



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA METALÚRGICA E DE MATERIAIS
CURSO DE GRADUAÇÃO EM ENGENHARIA METALÚRGICA

JOÃO PEDRO GONÇALVES SANTIAGO LIMA

**IDENTIFICAÇÃO DE DEFEITOS REAIS DE SOLDAGEM A PARTIR DE SINAIS
PRODUZIDOS POR SIMULAÇÃO COMPUTACIONAL DO ENSAIO ULTRASSÔNICO**

FORTALEZA

2026

JOÃO PEDRO GONÇALVES SANTIAGO LIMA

IDENTIFICAÇÃO DE DEFEITOS REAIS DE SOLDAGEM A PARTIR DE SINAIS
PRODUZIDOS POR SIMULAÇÃO COMPUTACIONAL DO ENSAIO ULTRASSÔNICO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Metalúrgica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Metalúrgica.

Orientador: Prof. Dr. Elineudo Pinho de Moura

FORTALEZA

2026

JOÃO PEDRO GONÇALVES SANTIAGO LIMA

IDENTIFICAÇÃO DE DEFEITOS REAIS DE SOLDAGEM A PARTIR DE SINAIS
PRODUZIDOS POR SIMULAÇÃO COMPUTACIONAL DO ENSAIO ULTRASSÔNICO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Metalúrgica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Metalúrgica.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Elineudo Pinho de Moura (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Guilherme de Alencar Barreto
Universidade Federal do Ceará (UFC)

Prof. Dr. Emanuel Seixas Campos
Universidade Federal do Ceará (UFC)

Prof. Dr. Igor Frota de Vasconcelos
Universidade Federal do Ceará (UFC)

A Deus.
À minha família.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, a quem devo cada passo desta trajetória, e a Nossa Senhora, por interceder continuamente por mim ao longo dessa caminhada.

Aos meus pais, José Rochester e Ana Claudia, por todo o amor, apoio incondicional e pela torcida sincera pelo meu sucesso.

À minha avó, Maria Gonçalves, que, quando em vida, fez tudo por mim.

A toda a minha família, em especial à minha madrinha, Lourdes Mascarenhas, e ao meu tio, Zacarias Gonçalves, pelo apoio constante ao longo de toda a minha vida acadêmica e pelo suporte nos momentos difíceis.

Ao meu orientador, Professor Dr. Elineudo Pinho de Moura, pela confiança depositada no desenvolvimento deste trabalho, pelo apoio, paciência e excelente orientação.

Aos integrantes do CENDE, em especial ao Professor Dr. Emanuel Seixas Campos, ao João Victor Barroso Xavier e ao Cauã Cardoso Saraiva, pela companhia, convivência e amizade.

Ao professor Dr. Guilherme de Alencar Barreto, pela excelente disciplina de Reconhecimento de Padrões ministrada, essencial para a base teórica e para o desenvolvimento deste trabalho.

Aos amigos Matheus Segundo, Miguel Dias, Luis Eduardo e Gabriel Pinheiro, pela amizade, companheirismo e apoio ao longo da graduação, tornando essa trajetória mais leve e significativa.

Por fim, a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, minha sincera gratidão.

"Demore o tempo que for para decidir o que você quer da vida, e depois que decidir não recue ante nenhum pretexto, por que o mundo tentará te dissuadir."

(Friedrich Nietzsche)

RESUMO

A detecção, localização e dimensionamento de descontinuidades internas em materiais podem ser realizados de maneira não invasiva pelo ensaio ultrassônico, o qual se baseia na propagação de ondas mecânicas de alta frequência. Dentre as técnicas baseadas nesse princípio, o tempo de percurso da onda difratada (TOFD, do inglês *Time Of Flight Diffraction*) destaca-se por sua elevada sensibilidade e capacidade de detectar defeitos a partir das ondas difratadas nas extremidades das descontinuidades. Contudo, a classificação dos defeitos obtidos pela técnica a partir dos sinais ultrassônicos ainda depende fortemente da interpretação e experiência do operador, e são sujeitas a imprecisões. Nesse contexto algoritmos de classificação têm se mostrado ferramentas promissoras para auxiliar na interpretação automática desses sinais, permitindo identificar padrões característicos associados a diferentes tipos de defeitos. Neste trabalho foi desenvolvido um ambiente de simulação por elementos finitos para geração de sinais ultrassônicos pela técnica TOFD. Foram modelados, no software COMSOL, peças com três tipos de defeitos presentes em juntas soldadas: falta de penetração, poro e falta de fusão. Os sinais resultantes foram pré-processados e empregados em algoritmos de reconhecimento de padrões, incluindo *K-Nearest Neighbors* (KNN), classificador quadrático e redes neurais artificiais. Considerando inicialmente o cenário em que os algoritmos são treinados e testados apenas com sinais simulados, o melhor desempenho foi obtido pelo classificador KNN, que alcançou 87,47% de acurácia média e acerto máximo de 100% ao utilizar a envoltória dos sinais como entrada. Já na etapa em que os modelos foram treinados com dados simulados e avaliados a partir dos dados experimentais, o destaque foi a rede neural artificial MLP com duas camadas ocultas, que atingiu 63,13% de taxa média de acerto e máximo de 80,57% na classificação do conjunto completo dos defeitos de soldagem.

