	6	1	0
Grupo 4	6	2	1
Grupo 5	5	7	4
Grupo 6	5	7	5
Grupo 7	1	6	5
Grupo 8	0	6	7
Grupo 9	0	4	6
Grupo 10	0	2	3
Grupo 11	0	0	4

5.3.2 Sinais ultrassônicos simulados normalizados

Os sinais ultrassônicos simulados normalizados apresentaram uma melhor classificação para $k = 1$, a matriz de confusão é mostrada na tabela 6. Observa-se que a classificação dos sinais de falta penetração normalizados foi de 98,85%. Aproximadamente 78% dos dados pertencentes a classe poro foram identificados como poro, e cerca de 71% dos dados referentes às trincas foram classificados como trincas. A taxa média de acerto passou de 83,86% para 82,76% com a normalização dos sinais.

Tabela 6 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais ultrassônicos simulados normalizados.

	Falta de Penetração (FP)	Poro (PO)	Trinca (TR)
Classificado como FP	98,85 %	8,28 %	1,14 %
Classificado como PO	0 %	78,15 %	27,57 %
Classificado como TR	1,15 %	13,57 %	71,29 %

A melhor classificação obtida na rede foi depois 1000 épocas, a matriz de confusão é mostrada na tabela 7. Aproximadamente 99.28% dos dados pertencentes a classe falta de penetração foram identificados corretamente, e cerca de 75% dos dados referentes aos poros foram classificados como poros. 73,85% dos dados referentes a classe trinca foram classificados como trinca. A taxa média de acerto quase não mudou com a normalização dos sinais, passou de

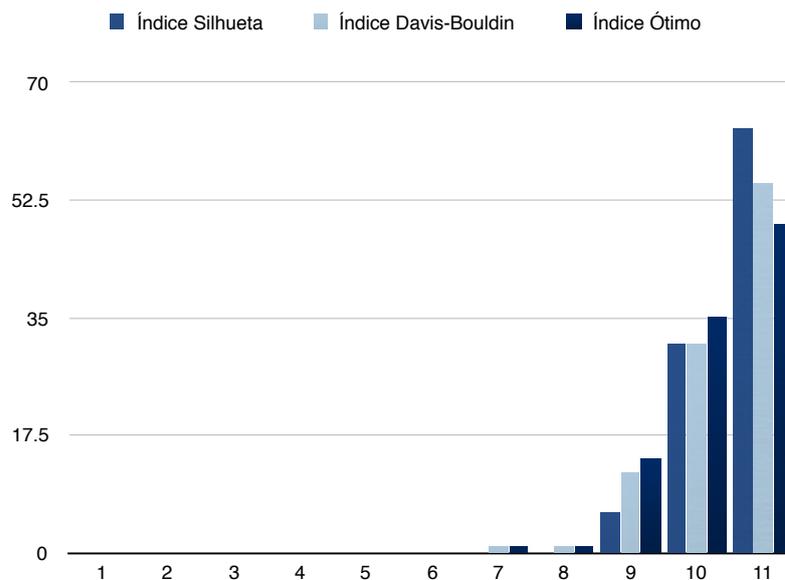
82,33% para 82,90%.

Tabela 7 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos simulados normalizados.

	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	99,28 %	11,71 %	9,00 %
Classificado como PO	0,43 %	75,57%	17,15 %
Classificado como TR	0,29 %	12,72 %	73,85 %

O k-médias também sugere que para os sinais ultrassônicos simulados normalizados a melhor maneira de agrupar os dados é em 11 grupos, como mostrado na figura 27.

Figura 27 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados normalizados.



Fonte – Figura do próprio autor.

Um exame detalhado da distribuição dos dados quando $k = 11$, revelou o mesmo padrão obtidos para os sinais ultrassônicos simulados. Os sinais ultrassônicos simulados normalizados de falta de penetração foram subdivididos em seis subconjuntos de acordo com a profundidade da descontinuidade (pouco profunda; média e profunda) e independente de sua largura. Os sinais de poros e de trinca não apresentaram um padrão no seu agrupamento, 75% dos sinais dessas duas classes foram agrupados nos grupos 7, 8, 9, 10 e 11.

Tabela 8 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos simulados normalizados sugerida pela k-médias.

	Falta de Penetração	Poros	Trinca
Grupo 1	7	1	1
Grupo 2	6	0	0
Grupo 3	6	1	0
Grupo 4	6	1	0
Grupo 5	6	2	0
Grupo 6	4	9	3
Grupo 7	1	8	5
Grupo 8	0	7	7
Grupo 9	0	5	8
Grupo 10	0	2	6
Grupo 11	0	0	6

5.3.3 *Envoltórias dos sinais ultrassônicos simulados*

A envoltória dos sinais ultrassônicos simulados apresentou uma melhor classificação para $k = 1$ no k-vizinhos mais próximos. Os sinais de teste de falta de penetração e de trinca apresentaram classificação parecidas com as obtidas para os sinais sem nenhum tratamento e os normalizados (99% de acerto para falta de penetração e 76% de acerto para trinca). Entretanto, houve uma piora significativa na classificação dos sinais do tipo poro, a porcentagem de acerto desse tipo de descontinuidade ficou em torno de 54%. A matriz de confusão é apresentada na Tabela 9. A taxa média de acerto obtida pelo k-vizinhos mais próximos na classificação da envoltória dos sinais ultrassônicos simulados foi de 76,48%.

Tabela 9 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos a envoltória dos sinais ultrassônicos simulados.

	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	99,00 %	12,85 %	11,43 %
Classificado como PO	0,15 %	54,43 %	12,57 %
Classificado como TR	0,85 %	32,72 %	76,00 %

A melhor classificação obtida pela rede neural artificial foi após 1000 épocas de treinamento, a matriz de confusão é mostrada na tabela 10. Aproximadamente 84,14% dos dados pertencentes a classe falta de penetração foram identificados corretamente. Houve uma piora significativa da taxa média de acerto dados pertencentes a classe poro e trinca com o uso da envoltória, 60,85% dos dados referentes aos poros e 67,15% dos dados referentes às trincas foram classificados corretamente. A taxa média de acerto foi de 70,71%.

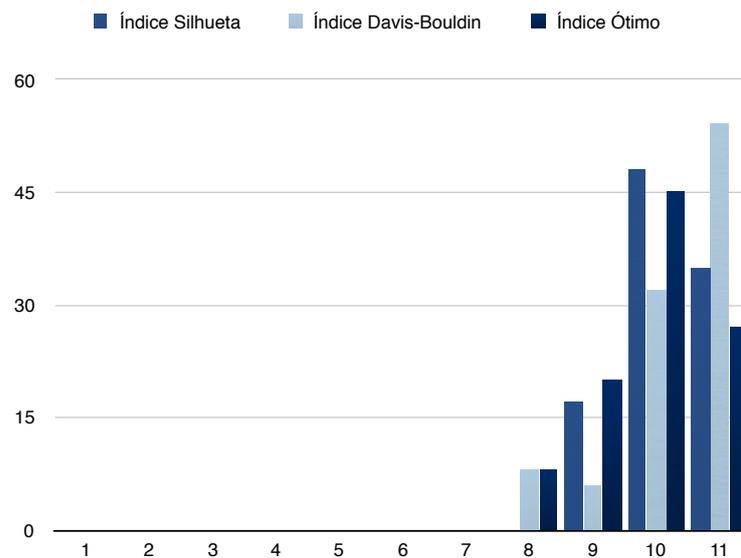
Tabela 10 – Matriz de confusão obtida pelo emprego de redes neurais artificiais a envoltória dos sinais ultrassônicos simulados.

	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	84,14 %	2,42 %	10,57 %
Classificado como PO	14,85 %	60,85 %	22,28 %
Classificado como TR	1,00 %	26,72 %	67,15 %

Percebe-se que a utilização da envoltória dos sinais ocasionou uma piora significativa na taxa média de acerto.

As envoltórias dos sinais ultrassônicos simulados foram processados pelo k-médias, e ele sugere que o melhor agrupamento desses sinais é em 10 classes, como mostra a Figura 28.

Figura 28 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para a envoltória dos sinais ultrassônicos simulados.



Fonte – Figura do próprio autor.

O agrupamento sugerido para as envoltórias dos sinais pertencentes à classe falta de penetração revelou a existência de um padrão pouco diferente que aquele para sinais simulados e simulados normalizados. O padrão revelado para as envoltórias dos sinais corresponde a {1, 2, 3, 4, 5, 5, 1, 2, 3, 4, 5, 5, 1, 2, 3, 4, 5, 5, 1, 2, 3, 4, 5, 5, 1, 2, 3, 4, 5, 5, 1, 2, 3, 4, 5, 5}, de modo que os sinais de falta de penetração foram subdivididos em cinco subconjuntos de acordo com a profundidade da descontinuidade e praticamente independente de sua largura. Geralmente, os grupos 1, 2, 3 e 4 reúnem os sinais de falta de penetração com 3.0, 4.0, 5.0 e 6.0 mm. As envoltórias dos sinais de falta de penetração com 7.0 e 8.0 mm de profundidade foram associadas, em sua maioria, ao 5º agrupamento.

Tabela 11 – Agrupamento, ou pseudo-classificação, envoltória dos sinais ultrassônicos simulados sugerida pela k-médias.