Palavras-chave: Ensaio ultrassônico; Defeitos de soldagem; KNN; Classificador quadrático; Redes neurais artificiais

ABSTRACT

The detection, location, and sizing of internal discontinuities in materials can be performed non-invasively using ultrasonic testing, which is based on the propagation of high-frequency mechanical waves. Among the techniques based on this principle, time-of-flight diffraction (TOFD) stands out for its high sensitivity and ability to detect defects from the diffracted waves at the ends of discontinuities. However, the classification of defects obtained by the technique from ultrasonic signals still strongly depends on the operator's interpretation and experience, and is subject to inaccuracies. In this context, classification algorithms have proven to be promising tools for the automatic interpretation of these signals, enabling the identification of characteristic patterns associated with different defect types. In this work, a finite element simulation environment was developed for generating ultrasonic signals using the TOFD technique. Parts with three defect types present in welded joints were modeled in the COMSOL software: lack of penetration, porosity, and lack of fusion. The resulting signals were pre-processed and used in pattern recognition algorithms, including K-Nearest Neighbors (KNN), quadratic classifier, and artificial neural networks. Initially considering the scenario where the algorithms are trained and tested only with simulated signals, the best performance was obtained by the KNN classifier, which achieved an average accuracy of 87.47% and a maximum accuracy of 100% when using the signal envelope as input. In the stage where the models were trained with simulated data and evaluated using experimental data, the standout was the MLP artificial neural network with two hidden layers, which achieved an average accuracy rate of 63.13% and a maximum of 80.57% in classifying the complete set of welding defects.

Keywords: Ultrasonic testing; Welding defects; KNN; Quadratic classifier; Artificial neural networks

LISTA DE FIGURAS

Figura 1 – Esquema básico da aplicação da técnica TOFD.	20
Figura 2 – Ilustração do A-scan de uma descontinuidade.	21
Figura 3 – Lugares geométricos de distância unitária para diferentes valores de m na métrica de Minkowski.	25
Figura 4 – Gráfico da FDP Gaussiana univariada para: (a) $\mu_1 = 0$, $\sigma_1^2 = 1$, (b) $\mu_2 = 2$ e $\sigma_2^2 = 0,5$	27
Figura 5 – Função Densidade de Probabilidade (FDP) Gaussiana bivariada com $\sigma_1^2 = \sigma_2^2$, $\mu = \mathbf{0}$ e $\rho_{12} = 0$	28
Figura 6 – Representação da rede Perceptron simples.	34
Figura 7 – Representação da rede Perceptron de múltiplas camadas.	35
Figura 8 – Esquemático do posicionamento dos defeitos modelados ao longo da peça.	43
Figura 9 – Fluxograma metodológico para geração dos sinais simulados para diferentes defeitos adicionados a modelagem da peça.	44
Figura 10 – Campos de deslocamento simulados para os diferentes defeitos (FP, PO e FF) e seus respectivos A-scans.	45
Figura 11 – Fluxograma do planejamento do trabalho (Simulados X Simulados).	50
Figura 12 – Fluxograma da metodologia proposta para avaliação dos modelos empregados para Simulados X Simulados e Simulados X Reais.	51
Figura 13 – Comparação dos sinais normalizados e suas envoltórias para o defeito poro (PO), obtidos de maneira simulada e real.	52
Figura 14 – Variância explicada acumulada (%) vs Número de Componentes Principais para os Sinais Simulados e suas Envoltórias, com 512 pontos.	54
Figura 15 – Diagrama de blocos da transformação linear do conjunto de treino (X_{treino}) e teste (X_{teste}) nas componentes principais de dimensão q (Z_{treino} e Z_{teste}), a partir da matriz de transformação (Q_{treino}).	55
Figura 16 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" e testado com Sinais Simulados (512, 256 e 128 Pontos).	58
Figura 17 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" e testado com a envoltória dos Sinais Simulados (512, 256 e 128 Pontos).	60