	Falta de Penetração	Poros	Trinca
Grupo 1	6	0	2
Grupo 2	6	2	3
Grupo 3	6	1	4
Grupo 4	6	3	1
Grupo 5	10	3	0
Grupo 6	2	3	6
Grupo 7	0	11	3
Grupo 8	0	6	6
Grupo 9	0	3	9
Grupo 10	0	4	2

5.3.4 Componentes principais dos sinais ultrassônicos simulados

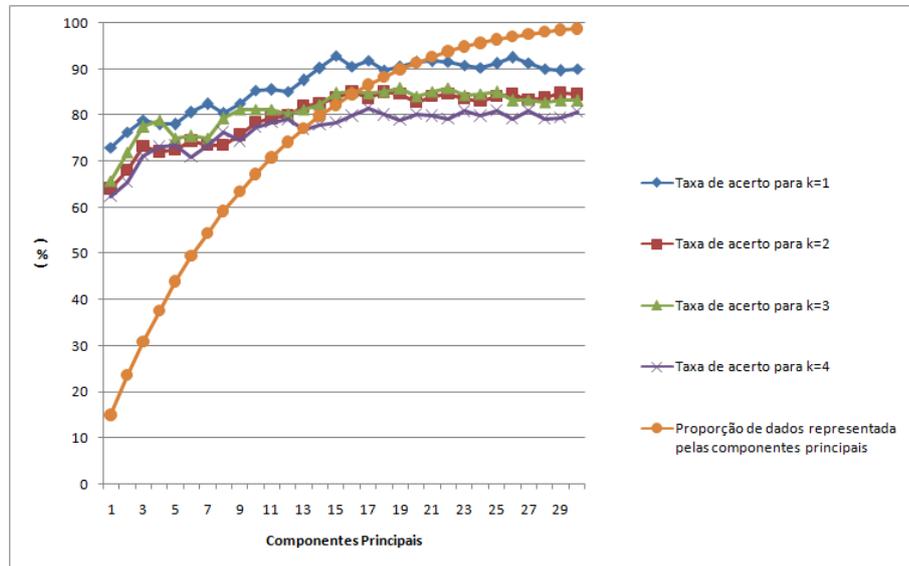
Foi avaliado se a classificação das descontinuidades a partir das componentes principais dos sinais simulados melhoraria as taxas de acerto. Como foi explicado na seção 3.8, cada componente principal mantém uma porcentagem de informações dos dados e quanto mais componentes utilizadas maior será a proporção de dados explicadas. Para uma análise mais detalhada do k-vizinhos mais próximos foi feito um estudo da variação da taxa média de acerto de acordo com o número de componentes utilizadas e do parâmetro k. Na figura 29, podemos observar esse resultado e qual a porcentagem de informações mantidas para cada número de componentes utilizadas.

A maior taxa média de acerto foi observada quando utilizamos as 15 primeiras componentes principais e $k=1$, onde cerca de 82% das informações são mantidas. A matriz de confusão é apresentada na Tabela 12. Todos os sinais do tipo falta de penetração foram classificados corretamente. Aproximadamente 88% dos sinais referentes a classe poro foi classificado como poro e 90% dos sinais referentes a classe trinca foi classificado como trinca. A taxa média de acerto aumentou em relação aos sinais simulados para 92.67%, a maior obtida pelo o k-NN.

Tabela 12 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 15 primeiras componentes principais dos sinais ultrassônicos simulados para $k=1$.

	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	100 %	6,43 %	2,42 %
Classificado como PO	0 %	87,86 %	7,42 %
Classificado como TR	0 %	5,71 %	90,16 %

Figura 29 – Variação da taxa média de acerto e da proporção de dados simulados representada de acordo com o número de componentes utilizadas.



Fonte – Figura do próprio autor.

O k-vizinhos mais próximos aplicados aos dados simulados apresentaram uma boa classificação, alcançando uma taxa média de acerto de 92.67% para as componentes principais dos sinais ultrassônicos simulados. Através dos resultados obtidos na classificação dos sinais simulados, podemos inferir que o algoritmo de reconhecimento de padrão k-vizinhos mais próximos é capaz de classificar bem esses tipo de sinais.

As 15 primeiras componentes dos sinais simulados foram processadas pelas redes neurais. Para esse conjunto de dados, o número de atributos é 15, desta forma, utilizamos apenas 9 neurônios na camada intermediária. Após 1000 épocas de treinamento, a matriz de confusão foi obtida e é apresentada na Tabela 13. 96,57% das discontinuidades do tipo falta de penetração foi classificada corretamente. Cerca de 83,57% das discontinuidades do tipo poro foram classificadas como poro, e 86% das discontinuidades do tipo trinca foram classificadas com trinca. A taxa média de acerto foi de 88,72%.

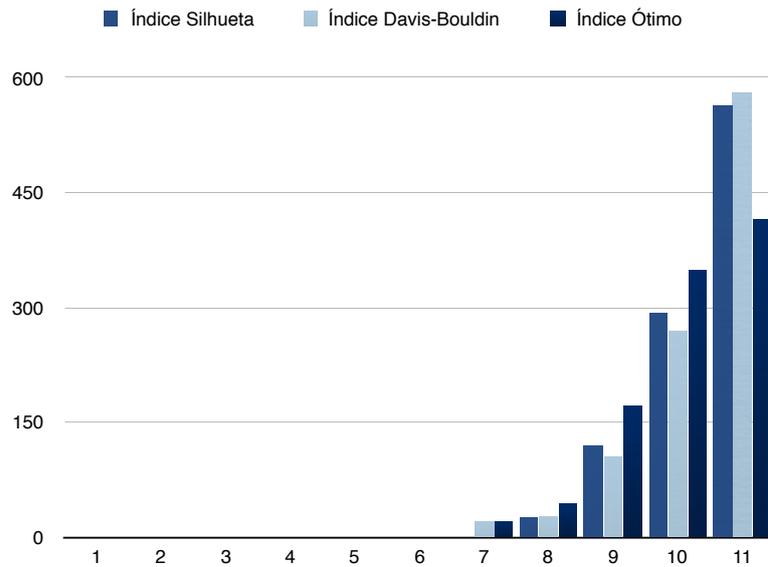
Tabela 13 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 15 primeiras componentes principais dos sinais ultrassônicos simulados.

	Falta de Penetração (FP)	Poro (PO)	Trinca (TR)
Classificado como FP	96,57 %	9,42 %	0,28%
Classificado como PO	2,85 %	83,58 %	13,72 %
Classificado como TR	0,58 %	7,00 %	86,00%

A análise de agrupamento das 15 primeiras componentes principais dos sinais

simulados sugere que 11 é número de grupos para melhor separar os dados, como mostra a figura 30.

Figura 30 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 15 primeiras componentes principais dos sinais ultrassônicos simulados.



Fonte – Figura do próprio autor.

A tabela 14 mostra o agrupamento sugerido pelo k-médias para as 15 primeiras componentes principais dos sinais ultrassônicos simulados. As componentes principais pertencentes à classe falta de penetração foram subdivididas em seis subconjuntos de acordo com a profundidade da descontinuidade e praticamente independente de sua largura. O agrupamento revelou a repetição de um padrão que corresponde a $\{1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6, 1, 2, 3, 4, 5, 6\}$, padrão semelhante ao observado na análise do agrupamento dos sinais de falta de penetração simulados. As componentes principais dos sinais pertencentes à classe poro foram distribuídas em 9 grupos. Nenhuma das componentes principais dos sinais obtidos através da simulação contendo um defeito do tipo poro foi associado aos grupos 2 e 11. As componentes principais dos sinais pertencentes à classe trinca foram distribuídos em 7 grupos. Nenhuma das componentes principais do sinal de trinca foi associado aos quatro primeiros grupos.

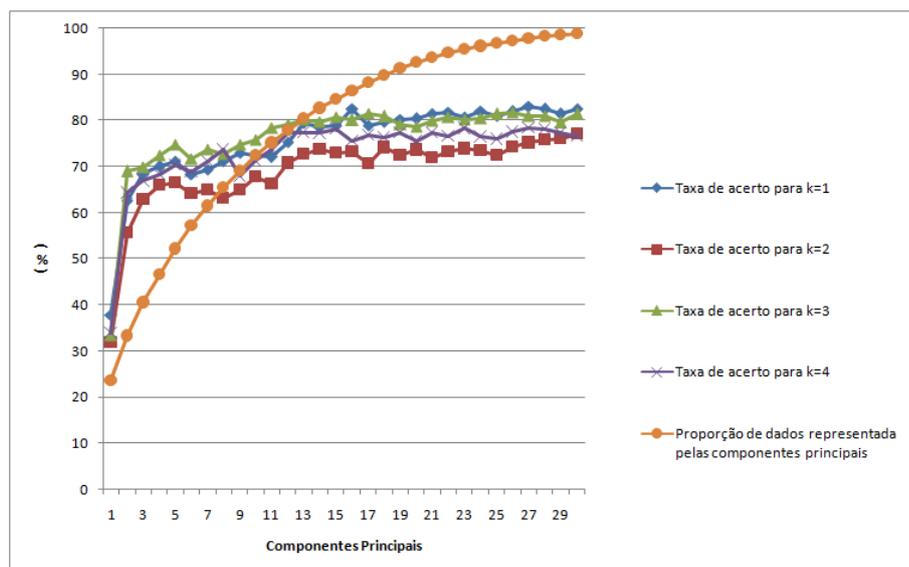
Tabela 14 – Agrupamento, ou pseudo-classificação, das 15 primeiras componentes principais dos sinais ultrassônicos simulados sugerida pela k-médias.

	Falta de Penetração	Poros	Trinca
Grupo 1	6	2	0
Grupo 2	6	0	0
Grupo 3	6	1	0
Grupo 4	6	2	0
Grupo 5	6	4	1
Grupo 6	5	9	2
Grupo 7	1	6	5
Grupo 8	0	6	6
Grupo 9	0	4	7
Grupo 10	0	2	8
Grupo 11	0	0	7

5.3.5 Componentes principais dos sinais ultrassônicos simulados normalizados

O algoritmo k-vizinhos mais próximos foi aplicado as componentes principais dos sinais ultrassônicos simulados normalizados e o mesmo estudo sobre a variação da taxa média de acerto de acordo com o número de componentes utilizadas e do parâmetro k foi realizado. Na figura 31, podemos observar esse resultado e qual a porcentagem de informações mantidas para cada número de componentes.

Figura 31 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas para k=1.



Fonte – Figura do próprio autor.

A maior taxa média de acerto foi observada quando utilizamos as 16 primeiras

componentes principais e $k=1$, onde cerca de 86% das informações são mantidas. A matriz de confusão é apresentada na Tabela 15. A grande maioria dos sinais do tipo falta de penetração foram classificadas corretamente (99.57%). Aproximadamente 83% dos sinais referentes a classe poro foi classificado como poro e 60% dos sinais referentes a classe trinca foi classificado como trinca. A taxa média de acerto foi de 81.05%, houve uma pequena queda no resultado quando comparado a taxa média de acerto dos sinais ultrassônicos simulados normalizados.