Figura 18 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado e testado com as componentes principais que retém 95% da informação dos sinais simulados (512, 256 e 128 pontos).	62
Figura 19 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado e testado com as componentes principais que retém 95% (512 e 256 pontos) e 90% (128 pontos) da informação das envoltória dos Sinais Simulados.	64
Figura 20 – Matrizes de confusão da melhor acurácia média e sua máxima do <i>Perceptron</i> de camada única treinado e testado com as componentes principais que retém 100% da informação dos sinais simulados (512, 256 e 128 Pontos).	66
Figura 21 – Matrizes de confusão da melhor acurácia média e sua máxima do <i>Perceptron</i> de camada única treinado e testado com a envoltória dos sinais simulados (128 pontos) e as suas componentes principais que retém 100% da sua informação (512 e 256 pontos).	68
Figura 22 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (uma camada oculta) treinado e testado com os sinais simulados (512 e 128 pontos) e as suas componentes principais que retém 100% da sua informação (256 pontos).	70
Figura 23 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (uma Camada Oculta) treinado e testado com a envoltória dos sinais simulados (128 pontos) e as suas componentes principais que retém 100% da informação (512 e 256 pontos).	72
Figura 24 – Gráfico das melhores acurácias médias dos classificadores para Simulados × Simulados considerando a redução do número de pontos.	73
Figura 25 – Melhores acurácias médias dos classificadores em função da redução da dimensionalidade (PCA) da envoltória dos sinais simulados com 128 pontos (Simulados X Simulados).	74
Figura 26 – Acurácias por classe dos melhores desempenhos médios e seus máximos para todos os classificadores alimentados com os dados obtidos pela envoltória dos sinais simulados com 128 pontos.	75
Figura 27 – Fluxograma para a etapa Simulados X Reais com a melhor configuração de pré-processamento escolhida em Simulados X Simulados.	76

Figura 28 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" com as componentes principais das envoltória dos sinais simulados e testado as componentes principais das envoltória de sinais reais com classificações ternárias e hierárquicas.	83
Figura 29 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" com as componentes principais das envoltória dos sinais simulados e testado as componentes principais das envoltória de sinais reais com classificações binárias.	84
Figura 30 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais com classificações ternárias e hierárquicas.	86
Figura 31 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais com classificações binárias.	87
Figura 32 – Matrizes de confusão da melhor acurácia média e sua máxima do <i>perceptron</i> de camada única treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.	89
Figura 33 – Matrizes de confusão da melhor acurácia média e sua máxima do <i>perceptron</i> de camada única treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.	90
Figura 34 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (Uma camada oculta) treinada com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltória dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.	92
Figura 35 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (1 camada oculta) treinada com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.	93

Figura 36 – Matrizes de confusão da melhor acurácia média e sua máxima do MLP (Duas camadas ocultas) treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.	95
Figura 37 – Matrizes de confusão da melhor acurácia média e sua máxima do MLP (2 camadas ocultas) treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.	96
Figura 38 – Gráfico das melhores acurácias médias e suas máximas dos classificadores para Simulados X Reais com classificações ternárias.	97
Figura 39 – Acurácias por classe dos melhores desempenhos médios e seus máximos em Simulados X Reais, para as classificações ternárias.	99

LISTA DE TABELAS

Tabela 1 – Distâncias derivadas da distância de Minkowski.	25
Tabela 2 – Parâmetros utilizados para modelagem da peça e dos transdutores.	41
Tabela 3 – Variantes de Regularização da Matriz de Covariância do classificador quadrático.	48
Tabela 4 – Melhor desempenho médio no conjunto de teste do KNN "treinado" e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	57
Tabela 5 – Melhor desempenho médio no conjunto de Teste do KNN "treinado" e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	59
Tabela 6 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	61
Tabela 7 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	63
Tabela 8 – Melhor desempenho médio no conjunto de teste do <i>Perceptron</i> de camada única treinado e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	65
Tabela 9 – Melhor desempenho médio no conjunto de teste do <i>Perceptron</i> de camada única treinado e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	67
Tabela 10 – Melhor desempenho médio no conjunto de teste da MLP (uma camada oculta) treinada e testada com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	69
Tabela 11 – Melhor desempenho médio no conjunto de teste da MLP (uma camada oculta) treinada e testada com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.	71
Tabela 12 – Melhor desempenho médio no conjunto de teste do KNN "treinado" com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.	82

Tabela 13 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.	85
Tabela 14 – Melhor desempenho médio no conjunto de teste do <i>perceptron</i> de camada única treinado com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.	88
Tabela 15 – Melhores desempenho no conjunto de teste do MLP (Uma camada oculta) treinada com a envoltória dos sinais simulados e testada com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.	91
Tabela 16 – Melhores desempenhos no conjunto de teste do MLP (Duas camadas ocultas) treinada com a envoltória dos sinais simulados e testada com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para as classificações binárias, ternárias e hierárquicas.	94

LISTA DE ABREVIATURAS E SIGLAS

END	Ensaio Não Destrutivo
TOFD	<i>Time of Flight Diffraction</i>
KNN	<i>K-Nearest Neighbors</i>
C.Q	Classificador quadrático
SLP	<i>Single-Layer Perceptron</i>
MLP	<i>MultiLayer Perceptron</i>
PDS	Processamento Digital de Sinais
FDP	Função Densidade de Probabilidade
MAP	<i>Maximum A Posteriori</i>
PCA	<i>Principal Component Analysis</i>
FP	Falta de Penetração
PO	Porosidade
FF	Falta de Fusão