Tabela 15 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados para $k=1$.

	Falta de Penetração (FP)	Poro (PO)	Trinca (TR)
Classificado como FP	99.57 %	1.28 %	2.28 %
Classificado como PO	0 %	83.28 %	37.42 %
Classificado como TR	0.43 %	15.44 %	60.30 %

As 16 primeiras componentes dos sinais simulados normalizados foram processadas pelas redes neurais. Para esse conjunto de dados, o número de atributos é 16, desta forma, utilizamos apenas 9 neurônios na camada intermediária. A matriz de confusão foi obtida depois de 1000 épocas de treinamento é apresentada na Tabela 16.

Tabela 16 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados.

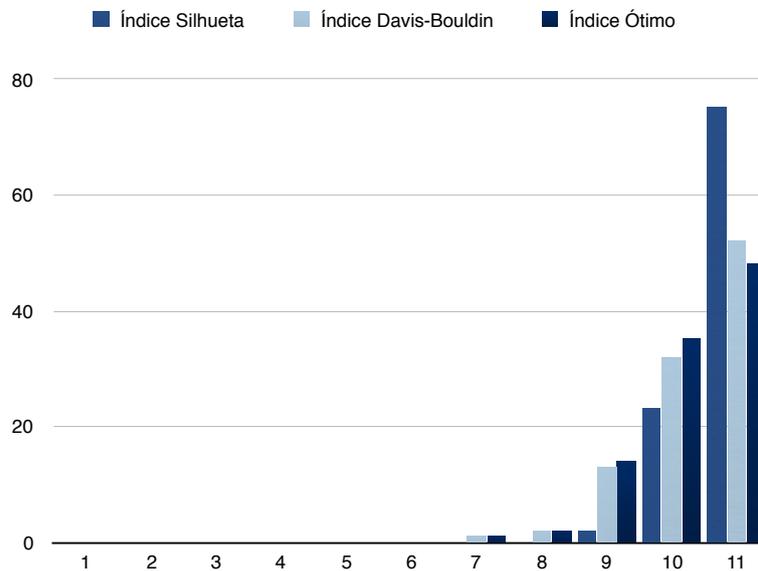
	Falta de Penetração (FP)	Poro (PO)	Trinca (TR)
Classificado como FP	95,15 %	6,00 %	9,72%
Classificado como PO	2,15 %	70,85 %	22,14 %
Classificado como TR	2,70 %	23,15 %	68,14%

Aproximadamente 95% das descontinuidades do tipo falta de penetração foram classificadas como falta de penetração. Cerca de 70% das descontinuidades do tipo poro foram classificadas como poro, e 68% das descontinuidades do tipo trinca foram classificadas com trinca. A taxa média de acerto foi de 78%. O k-vizinhos mais próximos obteve uma classificação melhor do que as redes neurais para o conjunto de dados estudado.

Foi utilizado as 16 primeiras componentes principais dos sinais simulados normalizados no algoritmo k-médias. O k-médias sugere que o melhor agrupamento desses sinais é em 11 classes, como mostra a Figura 32.

A tabela 17 mostra o agrupamento sugerido pelo k-médias para as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados. O agrupamento sugerido para os sinais simulados normalizados pertencentes à classe falta de penetração revelou a repeti-

Figura 32 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados.



Fonte – Figura do próprio autor.

ção do mesmo padrão observado para a análise de componentes principais dos sinais simulados. Os sinais de falta de penetração com 2.0, 3.0, 4.0, 5.0, 6.0 e 7.0 mm de profundidade foram, normalmente, reunidos, respectivamente, nos grupos 1, 2, 3, 4, 5 e 6. Os sinais pertencentes à classe poro foram distribuídos em 10 grupos. O grupo 2 contém apenas sinais do tipo falta de penetração. Novamente, os sinais pertencentes à classe trinca foram distribuídos em 7 grupos e nenhum sinal de trinca foi associado aos quatro primeiros grupos.

Tabela 17 – Agrupamento, ou pseudo-classificação, das 16 primeiras componentes principais dos sinais ultrassônicos simulados normalizados sugerida pela k-médias.

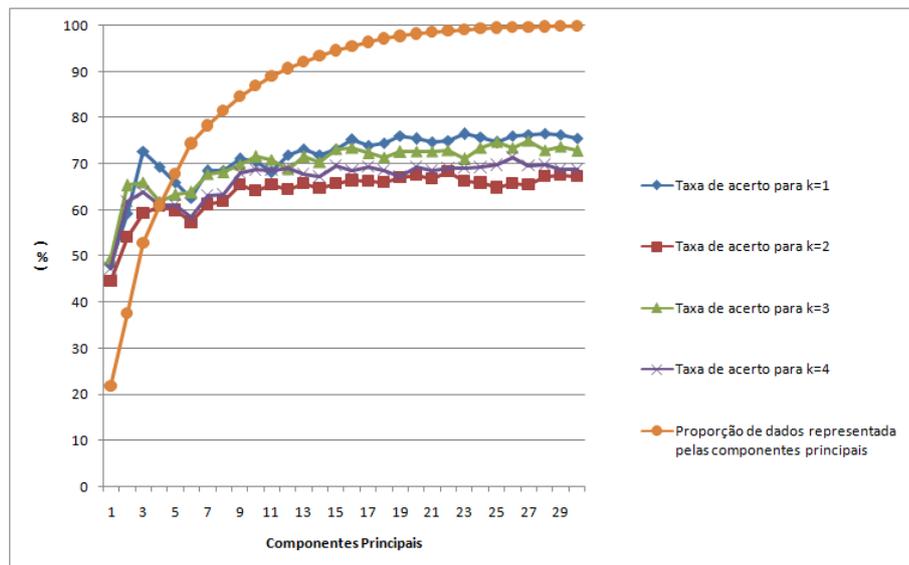
	Falta de Penetração	Poro	Trinca
Grupo 1	6	2	0
Grupo 2	6	0	0
Grupo 3	6	1	0
Grupo 4	6	2	0
Grupo 5	6	2	2
Grupo 6	5	5	4
Grupo 7	1	8	6
Grupo 8	0	7	7
Grupo 9	0	5	6
Grupo 10	0	3	4
Grupo 11	0	1	7

5.3.6 Componentes principais das envoltórias dos sinais ultrassônicos simulados

A análise de componentes principais também foi aplicada a envoltória dos sinais ultrassônicos simulados, com o intuito de verificar se para esse conjunto de sinais as descontinuidades são melhores classificadas.

O k-vizinho mais próximos foi aplicado às componentes principais das envoltórias dos sinais. A variação na taxa média de acerto em função do parâmetro k de vizinhos mais próximos e do número de componentes utilizadas, bem como o percentual de informações mantidas em cada componente, é mostrada na figura 33.

Figura 33 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas.



Fonte – Figura do próprio autor.

A maior taxa média de acerto foi observada quando utilizamos as 22 primeiras componentes principais e $k=1$, onde cerca de 99% das informações são mantidas. Cerca de 98% dos sinais com descontinuidades do tipo falta de penetração foram classificados como falta de penetração, de 61% dos sinais com descontinuidades do tipo poro foram classificados como poro e 66% dos sinais com tipo trinca foram classificados como trinca. A taxa média de acerto foi de 74.86%, resultado semelhante ao obtido quando aplicado o K-NN a envoltória dos sinais ultrassônicos simulados. A matriz de confusão é apresentada na tabela 18.

As 22 primeiras componentes principais da envoltória dos sinais simulados foram processadas pela rede neural. Para esse conjunto de dados, que apresenta 22 atributos, foram

Tabela 18 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados.

	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	97.71 %	7.28 %	17.57 %
Classificado como PO	0.57 %	60.72 %	16.28 %
Classificado como TR	1.72 %	32.00 %	66.15 %

utilizados 12 neurônios na camada intermediária A matriz de confusão, obtida após 1000 épocas de treinamento, está apresentada na tabela 19. Cerca de 95% das descontinuidades do tipo falta de penetração foram classificadas como falta de penetração. 67% das descontinuidades do tipo poro foram classificadas como poro, e aproximadamente 77% das descontinuidades do tipo trinca foram classificadas com trinca. A taxa média de acerto foi de 79,62%. A rede neural apresentou uma taxa média de acerto aproximadamente 5% maior do que o algoritmo k-vizinhos mais próximos para esse conjunto de dados.

Tabela 19 – Matriz de confusão obtida pelo emprego de redes neurais artificiais as 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados.

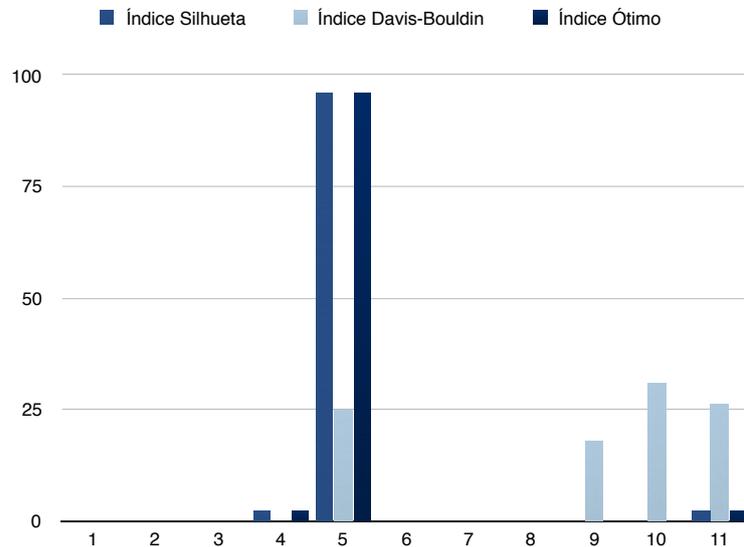
	Falta de Penetração (FP)	Poros (PO)	Trinca (TR)
Classificado como FP	95,15 %	12,57 %	12,43%
Classificado como PO	3,85 %	67,00 %	10,85 %
Classificado como TR	1,00 %	20,43 %	76,82%

Foram utilizadas as 22 primeiras componentes principais da envoltória dos sinais simulados no algoritmo k-médias, e ele sugere que o melhor agrupamento desses sinais é em 5 classes, como mostra a figura 34.

A tabela 20 mostra o agrupamento sugerido pelo k-médias para as 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados. Os 36 dados pertencentes à classe falta de penetração foram distribuídos em 3 grupos como mostram os índices a seguir, que revelam a existência de um padrão mais fortemente relacionado à profundidade da descontinuidade e com alguma relação à sua largura. Todas as faltas de penetração com 2,0 e 3,0 mm de profundidade foram associadas ao grupo 1, com 4,0 e 5,0 mm de profundidade foram associadas ao grupo 2 e com 6,0 e 7,0 mm de profundidade foram associadas ao grupo 3. A maioria dos dados de poro (66,67%) foram associados ao grupo 4 e a maioria dos dados de trinca (63,89%) foram reunidos no grupo 5.

A falta de penetração, introduzida na seção 3.1.1, é uma descontinuidade caracterizada pela insuficiência de metal na raiz da solda e, conseqüentemente, sua posição no centro

Figura 34 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 22 primeiras componentes principais para a envoltória dos sinais ultrassônicos simulados.



Fonte – Figura do próprio autor.

Tabela 20 – Agrupamento, ou pseudo-classificação, das 22 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados sugerida pela k-médias.

	Falta de Penetração	Poro	Trinca
Grupo 1	12	6	5
Grupo 2	12	3	4
Grupo 3	12	3	4
Grupo 4	0	22	21
Grupo 5	0	2	2

do cordão de solda facilita sua localização. Evidentemente, a modelagem desse tipo de descontinuidade levou em consideração a posição de sua ocorrência em relação ao centro do cordão. Por outro lado, não existem sítios específicos ou regiões preferenciais para formação de poros (seção 3.1.2) e trincas (seção 3.1.3), que podem aparecer em posições aleatórias. Diante disso, podemos supor que o fato da falta de penetração sempre ocorrer no centro do cordão facilita a sua classificação em relação ao poro e a trinca.

5.3.7 Sinais ultrassônicos capturados experimentalmente e simulados

Os sinais simulados foram empregados no treinamento dos algoritmos posteriormente utilizados na classificação dos sinais capturados experimentalmente.

Assim como nos agrupamentos anteriores, um estudo do k ótimo foi realizado. A melhor classificação foi obtida quando k=1, a matriz de confusão é mostrada na Tabela 21. Todos os sinais experimentais foram classificados como pertencentes a classe Poro. Desta forma, a taxa média de acerto na classificação foi de apenas 33,33%.

Tabela 21 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais capturados experimentalmente quando utilizados os sinais simulados na fase de teste para k=1.

	Falta de Penetração (FP)	Poro (PO)	Falta de Fusão (FF)
Classificado como FP	0 %	0 %	0 %
Classificado como PO	100,00 %	100,00 %	100,00%
Classificado como TR	0 %	00 %	0 %

No processamento desses sinais pela rede neural artificial, foi obtida a melhor classificação após 200 épocas de treinamento, resultando na matriz de confusão mostrada na Tabela 22. A classe falta de penetração foi a melhor classificada, 58,54% dos dados associados à falta de penetração foram corretamente classificados. 40,45% dos dados associados à trinca foram classificados como trinca e, somente, 29,98% dos dados pertencentes a classe poro foram identificados como poro. A taxa média de acerto obtida na classificação foi de 42,99%.

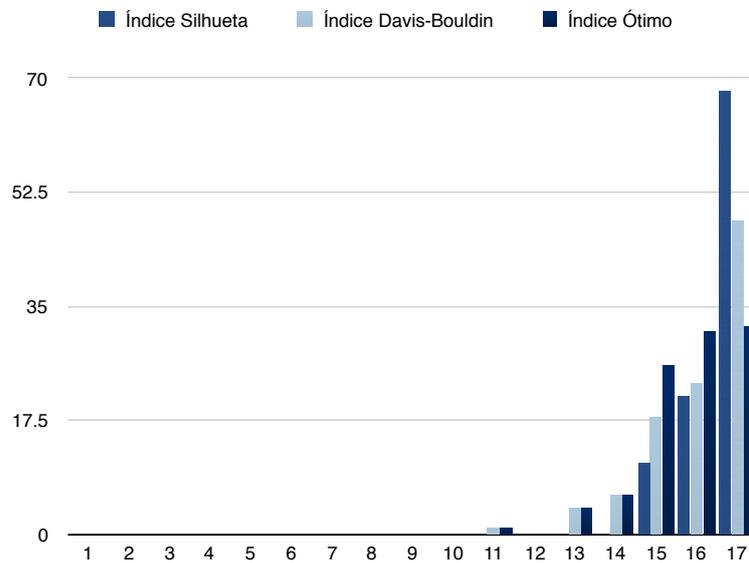
Tabela 22 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos capturados experimentalmente.

	Falta de Penetração (FP)	Poro (PO)	Falta de Fusão (FF)
Classificado como FP	58,54 %	41,55 %	26,35 %
Classificado como PO	10,18 %	29,98 %	33,20%
Classificado como TR	31,28 %	28,47 %	40,45 %

Um conjunto de sinais formado pela união dos sinais ultrassônicos simulados e capturados experimentalmente também foi analisado pelo algoritmo k-médias, que sugeriu que o melhor agrupamento dos sinais acontece em 16 grupos, como mostra a figura 35.

O agrupamento sugerido pelo k-médias é mostrado na tabela 26. A tabela mostra como esses dados foram agrupados, onde FP, PO, TR, FF, Sim e Exp foram as nomenclaturas utilizadas para os dados pertencentes a classe Falta de Penetração, Poro, Trinca, Falta de Fusão, simulados e capturados experimentalmente, respectivamente. Todos os sinais capturados experimentalmente foram agrupados nos grupos 6,7,8 e 9. Os sinais pertencentes a classe falta de penetração simulados foram subdivididos em seis subconjuntos de acordo com a profundidade da descontinuidade e praticamente independente de sua largura. Geralmente, os grupos 1, 2, 3,

Figura 35 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados e capturados experimentalmente.



Fonte – Figura do próprio autor.

4 e 5 reúnem os sinais de falta de penetração com 3.0, 4.0, 5.0, 6.0 e 7.0 mm de profundidade e os grupos 6 e 8 reúnem os sinais de falta de penetração simulados com 8 mm de profundidade. Novamente, os sinais simulados de poro e trinca não apresentaram um padrão no seu agrupamento.

5.3.8 Sinais ultrassônicos capturados experimentalmente e simulados normalizados

Sinais simulados e experimentais foram normalizados antes de serem submetidos novamente à análise de agrupamento. Para sinais normalizados o agrupamento considerado ótimo foi obtido com 22 grupos ($k = 22$). A matriz de confusão é apresentada na tabela 24. Somente 33.40% dos dados com descontinuidade do tipo falta de penetração foram corretamente classificados. A classificação do poro e da falta de fusão foi de 40.00% e 39.17%, respectivamente. Portanto, a taxa média de acerto na classificação foi de 37.52%.

Sinais simulados e capturados experimentalmente normalizados foram classificados pela rede neural artificial. A melhor classificação foi obtida após 1000 épocas de treinamento. A matriz de confusão é mostrada na Tabela 25. 53,67 % dos dados associados à falta de penetração foram corretamente classificados. 36,67% dos dados associados a poro foram classificados como poro e 40% dos dados pertencentes a classe trinca foram identificados como trinca. A taxa média de acerto foi de 40,11%, parecida com a obtida quando os sinais não foram pré-processados

Tabela 23 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias.

	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	6	0	1	0	0	0
Grupo 2	6	0	1	0	0	0
Grupo 3	6	0	0	0	0	0
Grupo 4	6	0	1	0	0	0
Grupo 5	6	0	1	0	1	0
Grupo 6	3	1	7	1	4	1
Grupo 7	3	15	1	15	1	15
Grupo 8	0	39	2	39	3	39
Grupo 9	0	5	5	5	3	5
Grupo 10	0	0	6	0	4	0
Grupo 11	0	0	5	0	5	0
Grupo 12	0	0	4	0	4	0
Grupo 13	0	0	2	0	2	0
Grupo 14	0	0	0	0	2	0
Grupo 15	0	0	0	0	2	0
Grupo 16	0	0	0	0	3	0
Grupo 17	0	0	0	0	2	0

Tabela 24 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos aos sinais capturados experimentalmente normalizados quando utilizados os sinais simulados normalizados na fase de teste para k=22.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	33.40 %	28.37 %	6.65 %
Classificado como PO	14.22 %	40.00 %	54.18%
Classificado como TR	44.05 %	31.63 %	39.17 %

(42,99%).

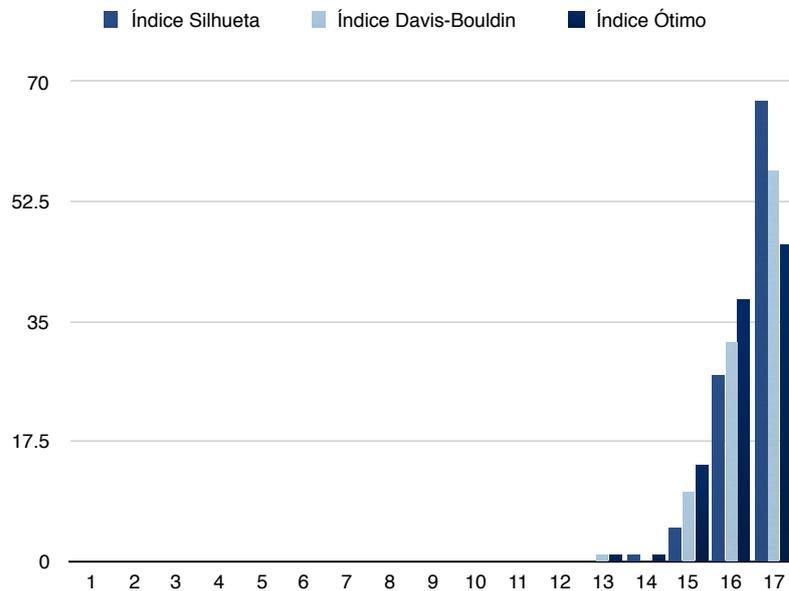
Tabela 25 – Matriz de confusão obtida pelo emprego de redes neurais artificiais aos sinais ultrassônicos capturados experimentalmente normalizados.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	43,67 %	25,33 %	25,00 %
Classificado como PO	16,67 %	36,67 %	35,00%
Classificado como TR	39,66 %	38,00 %	40,00 %

O k-médias sugere agrupar os sinais simulados e capturados experimentalmente normalizados em 17 classes, como mostra a figura 36.