SUMÁRIO

1	INTRODUÇÃO	18
2	REFERÊNCIAS TEÓRICAS	20
2.1	Sinais de ultrassom	20
2.1.1	<i>Time of Flight Diffraction (TOFD)</i>	20
2.1.2	<i>Phased array</i>	21
2.2	Simulação computacional por elementos finitos	21
2.3	Transformada de Hilbert	22
2.4	Algoritmos de reconhecimento de padrões	23
2.4.1	<i>K-Nearest Neighbors (KNN)</i>	23
2.4.1.1	O algoritmo KNN	23
2.4.1.2	Medidas de Similaridade e Dissimilaridade	24
2.4.1.3	Distância de Minkowski	24
2.4.1.4	Lugares Geométricos	25
2.4.2	Classificador Quadrático	26
2.4.2.1	Matriz de covariância	26
2.4.2.2	Função Densidade de Probabilidade (FDP)	27
2.4.2.3	Teorema de Bayes e critério de decisão <i>maximum a posteriori</i> (MAP)	28
2.4.2.4	O algoritmo do classificador quadrático	30
2.4.3	Análise de Componentes Principais (PCA)	32
2.4.4	Redes neurais artificiais	34
2.4.4.1	<i>Perceptron</i> simples	34
2.4.4.2	<i>Perceptron</i> de Múltiplas Camadas	35
2.4.4.3	Funções de ativação	37
3	METODOLOGIA	39
3.1	Sinais simulados	39
3.1.1	Material da simulação e a peça	39
3.1.2	Transdutores e seus parâmetros	40
3.1.3	Defeitos, malha e condições de contorno da simulação	41
3.2	Sinais reais	45
3.3	Classificação	46

3.3.1	<i>K-Nearest Neighbors</i> (KNN)	46
3.3.2	Classificador quadrático	47
3.3.3	Redes neurais artificiais	48
3.3.4	<i>Perceptron</i> de camada única (SLP)	48
3.3.5	<i>Perceptron</i> de múltiplas camadas (MLP)	48
3.3.6	Pré-processamento e subdivisão dos conjuntos de treino e teste	49
4	RESULTADOS	52
4.1	Dados simulados e reais	52
4.2	Simulados X Simulados	55
4.3	Avaliação e desempenho dos modelos de classificação: Simulados X Simulados	73
4.4	Simulados X Real	77
4.5	Resumo dos resultados na etapa Simulados X Reais para as classificações ternárias	97
5	CONCLUSÕES	100
	REFERÊNCIAS	102

1 INTRODUÇÃO

Os Ensaio Não Destrutivos (END) desempenham um papel fundamental na garantia do controle de qualidade e segurança de estruturas de equipamentos industriais. Os ENDs podem ser definidos como técnicas utilizadas na inspeção de materiais e peças semi-acabadas ou acabadas para verificar a existência ou não de descontinuidades, sem que isso prejudique sua utilização futura (WORKMAN *et al.*, 2007). A principal finalidade destas técnicas é a detecção, localização e dimensionamento de defeitos como falta de fusão, porosidades ou inclusões que possam comprometer a integridade mecânica do material.

Existem diversos métodos não invasivos aplicáveis dependendo da natureza do material e do tipo de descontinuidade esperada, tais como líquidos penetrantes, partículas magnéticas, correntes parasitas e radiografia. Dentre as técnicas disponíveis, este trabalho abordará especificamente o ensaio não destrutivo por ultrassom, explorando suas capacidades de detecção de defeitos internos através da propagação de ondas mecânicas de alta frequência.

O ensaio ultrassônico tem o objetivo de detectar descontinuidades presentes no interior de materiais. A emissão dessas ondas é possibilitada por um cristal piezoelétrico presente no transdutor, convertendo impulsos elétricos em impulsos mecânicos (pressão sonora) para gerar a onda ultrassônica e, posteriormente, converte as ondas mecânicas refletidas de volta em impulsos elétricos para análise. Ao encontrar uma descontinuidade, as ondas são refletidas ou difratadas de volta ao transdutor. A partir da análise da variação da amplitude da onda e do tempo de retorno do sinal, é possível não apenas detectar a presença da falha, mas também determinar a espessura do material e dimensionar as descontinuidades. Em suma, a presença de defeitos internos ou descontinuidades alteram o padrão de propagação das ondas, seja por reflexão, atenuação ou difração (KRAUTKRAMER; KRAUTKRAMER, 1990).

Existe uma gama de técnicas que podem ser utilizadas baseado no princípio físico da propagação das ondas ultrassônicas, porém o presente trabalho irá empregar apenas a técnica do tempo de percurso da onda difratada (TOFD, do inglês *Time Of Flight Diffraction*). A técnica TOFD baseia-se no princípio da difração das ondas ultrassônicas, medindo o tempo de percurso dos sinais difratados nas extremidades da descontinuidade presente no interior do material (SILK; LIDDINGTON, 1975). Essa abordagem garante uma robusta chance de detecção de falhas, com elevada aplicabilidade do ponto de vista de engenharia.

Apesar da eficácia do TOFD na detecção de descontinuidades, surge uma grande dificuldade na classificação e caracterização precisa desses defeitos a partir dos sinais gerados,

sendo o A-scan uma forma de representá-los. O A-scan pode ser confuso ou ambíguo, especialmente quando se trata de descontinuidades complexas ou com características similares. Além disso, a inspeção gera uma grande quantidade de sinais que, mesmo para um inspetor altamente qualificado, inviabilizam a atuação humana em tempo hábil para a caracterização detalhada e precisa de cada defeito.