A classificação obtida pelo k-média para o conjunto de dados normalizados não apresentou um padrão na classificação dos sinais. Os sinais capturados experimentalmente foram agrupados em todos os 17 grupos. 31% dos sinais de falta de fusão capturados experimentalmente foram agrupados no grupo 17.

Figura 36 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para os sinais ultrassônicos simulados e capturados experimentalmente normalizados.



Fonte – Figura do próprio autor.

5.3.9 *Envoltórias dos sinais ultrassônicos capturados experimentalmente e simulados*

A envoltória dos sinais ultrassônicos capturados experimentalmente foram classificados pelo k-vizinhos mais próximos, anteriormente treinado com a envoltória dos sinais ultrassônicos simulados, e a melhor classificação foi obtida quando $k=1$, a matriz de confusão está sendo mostrada na Tabela 27. O k-NN não classificou os sinais capturados experimentalmente corretamente, a maioria dos sinais foram classificados como poro. A taxa média de acerto foi de somente 29.45%.

Uma rede neural, previamente treinada com a envoltória de sinais simulados, foi empregada para classificar sinais capturados experimentalmente. A melhor classificação foi obtida após 1000 épocas de treinamento. A matriz de confusão é mostrada na tabela 28. 46,33 % dos dados associados à falta de penetração foram corretamente classificados. 36,17 % dos dados associados a poro foram classificados como poro e 40,50% dos dados pertencentes a classe trinca foram identificados como trinca. A taxa média de acerto foi de 41%, parecida com a obtida quando para os sinais sem pre-processamento e normalizados.

Para a envoltória dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados o k-médias sugeriu que a melhor maneira de agrupar os dados é em 5 classes, como mostra a figura 37.

Tabela 26 – Agrupamento, ou pseudo-classificação, dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias.

	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	11	6	1	4	2	0
Grupo 2	9	2	1	3	1	0
Grupo 3	7	1	2	2	1	0
Grupo 4	5	1	8	2	6	0
Grupo 5	3	3	7	5	6	0
Grupo 6	1	7	3	7	4	1
Grupo 7	0	10	1	5	3	2
Grupo 8	0	8	2	4	1	3
Grupo 9	0	8	1	5	1	2
Grupo 10	0	6	1	4	2	2
Grupo 11	0	6	2	3	3	2
Grupo 12	0	3	3	2	3	2
Grupo 13	0	1	3	3	3	4
Grupo 14	0	0	1	5	1	5
Grupo 15	0	0	0	4	0	7
Grupo 16	0	0	0	2	0	11
Grupo 17	0	0	0	0	0	19

Tabela 27 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos a envoltória dos sinais capturados experimentalmente quando utilizados os sinais simulados normalizados na fase de teste para k=1.

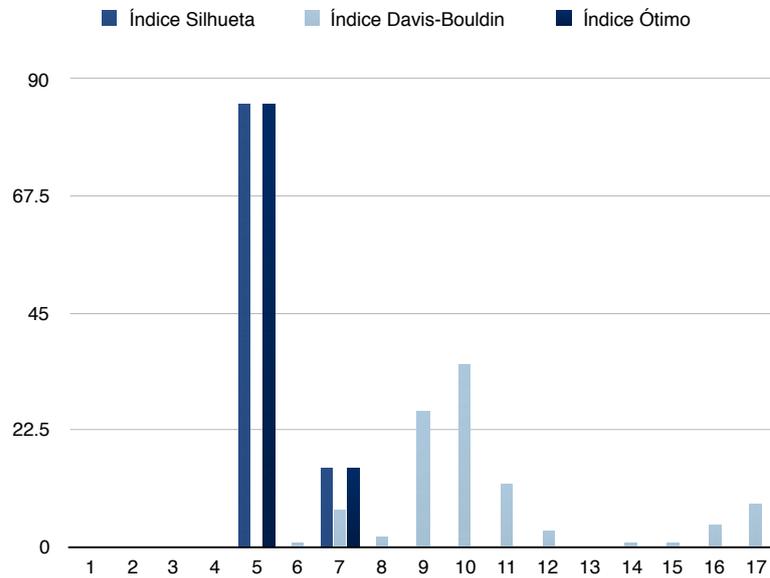
	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	1.67 %	0 %	0 %
Classificado como PO	65 %	81.67 %	95 %
Classificado como TR	33.33 %	18.33 %	5 %

Tabela 28 – Matriz de confusão obtida pelo emprego de redes neurais artificiais a envoltória dos sinais ultrassônicos capturados experimentalmente.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	46,33 %	29,00 %	25,67 %
Classificado como PO	15,50 %	36,17 %	33,83 %
Classificado como TR	38,17 %	34,83 %	40,50 %

Na tabela 29 é mostrado o agrupamento sugerido. Os sinais simulados e os capturados experimentalmente de cada uma das classes não foram agrupados no mesmo grupo. No grupo 1 e 2, foram agrupados somente os sinais simulados. Já ao grupo 4, foram associado somente os sinais capturados experimentalmente.

Figura 37 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para a envoltória dos sinais ultrassônicos simulados e capturados experimentalmente.



Fonte – Figura do próprio autor.

Tabela 29 – Agrupamento, ou pseudo-classificação, das envoltórias dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias.

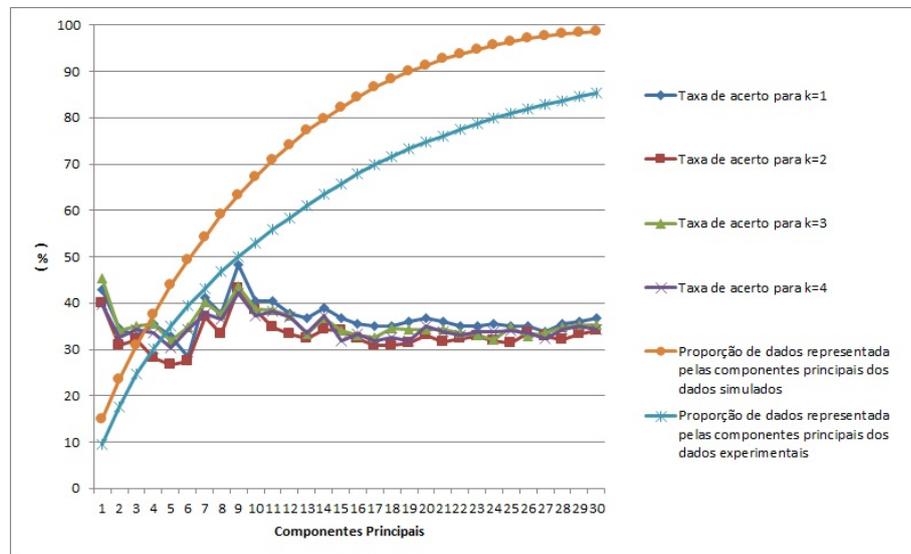
	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	18	0	6	0	0	0
Grupo 2	18	0	6	0	0	0
Grupo 3	0	26	7	33	8	0
Grupo 4	0	23	0	27	0	60
Grupo 5	0	11	17	0	12	0

5.3.10 Componentes principais dos sinais ultrassônicos capturados experimentalmente e simulados

Após o treinamento do algoritmo k-vizinhos mais próximos, realizado com as primeiras componentes principais de sinais simulados, a etapa de teste foi executada com a classificação das respectivas componentes principais dos sinais capturados experimentalmente. Assim como para os conjuntos de sinais estudados anteriormente, um estudo da variação da taxa média de acerto com o parâmetro k foi realizado, como pode ser observado na Figura 38.

A maior taxa média de acerto foi obtida quando utilizadas as 9 primeiras componentes principais e k=1. Aproximadamente 50% e 63% das informações são mantidas utilizando as 9 primeiras componentes dos dados de treino e teste, respectivamente. A matriz de confusão é apresentada na Tabela 30. Observa-se que 60% e 53.33% dos dados do tipo poro e trinca,

Figura 38 – Variação da taxa média de acerto e da proporção de dados simulados e experimentais representados de acordo com o número de componentes utilizadas.



Fonte – Figura do próprio autor.

respectivamente, foram classificados corretamente. Já a média de acerto da classificação da descontinuidade do tipo falta de penetração foi de somente 31.67%. A taxa média de acerto foi de 48.33%.

Tabela 30 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 9 primeiras componentes principais dos sinais capturados experimentalmente quando utilizados as 9 primeiras componentes principais aos sinais simulados na fase de teste para k=1.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	31.67 %	16.67 %	23.33 %
Classificado como PO	46.67 %	60.00 %	23.33 %
Classificado como TR	21.66 %	23.33 %	53.33 %

As 9 primeiras componentes principais dos sinais simulados e dos sinais capturados experimentalmente foram utilizadas, respectivamente, para treinamento e teste do classificador baseado na rede neural. Cada par de treinamento, bem como cada dado de teste, possui 9 atributos (constituídas pelas 9 primeiras componentes principais). Assim, foram utilizados 6 neurônios na camada intermediária da rede neural. Uma matriz de confusão foi obtida após 1000 épocas de treinamento e está apresentada na tabela 31. A classificação obtida para os sinais capturados experimentalmente não foi satisfatória. A rede neural apresentou uma taxa média de acerto de apenas 30% para esse conjunto de sinais.

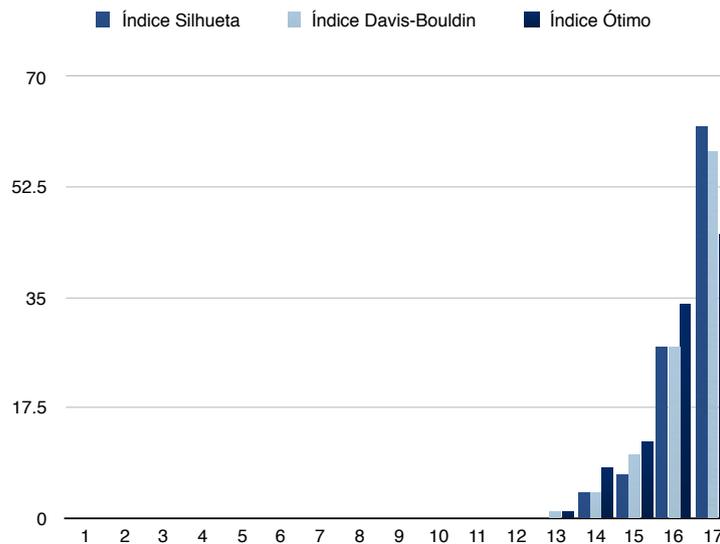
As 9 primeiras componentes principais dos sinais ultrassônicos simulados e captura-

Tabela 31 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 9 primeiras componentes principais dos sinais capturados experimentalmente quando utilizados as 9 primeiras componentes principais dos sinais simulados na fase de teste.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	28,22 %	42,43 %	58,62 %
Classificado como PO	46,58 %	33,32 %	12,82 %
Classificado como TR	25,20 %	24,25 %	28,56 %

dos experimentalmente foram processados pelo k-médias e ele sugeriu que o melhor agrupamento desses sinais é em 17 classes, como mostra a figura 39.

Figura 39 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 9 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados.



Fonte – Figura do próprio autor.

O resultados da análise de agrupamento é mostrado na tabela 32. Os sinais capturados experimentalmente foram agrupados em todos os 17 conjuntos E não foi possível detectar nenhum padrão no agrupamento dos mesmos.

5.3.11 Componentes principais dos sinais ultrassônicos capturados experimentalmente e simulados normalizados

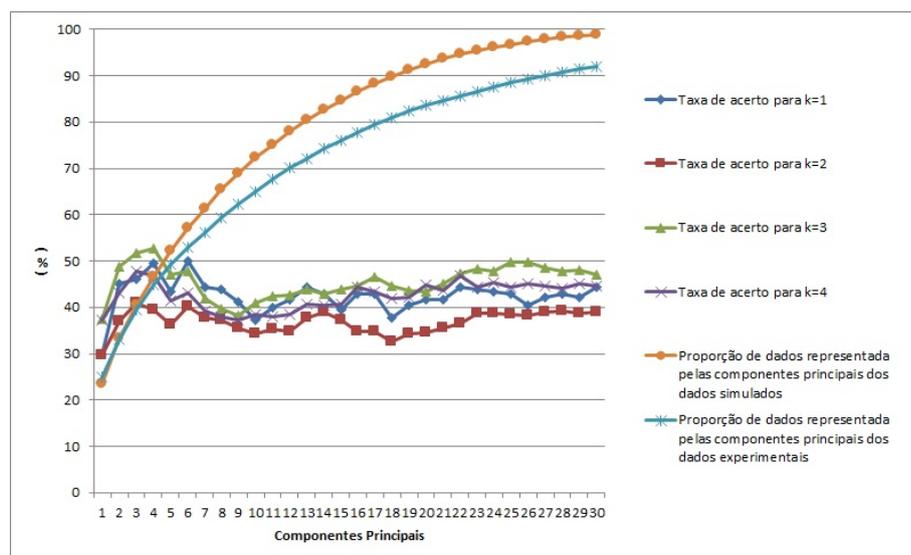
Uma nova análise de agrupamento foi realizada sobre o conjunto de dados composto pela união das componentes principais dos sinais simulados normalizados e dos sinais capturados

Tabela 32 – Agrupamento, ou pseudo-classificação, das 9 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados sugerido pelo k-médias.

	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	6	0	1	2	0	4
Grupo 2	7	1	0	2	0	6
Grupo 3	6	6	2	3	0	2
Grupo 4	5	6	3	4	1	1
Grupo 5	5	5	5	5	1	1
Grupo 6	5	4	3	3	0	3
Grupo 7	2	7	4	2	2	4
Grupo 8	0	6	6	4	3	5
Grupo 9	0	6	5	6	4	2
Grupo 10	0	3	4	3	5	4
Grupo 11	0	3	3	3	3	4
Grupo 12	0	3	2	5	3	2
Grupo 13	0	2	0	5	3	3
Grupo 14	0	2	0	4	6	4
Grupo 15	0	3	0	4	3	3
Grupo 16	0	3	0	5	2	5
Grupo 17	0	0	0	0	0	7

experimentalmente normalizados. O estudo da variação da taxa média de acerto de acordo com o parâmetro k, pode ser observado na figura 40.

Figura 40 – Variação da taxa média de acerto e da proporção de dados normalizados representada de acordo com o número de componentes utilizadas.



Fonte – Figura do próprio autor.

A maior taxa média de acerto foi obtida quando utilizadas as 4 primeiras componentes

principais e $k=3$. Aproximadamente 50% e 52% das informações são mantidas utilizando as 4 primeiras componentes dos dados de treino e teste, respectivamente. A matriz de confusão é apresentada na Tabela 33. A maioria dos sinais (75,5%) referentes à classe poro foram classificados corretamente. Cerca de 47% dos sinais referentes a classe falta de fusão foram classificadas como trinca e 36% do tipo falta de penetração foi classificada corretamente. A taxa média de acerto foi de 52,70%, a maior obtida para a classificação dos dados capturados experimentalmente.

Tabela 33 – Matriz de confusão obtida pelo emprego do k-vizinhos mais próximos as 4 primeiras componentes principais dos sinais capturados experimentalmente normalizados quando utilizados as 4 primeiras componentes principais aos sinais simulados normalizados na fase de teste para $k=3$.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	36 %	9 %	25.11 %
Classificado como PO	46 %	75.50 %	28.25 %
Classificado como TR	18 %	15.50 %	46.64 %

Um classificador baseado numa rede neural artificial foi treinado com as 4 primeiras componentes principais dos sinais simulados normalizados e testado com as 4 primeiras componentes principais dos sinais capturados experimentalmente normalizados. Cada par de treinamento, bem como os dados de teste, contém 4 atributos. Assim, a camada intermediária da rede neural empregada para analisar esse dados foi composta por 3 neurônios. Cada par de treinamento foi apresentado 1000 vezes (1000 épocas de treinamento). A matriz de confusão é apresentada na tabela 34. 41,52% e 51,77% dos sinais do tipo falta de penetração e falta de fusão foram classificados corretamente. Apenas 17,02% dos sinais do tipo poro foram classificados como poro. A rede neural apresentou uma taxa média de acerto de 36,77%.

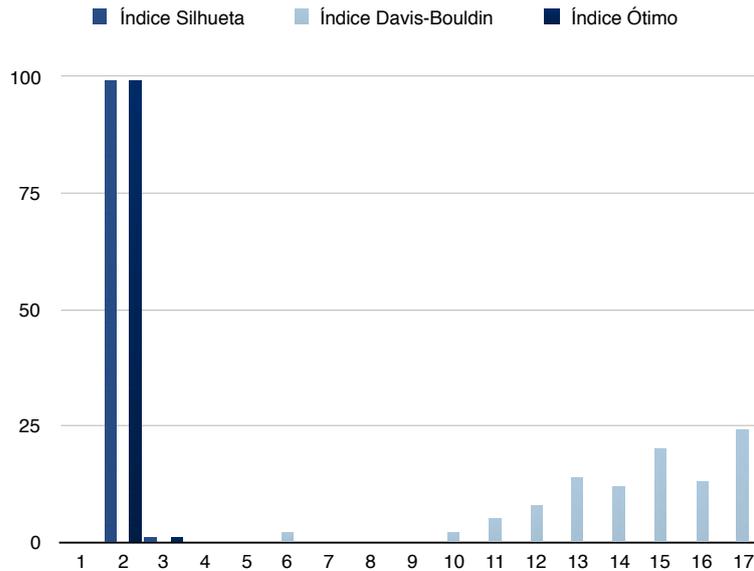
Tabela 34 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 4 primeiras componentes principais dos sinais capturados experimentalmente normalizados quando utilizados as 4 primeiras componentes principais dos sinais simulados normalizados na fase de teste.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	41,52 %	38,40 %	46,65 %
Classificado como PO	21,92 %	17,02 %	1,58 %
Classificado como TR	36,56 %	44,58 %	51,77 %

O k-médias agrupou as 4 primeiras componentes principais dos sinais simulados normalizados e dos sinais capturados experimentalmente normalizados. O algoritmo sugere que

a melhor maneira de agrupar esses sinais é em 2 classes, como mostra a figura 41. A tabela 35 mostra o agrupamento sugerido.

Figura 41 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 4 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados normalizados.



Fonte – Figura do próprio autor.

Tabela 35 – Agrupamento, ou pseudo-classificação, das 4 primeiras componentes principais dos sinais ultrassônicos capturados experimentalmente normalizados e dos sinais simulados normalizados sugerido pelo k-médias.

	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	22	40	23	52	32	59
Grupo 2	14	20	13	8	4	1

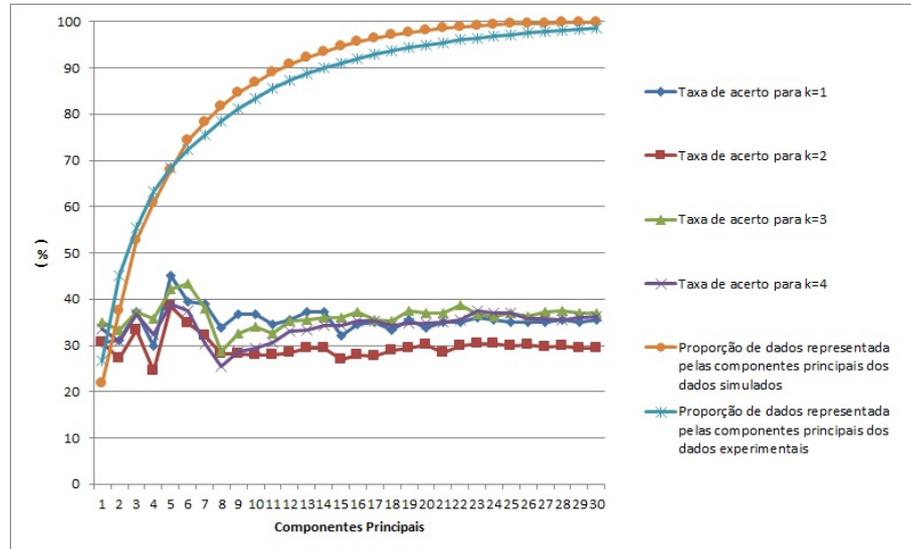
A maioria dos sinais foram agrupados no grupo 1. Nenhum padrão foi observado na classificação desses sinais.