Muitos trabalhos já propuseram a utilização de algoritmos de reconhecimento de padrões (tanto supervisionados quanto não-supervisionados) para classificar ou agrupar sinais obtidos no dia a dia por meio da inspeção utilizando TOFD. Uma das limitações disso é que esses algoritmos treinados possuem finalidades limitadas pelas geometrias das peças a serem inspecionadas ou pelas configurações dos transdutores utilizados. Além disso, o custo pela rotulação desses dados é elevado, pois se faz necessária a atuação de um soldador extremamente experiente para induzir esses defeitos de maneira proposital, bem como a realização de ensaios complementares para o reconhecimento desses defeitos, como ensaios ultrassônicos convencionais e radiográficos.

Este trabalho propõe a simulação por elementos finitos do ensaio ultrassônico realizado pela técnica TOFD em juntas soldadas contendo descontinuidades modeladas computacionalmente, com o objetivo de produzir sinais a serem utilizados no treinamento de algoritmos de classificação, tais como *K-Nearest Neighbors* (KNN), classificador quadrático e redes neurais artificiais. Posteriormente, esses classificadores foram empregados para classificar defeitos reais, a partir de sinais obtidos durante inspeções reais.

2 REFERÊNCIAS TEÓRICAS

2.1 Sinais de ultrassom

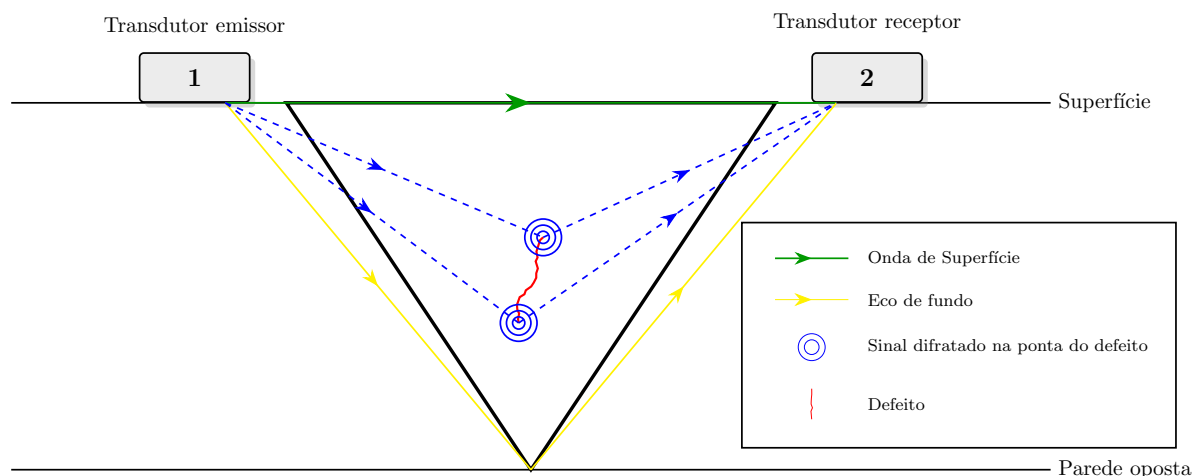
O ensaio ultrassônico fundamenta-se na propagação de ondas mecânicas de alta frequência através de materiais, onde defeitos internos ou discontinuidades alteram o padrão de propagação das ondas, seja por reflexão, atenuação ou difração (KRAUTKRAMER; KRAUTKRAMER, 1990). Dentre as técnicas ultrassônicas avançadas, destacam-se: *Time of Flight Diffraction* (TOFD) e o *phased array*.

2.1.1 *Time of Flight Diffraction* (TOFD)

A técnica *Time of Flight Diffraction* (TOFD), conforme estabelecido na norma britânica BS 7706 (British Standards Institution, 1993) utiliza um par de transdutores posicionados na mesma superfície da peça, mas em lados opostos da região a ser inspecionada onde um é denominado transdutor emissor e o outro de transdutor receptor, como apresentado na figura 1.

O princípio baseia-se na difração de ondas ultrassônicas nas extremidades das discontinuidades, o que gera sinais característicos que permitem sua detecção e dimensionamento. Esse sinal resultante é representado em um A-scan, que registra a amplitude da pressão acústica medida no transdutor receptor em função do tempo. Na figura 2 são identificadas quatro ondas principais: a onda de superfície (a); os sinais difratados na extremidade superior (b) e inferior da discontinuidade (c); e o eco de fundo, resultante da reflexão na superfície oposta (d).


Figura 1 – Esquema básico da aplicação da técnica TOFD.



Fonte: Elaborado pelo autor (2026).

A configuração básica do TOFD garante que quaisquer sinais originados de descontinuidades cheguem entre a onda de superfície e o eco de fundo, sendo o tempo de percurso desses sinais uma medida direta da altura do defeito (British Standards Institution, 1993). A técnica é particularmente eficaz para dimensionamento de descontinuidades internas, embora exija cuidados com zonas mortas próximas às superfícies (SILK; LIDDINGTON, 1975).