5.3.12 Componentes principais das envoltórias dos sinais ultrassônicos capturados experimentalmente e simulados

A análise de agrupamento foi aplicada as componentes principais das envoltórias dos sinais capturados experimentalmente utilizando as componentes principais das envoltórias dos

sinais simulados na fase de teste. O estudo da variação da taxa média de acerto com o parâmetro k é mostrado na figura 42.

Figura 42 – Variação da taxa média de acerto e da proporção da envoltória dos dados representada de acordo com o número de componentes utilizadas.



Fonte – Figura do próprio autor.

A maior taxa média de acerto foi obtida para as 5 primeiras componentes principais e $k=1$, aproximadamente 67% das informações dos dados de treino e teste são mantidas. Na Tabela 36 podemos observar a matriz confusão obtida pelo emprego das 5 primeiras componentes principais. Aproximadamente 42%, 48 % e 45 % dos sinais do tipo falta de penetração, poro e falta de fusão, respectivamente, foram classificados corretamente. A taxa média de acerto foi de 45%.

Tabela 36 – Matriz de confusão obtida pelo emprego do k -vizinhos mais próximos as 5 primeiras componentes principais da envoltória dos sinais capturados experimentalmente quando utilizados as 5 primeiras componentes principais da envoltória dos sinais simulados na fase de teste para $k=1$.

	Falta de Penetração (FP)	Poros (PO)	Falta de Fusão (FF)
Classificado como FP	41.67 %	6.67 %	18.33 %
Classificado como PO	16.67 %	48.34 %	36.67 %
Classificado como TR	41.66 %	45 %	45 %

As 5 primeiras componentes principais da envoltória dos sinais simulados e capturados experimentalmente também foram processados pela rede neural artificial. Durante a análise desse conjunto de dados uma rede foi configurada com 4 neurônios na camada intermediária

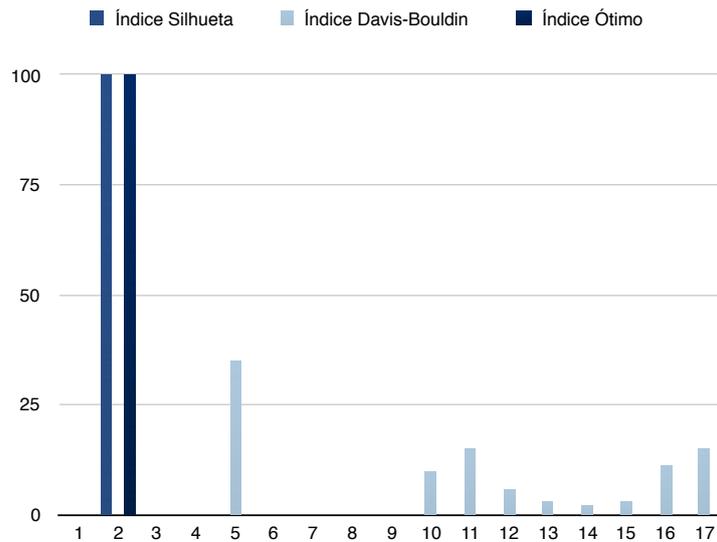
(dado pela média entre o número de classes e o número de atributos de entrada). A melhor classificação foi obtida após 1000 épocas de treinamento. A matriz de confusão é mostrada na tabela 37. Aproximadamente 51 % dos dados associados à falta de penetração foram classificados como falta de penetração. Cerca de 35% dos dados associados a poro e a trinca foram classificados corretamente. A taxa média de acerto foi de 40,58%,

Tabela 37 – Matriz de confusão obtida pelo emprego das redes neurais artificiais as 5 primeiras componentes principais da envoltória dos sinais capturados experimentalmente quando utilizados as 5 primeiras componentes principais da envoltória dos sinais simulados na fase de teste.

	Falta de Penetração (FP)	Poro (PO)	Falta de Fusão (FF)
Classificado como FP	51,35 %	15,63 %	61,85 %
Classificado como PO	20,25 %	34,95 %	2,72 %
Classificado como TR	28,40 %	49,42 %	35,43%

As 5 primeiras componentes principais da envoltória dos sinais ultrassônicos simulados e capturados experimentalmente foram processados pelo k-médias e ele sugeriu que o melhor agrupamento desses sinais é em 2 classes, como mostra a figura 43.

Figura 43 – Histograma do número ótimo de agrupamentos sugerido pelo k-médias para as 5 primeiras componentes principais da envoltória dos sinais ultrassônicos capturados experimentalmente e dos sinais simulados.



Fonte – Figura do próprio autor.

O agrupamento é mostrado na tabela 38. Os sinais foram agrupados majoritariamente

no grupo 1. A maioria dos sinais do grupo 2 são capturados experimentalmente pertencentes a classe falta de penetração. Não foi identificado um padrão na classificação desses sinais.

Tabela 38 – Agrupamento, ou pseudo-classificação, das 5 primeiras componentes principais da envoltória dos sinais ultrassônicos capturados experimentalmente e da envoltória dos sinais simulados sugerido pelo k-médias.

	FP - Sim.	FP - Exp.	PO - Sim.	PO - Exp.	TR - Sim.	FF - Exp.
Grupo 1	20	19	28	58	31	58
Grupo 2	16	41	8	2	5	2

Para uma melhor visualização/analise dos resultados obtidos nesse trabalho, eles são apresentados na tabela 39. Os asteriscos presentes na tabela 39 (*) indicam os conjuntos de sinais que não apresentaram um padrão no agrupamento dos sinais simulados pertencentes à classe Falta de Penetração, de acordo com a profundidade da descontinuidade, sugerido pelo k-médias.

Foi obtido uma alta taxa média de acerto quando os algoritmos K-vizinhos mais próximos e Redes neurais artificiais foram aplicados aos sinais simulados. A taxa média de acerto foi de 92,67% na classificação realizada pelo k-NN das componentes principais dos sinais ultrassônicos simulados. O k-médias agrupou os sinais simulados pertencentes à classe falta de penetração de acordo com a profundidade da descontinuidade.

Trabalhos anteriores utilizaram sinais ultrassônicos simulados no software COMSOL para treinar e testar algoritmos de reconhecimento de padrão. Murta (2015) também observou uma maior facilidade de separar os sinais de tipo falta de penetração do que os do tipo poro e trinca. Neste trabalho, foi alcançado uma taxa média de acerto maior do que a obtida no trabalho de Vieira (2017) utilizando os sinais simulados para treinar e testar o algoritmo k-vizinhos mais próximos (A taxa média de acerto aumentou de 72,1% para 92,67 %).

A classificação dos sinais capturados experimentalmente não foi tão boa quanto a classificação obtida quando utilizados os dados simulados para treino e teste. Entretanto, foi alcançado uma taxa média de acerto de 52,70% no agrupamento das componentes principais dos sinais ultrassônicos capturados experimentalmente normalizados utilizado as componentes principais dos sinais simulados normalizados na fase de treino.

A chance de acertar aleatoriamente o tipo de descontinuidade dentre as três estudadas é de 33.33%. Desta forma, embora a taxa média não seja tão alta, ela é maior do que se a descontinuidade fosse adivinhada aleatoriamente. Então, isto pode ser um indício de que

estamos no rumo certo para a classificação de sinais ultrassônicos através de algoritmos de reconhecimento de padrões. Para que ocorra um aumento na taxa média de acerto, é necessário que a simulação se aproxime ainda mais do ensaio ultrassônico.

Entre as possíveis causas de uma menor acerto na classificação dos experimentais estão: os sinais capturados experimentalmente foram obtidos em uma peça tridimensional, já a simulação ocorreu em um meio bidimensional; e uma das descontinuidades simuladas foi de trinca e o sinal capturado experimentalmente é de falta fusão, embora os A-scan dessas duas descontinuidades sejam parecidos, essa diferença pode ter interferido negativamente na taxa média de acerto.

A utilização das componentes principais nos sinais capturados experimentalmente aumentou a taxa média de acerto na classificação feita pelo algoritmo k-vizinhos mais próximos. Entretanto, houve uma diminuição na taxa média quando as componentes dos sinais foram processados pela rede neural.

Embora a rede neural artificial seja um algoritmo mais complexo e na literatura, normalmente, apresentar uma melhor performance na classificação de dados do que o k-vizinhos mais próximos, os melhores resultados deste trabalho foi obtido utilizando o k-vizinhos mais próximos. A quantidade de dados de treino pode ser uma das possíveis causas desse resultado, quanto maior é o número de dados de treino melhor é o aprendizado da rede e a classificação dos sinais.

Tabela 39 – Sintetização dos resultados.

Conjunto de dados	K-NN	Redes Neurais	K-médias
Sinais ultrassônicos simulados	83,86%	82,33%	11 classes
Sinais ultrassônicos simulados normalizados	82,76%	82,90%	11 classes
Envoltórias dos sinais ultrassônicos simulados	76,48%	70,71%	10 classes
Componentes principais dos sinais ultrassônicos simulados	92,67%	88,72%	11 classes
Componentes principais dos sinais ultrassônicos simulados normalizados	81,05%	78,00%	11 classes
Componentes principais das envoltórias dos sinais ultrassônicos simulados	74,86%	79,62%	5 classes
Sinais ultrassônicos capturados experimentalmente	33,33%	42,99%	17 classes
Sinais ultrassônicos capturados experimentalmente normalizados	37,52%	40,11%	17 classes*
Envoltórias dos sinais ultrassônicos capturados experimentalmente	29,45%	41,00%	5 classes*
Componentes principais dos sinais ultrassônicos capturados experimentalmente	48,33%	30,00%	17 classes
Componentes principais dos sinais ultrassônicos capturados experimentalmente normalizados	52,70%	36,77%	2 classes*
Componentes principais das envoltórias dos sinais ultrassônicos capturados experimentalmente	45,00%	40,58%	2 classes*

6 CONCLUSÕES

A simulação numérica de um meio bidimensional isotropico foi realizada com sucesso, considerando as características inerentes ao ensaio por ultrassom, como a densidade do material, a velocidade de propagação da onda e descontinuidades do tipo: falta de penetração, poro e trinca.