Figura 2 – Ilustração do A-scan de uma descontinuidade.



Fonte: Elaborado pelo autor (2026).

2.1.2 *Phased array*

A técnica de *phased array* representa um avanço significativo na inspeção ultrassônica, permitindo o controle eletrônico do feixe ultrassônico através de arranjos com múltiplos cristais piezoelétricos em um único transdutor. Esta técnica possibilita varreduras rápidas e flexíveis sem a necessidade de movimento mecânico do transdutor (WOOH; SHI, 1999).

A formação do feixe no *phased array* baseia-se no princípio da interferência construtiva e destrutiva das ondas ultrassônicas provenientes dos vários cristais piezoelétricos. O controle preciso dos atrasos temporais aplicados a cada cristal permite focalizar e direcionar o feixe em diferentes profundidades e ângulos.

2.2 Simulação computacional por elementos finitos

O método dos elementos finitos é uma ferramenta computacional muito utilizada para a simulação numérica de problemas de engenharia, sendo feita em análises estruturais, térmicas e de fluidos. Diferente dos métodos de diferenças e volumes finitos, o método dos elementos

finitos baseia-se na discretização do domínio em subdomínios menores de geometria simples, denominados elementos finitos, interconectados por nós. Essa técnica permite a modelagem de geometrias complexas e a solução de problemas multifísicos acoplados, aproximando a solução de equações diferenciais governantes por meio de funções de interpolação definidas dentro de cada elemento (REDDY, 2019).

No contexto da mecânica dos sólidos, a formulação do problema frequentemente emprega uma função de deslocamento como variável nodal primária. A seleção dessa função de interpolação é uma etapa importante, pois ela define como o deslocamento varia dentro de um elemento a partir dos valores nodais. Aplicando as relações deformação-deslocamento e tensão-deformação, deriva-se para cada elemento uma matriz de rigidez que relaciona forças e deslocamentos nodais. O processo de montagem consiste na combinação sistemática das matrizes de rigidez de todos os elementos, resultando em uma equação global de equilíbrio que representa o comportamento completo da estrutura, na qual são então impostas as condições de contorno (REDDY, 2019).

2.3 Transformada de Hilbert

O processamento digital de sinais (PDS) é uma área fundamental para diversas aplicações na engenharia e ciência, que permite a análise, modificação e síntese de sinais. Uma das ferramentas essenciais no PDS é a transformada de Hilbert, onde nela é realizada uma operação linear que desloca todas as componentes de frequência de um sinal em -90° (ou $-\pi/2$ radianos). Para um sinal de tempo contínuo $x(t)$, sua transformada de Hilbert $\mathcal{H}\{x(t)\}$ é definida pela equação 2.1:

$$\mathcal{H}\{x(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2.1)$$

Essa é uma integral de convolução, onde τ é a variável de integração. Em termos de domínio da frequência, a transformada de Hilbert pode ser entendida como a multiplicação do espectro de Fourier de $x(t)$ por $-j \cdot \text{sgn}(\omega)$, onde $\text{sgn}(\omega)$ é a função sinal. O sinal analítico é formado, $z(t) = x(t) + j\hat{x}(t)$, que possui o espectro de frequência unilateral (apenas componentes positivas). (OPPENHEIM; SCHAFER, 2010).

Um dos usos mais significativos da transformada de Hilbert é a capacidade de gerar a envoltória (ou envelope) de um sinal. Ela é uma curva que descreve as variações da amplitude

de um sinal modulado ao longo do tempo, sem capturar as oscilações de alta frequência do sinal portador. No contexto do sinal analítico $z(t) = x(t) + j\hat{x}(t)$, a envoltória do sinal original $x(t)$ pode ser obtida calculando o módulo (magnitude) de $z(t)$:

$$E(t) = |z(t)| = |x(t) + j\hat{x}(t)| = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (2.2)$$

2.4 Algoritmos de reconhecimento de padrões

2.4.1 *K-Nearest Neighbors (KNN)*

2.4.1.1 *O algoritmo KNN*

O algoritmo *K-Nearest Neighbors* (KNN) é uma abordagem para tarefas de classificação supervisionada. Ele pertence à classe de métodos baseados em instâncias, ou seja, não constrói explicitamente um modelo durante a fase de treinamento, tendo uma denominação para o tipo de aprendizado *lazy learning* (AHA *et al.*, 1991). Em vez disso, armazena todos os exemplos de treinamento e, no momento da classificação de uma nova instância, busca os K vizinhos mais próximos. (BISHOP, 2006; THEODORIDIS; KOUTROUMBAS, 2009).

O funcionamento do KNN segue três passos principais, onde primeiramente todos os dados de treinamento são armazenados em memória. Em seguida, para uma nova instância \mathbf{x}_{new} , calcula-se a distância entre ela e todos os exemplos do conjunto de treinamento, utilizando uma métrica pré-definida, como a distância euclidiana ou quarteirão. O vizinho mais próximo é determinado pelo índice:

$$i^* = \arg \min_{i=1, \dots, N} \text{dist}(\mathbf{x}_{new}, \mathbf{x}_i) \quad (2.3)$$

onde a nova instância é classificada com o mesmo rótulo de \mathbf{x}_{i^*} . Em sua versão generalizada, o algoritmo pode considerar os K vizinhos mais próximos e realizar uma votação entre os rótulos desses vizinhos para determinar a classe final (BISHOP, 2006; THEODORIDIS; KOUTROUMBAS, 2009).

2.4.1.2 Medidas de Similaridade e Dissimilaridade

O desempenho do KNN depende fortemente da escolha da medida de distância, pois é essa métrica que define a noção de "proximidade" entre os vetores de atributos. Tais medidas são classificadas em duas grandes categorias: medidas de dissimilaridade e similaridade. Medidas de dissimilaridade atribuem menores valores a pares de objetos mais similares. Por outro lado, medidas de similaridade atribuem maiores valores à medida que os objetos se tornam mais semelhantes (THEODORIDIS; KOUTROUMBAS, 2009).

Uma medida de dissimilaridade entre dois objetos 1 e 2 (d_{12}) deve obedecer, em geral, às seguintes propriedades: não negatividade ($d_{12} \geq 0$), identidade ($d_{11} = 0$) e simetria ($d_{12} = d_{21}$). Entretanto, a simetria pode ser violada por algumas medidas, como a divergência de Kullback-Leibler (BISHOP, 2006). Nesse contexto, valores de dissimilaridade pertencem ao intervalo $[0, \infty)$, enquanto medidas de similaridade são normalmente normalizadas para o intervalo $[0, 1]$, onde 1 representa máxima similaridade e 0, mínima (THEODORIDIS; KOUTROUMBAS, 2009). O KNN, em particular, utiliza medidas de dissimilaridade para determinar a "proximidade" entre os vetores de atributos. Quanto menor o valor da dissimilaridade, mais semelhantes são os objetos.

2.4.1.3 Distância de Minkowski

A distância de Minkowski constitui uma generalização de várias métricas/distâncias comumente utilizadas em algoritmos de distância mínima. Ela é dada pela equação 2.4:

$$d_M^{(m)}(\mathbf{x}, \mathbf{y}) = \left(\sum_{j=1}^p |x_j - y_j|^m \right)^{\frac{1}{m}} = \|\mathbf{x} - \mathbf{y}\|_m \quad (2.4)$$

Cada parâmetro m ajusta para um tipo de distância. No caso de $m \geq 1$, a função atende à desigualdade triangular e, portanto, define uma métrica válida. Quando $m < 1$, essa propriedade é violada, e a função não é mais uma distância no sentido formal (WEBB, 2002). Alguns casos particulares da distância de Minkowski são apresentados na tabela 1.

Tabela 1 – Distâncias derivadas da distância de Minkowski.


Parâmetro m	Nome da Distância	Fórmula
$m = 1/2$	Distância de Minkowski ($m = 1/2$)	$d(\mathbf{x}, \mathbf{y}) = \left(\sum_{j=1}^p x_j - y_j ^{1/2} \right)^2$
$m = 1$	Distância Quarteirão	$d_{quar}(\mathbf{x}, \mathbf{y}) = \sum_{j=1}^p x_j - y_j $
$m = 2$	Distância Euclidiana	$d_e(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{j=1}^p x_j - y_j ^2}$
$m \rightarrow \infty$	Distância de Chebyshev	$d_{ch}(\mathbf{x}, \mathbf{y}) = \max_j x_j - y_j $

Fonte: Elaborado pelo autor (2026).

2.4.1.4 Lugares Geométricos

O conceito de lugar geométrico é fundamental para visualizar como diferentes métricas definem regiões no espaço de atributos. No caso da distância de Minkowski, o lugar geométrico de distância unitária corresponde ao conjunto de pontos equidistantes da origem, cuja forma varia de acordo com o parâmetro m . A figura 3 ilustra essa variação para m igual a $1/2$, 1 e 2 , respectivamente, a partir de uma simulação com 10000 pontos bidimensionais com distribuição uniforme e aleatória em $[-1, 1]$. Nota-se que diferentes valores de m resultam em formas distintas, em que ocorre uma curvatura côncava para $m = 1/2$, losango para $m = 1$ (distância quarteirão) e círculo para $m = 2$ (distância Euclidiana).

Figura 3 – Lugares geométricos de distância unitária para diferentes valores de m na métrica de Minkowski.



Fonte: Elaborado pelo autor (2026).

Além do aspecto geométrico, a escolha de m impacta diretamente o desempenho do classificador k -Nearest Neighbors (KNN). Para valores menores de m , como $m = 1$, existe a tendência de aceleração para o processo de classificação e apresentam maior robustez a *outliers*, por suavizarem o efeito de atributos com valores discrepantes (AGGARWAL *et al.*, 2001).