Os algoritmos k-vizinhos mais próximos e redes neurais artificiais apresentam uma boa taxa médias de acerto na classificação dos sinais simulados. Embora a rede neural artificial seja um algoritmo mais complexo e, na literatura, normalmente apresentar uma melhor performance na classificação de dados do que o k-vizinhos mais próximos, os melhores resultados deste trabalho foi obtido utilizando o k-vizinhos mais próximos. A taxa média de acerto foi de 92,67% na classificação realizada pelo k-vizinhos mais próximos das componentes principais dos sinais ultrassônicos simulados.

O k-médias agrupou os sinais simulados pertencentes à classe falta de penetração de acordo com a profundidade da descontinuidade.

A classificação dos sinais capturados experimentalmente não foi tão boa quanto a classificação obtida quando utilizados os dados simulados para treino e teste. Entretanto, foi alcançado uma taxa média de acerto de 52,70% no agrupamento das componentes principais dos sinais ultrassônicos capturados experimentalmente normalizados utilizado as componentes principais dos sinais simulados normalizados na fase de treino. Embora a taxa média não seja tão alta, ela é maior do que se a descontinuidade fosse adivinhada aleatoriamente. Então, isto pode ser um indício de que estamos no rumo certo para a classificação de sinais ultrassônicos através de algoritmos de reconhecimento de padrões.

Para que ocorra um aumento na taxa média de acerto, é necessário que a simulação se aproxime ainda mais do ensaio ultrassônico. A modelagem de um meio tridimensional, ao invés de bidimensional, e de uma peça heterogênea e anisotrópica, ao invés de homogênea e isotrópica, são possíveis mudanças que podem fazer a simulação mais verossímil.

REFERÊNCIAS

- AJANK, A. **K-NN**. 2007. Disponível em: <<https://upload.wikimedia.org/wikipedia/commons/thumb/e/e7/KnnClassification.svg/220px-KnnClassification.svg.png>{29Jan.2018}>.
- ANCELME, R. L. **Aplicação da migração reversa no tempo para análise de aviem meios complexos**. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2011.
- BARRA, S. R.; PEREIRA, A. S. Descontinuidades em soldagem. **Trabalho de Pesquisa para pós-graduação**. Florianópolis: UFSC, 1999.
- BASKARAN, G.; RAO, C. L.; BALASUBRAMANIAM, K. Simulation of the tofd technique using the finite element method. **Insight-Non-Destructive Testing and Condition Monitoring**, The British Institute of Non-Destructive Testing, v. 49, n. 11, p. 641–646, 2007.
- BISHOP, C. M. Pattern recognition. **Machine Learning**, v. 128, p. 1–58, 2006.
- BLITZ, J.; SIMPSON, G. **Ultrasonic methods of non-destructive testing**. [S.l.]: Springer Science & Business Media, 1995. v. 2.
- BOLDRINI, J. L.; COSTA, S. I.; FIGUEREDO, V.; WETZLER, H. G. **Álgebra linear**. [S.l.]: Harper & Row, 1980.
- CAMURÇA, P. J. Simulação do ensaio ultrassônico pela técnica tofd utilizando o método dos volumes finitos. **Dissertação de Mestrado**. Universidade Federal do Ceará (UFC), 2014.
- CAPARRINI, F. S. **Artificial Neural Networks in NetLogo**. 2017. Disponível em: <<http://www.cs.us.es/~fsancho/?e=135>>.
- CARCIONE, J. Boundary conditions for wave propagation problems. **Finite elements in analysis and design**, Elsevier, v. 16, n. 3-4, p. 317–327, 1994.
- CATUNDA, C. E. G. Implementação da modelagem elástica para detecção de defeitos por ultra-som em juntas soldadas dissimilares. **Dissertação de Mestrado**. Universidade Federal do Rio de Janeiro (UFRJ), 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.
- FARRAR, D. **Exploratory Data Analysis**. 2017. Disponível em: <https://www3.epa.gov/caddis/da_exploratory_5.details.html={26mar.2017}>.
- FILHO, J. de M. **O ensaio por ultra-som**. 2005. Disponível em: <https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=6&cad=rja&uact=8&ved=0ahUKEwj3zpqAhoHSAhWDEZAKHW84ABYQFgg6MAU&url=http%3A%2F%2Fwww.feis.unesp.br%2FHome%2Fdepartamentos%2Fengenhariamecanica%2Fintranet%2Fce-celso_ultrasom.doc&usg=AFQjCNFRGsbFThZ-5gvMewRqAKgWvKqjHQ={08fev.2017}>.
- FILHO, J. de M. **NDT RESOURCE CENTER**. 2017. Disponível em: <<http://www.autsolutions.net/images/resources/TOFD-1.jpg>={09fev.2017}>.

- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2007.
- HEBB, D. O. **The organization of behavior: A neuropsychological theory**. [S.l.]: Psychology Press, 2005.
- JAIN, A. K. Data clustering: 50 years beyond k-means. **Pattern recognition letters**, Elsevier, v. 31, n. 8, p. 651–666, 2010.
- KAUFMAN, L.; ROUSSEEUW, P. J. **Finding groups in data: an introduction to cluster analysis**. [S.l.]: John Wiley & Sons, 2009. v. 344.
- KLEINER, D.; BIRD, C. R. Ultrasonic phased array inspection of fsw lap joints. In: . [S.l.]: **BINDT Annual Conference**, 2004. 14-16 Sept.
- LANDAU, L. D.; LIFSHITZ, E. M. **Course of Theoretical Physics Vol 7: Theory and Elasticity**. [S.l.]: Pergamon press, 1959, p 96.
- MALISKA, C. R. **Transferência de calor e mecânica dos fluidos computacional: fundamentos e coordenadas generalizadas**. [S.l.]: Livros Técnicos e Científicos, 1994.
- 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.
- MODENESI, P. J.; MARQUES, P. V.; BRACARENSE, A. Q. **Soldagem-fundamentos e tecnologia**. [S.l.]: Editora UFMG, 2005.
- MOURA, E. de; SILVA, R. da; SIQUEIRA, M.; REBELLO, J. Pattern recognition of welding defects in preprocessed tofd signal using linear classifiers. **Journal of Nondestructive Evaluation**, Springer, v. 43, n. 4, p. 163–172, 2004.
- MOURA, E. de; SIQUEIRA, M.; SILVA, R. da; REBELLO, J.; CALÔBA, L. Welding defect pattern recognition in tofd signals - part 1. linear classifiers. **Insight-Non-Destructive Testing and Condition Monitoring**, The British Institute of Non-Destructive Testing, v. 47, n. 12, p. 777–782, 2005.
- MOURA, E. de; SIQUEIRA, M.; SILVA, R. da; REBELLO, J. Welding defect pattern recognition in tofd signals - part 2. non-linear classifiers. **Insight-Non-Destructive Testing and Condition Monitoring**, The British Institute of Non-Destructive Testing, v. 47, n. 12, p. 783–787, 2005.
- MURTA, R. H. F. Análise de agrupamento de sinais obtidos por simulação do ensaio ultrassônico pela técnica TOFD para reconhecimento de defeitos de soldagem modelados. 2015. **Monografia** (Engenharia Metalúrgica), UFC (Universidade Federal do Ceará), Ceará, Brazil.
- NDT RESOURCE CENTER. **Ultrasound–Weldments(Welded Joint)**. 2011. Disponível em: <<https://www.ndeed.org/EducationResources/CommunityCollege/Ultrasonics/SelectedApps/weldments.htm>{11Mar.201}.>
- NDT RESOURCE CENTER. **Radiograph interpretation – Welds**. 2012. Disponível em: <<https://www.nde-ed.org/EducationResources/CommunityCollege/Radiography/TechCalibrations/RadiographInterp.htm>= {07fev.201}.>

PAO, Y.-H.; VARATHARAJULU, V. Huygens' principle, radiation conditions, and integral formulas for the scattering of elastic waves. **The Journal of the Acoustical Society of America**, ASA, v. 59, n. 6, p. 1361–1371, 1976.

PATANKAR, S. **Numerical heat transfer and fluid flow**. [S.l.]: CRC press, 1980.

PEREIRA, A. H. A. Cerâmicas piezoelétricas: funcionamento e propriedades. **São Carlos: ATCP Engenharia Física**, 2010.

PETROVIC, S. A comparison between the silhouette index and the davies-bouldin index in labelling ids clusters. In: **Proceedings of the 11th Nordic Workshop of Secure IT Systems**. [S.l.: s.n.], 2006. p. 53–64.

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 waves in solid media**. [S.l.]: Cambridge university press, 2004.

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

SILK, M.; LIDINGTON, B. The potential of scattered or diffracted ultrasound in the determination of crack depth. **Non-Destructive Testing**, Elsevier, v. 8, n. 3, p. 146–151, 1975.

TEMPLE, J. Predicted ultrasonic responses for pulse-echo inspections. **British Journal of Non-Destructive Testing**, v. 28, n. 3, p. 145–154, 1986.

THEODORIDIS, S.; KOUTROUMBAS, K. Pattern recognition, academic press. **New York**, 1999.

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

VARELLA, C. A. A. Análise de componentes principais. **Seropédica: Universidade Federal Rural do Rio de Janeiro**, 2008.

VIEIRA, F. d. A. Análise de sinais obtidos por simulação do ensaio ultrassônico pela técnica TOFD para reconhecimento de defeitos de soldagem utilizando o método K-NN. 2017. **Monografia** (Engenharia Mecânica), UFC (Universidade Federal do Ceará), Ceará, Brazil.

WEBB, A. R. **Statistical pattern recognition**. [S.l.]: 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.

ZUBEN, I.-P. F. J. V. Rede mlp: Perceptron de múltiplas camadas. **Nota de aula**. 2017.