Em contrapartida, valores maiores, como $m = 2$, enfatizam diferenças absolutas e tornam o classificador mais sensível a variações locais, o que pode comprometer a generalização em conjuntos de dados ruidosos (JAIN *et al.*, 2000). Dessa forma, a escolha do parâmetro m deve considerar tanto a geometria do espaço quanto a eficiência e a estabilidade do desempenho classificatório.

2.4.2 Classificador Quadrático

2.4.2.1 Matriz de covariância

Considere uma matriz de dados $\mathbf{X} \in \mathbb{R}^{n \times p}$, contendo p atributos observados em n amostras independentes. Cada elemento x_{ij} representa a realização da j -ésima variável aleatória X_j na i -ésima observação. A estrutura de dependência linear entre essas variáveis pode ser completamente caracterizada pela matriz de covariância $\mathbf{C} \in \mathbb{R}^{p \times p}$ (THEODORIDIS; KOUTROUMBAS, 2009), cujos elementos são definidos por:

$$\sigma_{ij} = \text{Cov}(x_i, x_j) = \mathbb{E}[(x_i - \mu_i)(x_j - \mu_j)] \quad (2.5)$$

onde $\mu_i = \mathbb{E}[x_i]$ denota o valor esperado da i -ésima variável (THEODORIDIS, 2020). Essa matriz simétrica possui a seguinte estrutura fundamental:

$$\mathbf{C} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_p^2 \end{bmatrix} \quad (2.6)$$

A diagonal principal contém as variâncias $\sigma_i^2 = \text{Var}(X_i)$, enquanto os elementos fora da diagonal representam as covariâncias entre pares de variáveis (BISHOP, 2006). A matriz de covariância pode ser expressa, retomando a equação 2.5 através do operador valor esperado:

$$\mathbf{C} = \mathbb{E}[(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T] \quad (2.7)$$

onde $\boldsymbol{\mu} = \mathbb{E}[\mathbf{x}]$ é o vetor de médias dos atributos (THEODORIDIS, 2020).

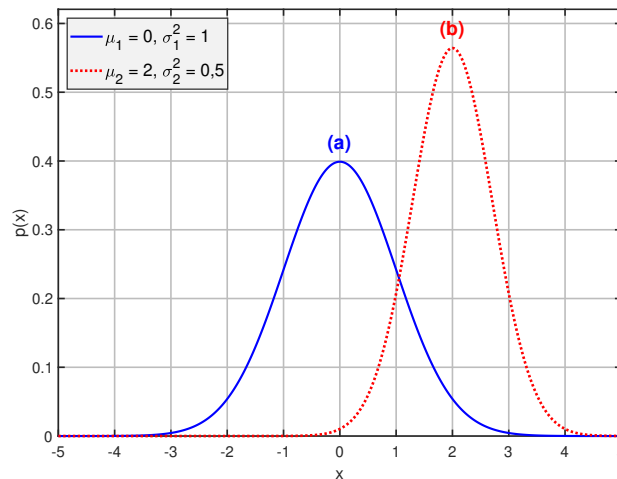
2.4.2.2 Função Densidade de Probabilidade (FDP)

Para uma variável aleatória $x \in \mathbb{R}$, a FDP Gaussiana é dada por:

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (2.8)$$

em que μ é a média (valor esperado) e σ^2 a variância. A figura 4 mostra exemplos para diferentes parâmetros.

Figura 4 – Gráfico da FDP Gaussiana univariada para: (a) $\mu_1 = 0, \sigma_1^2 = 1$, (b) $\mu_2 = 2$ e $\sigma_2^2 = 0,5$.



Fonte: Elaborado pelo autor (2026).

Para um conjunto de variáveis aleatórias $x \in \mathbb{R}^p$, a FDP Gaussiana multivariada é dada por:

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{p/2} |\mathbf{C}|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \mathbf{C}^{-1}(\mathbf{x}-\boldsymbol{\mu})\right) \quad (2.9)$$

Para a equação 2.9, $\boldsymbol{\mu} \in \mathbb{R}^p$ é o vetor de médias (com $\mu_i = \mathbb{E}[x_i]$ para cada dimensão), $\mathbf{C} \in \mathbb{R}^{p \times p}$ é a matriz de covariância, \mathbf{C}^{-1} denota sua inversa matricial, e $|\mathbf{C}|$ representa o determinante de \mathbf{C} . Considerando um caso bi-dimensional onde as variáveis x_1 e x_2 estão descorrelacionadas ($\sigma_{ij} = 0$ para $i \neq j$) a matriz de covariância torna-se diagonal:


$$\mathbf{C} = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix} \quad (2.10)$$

Neste caso especial o determinante simplifica-se para $|\mathbf{C}| = \sigma_1^2 \sigma_2^2$ e a sua inversa é:

$$\mathbf{C}^{-1} = \begin{bmatrix} \frac{1}{\sigma_1^2} & 0 \\ 0 & \frac{1}{\sigma_2^2} \end{bmatrix} \quad (2.11)$$

A figura 5 apresenta uma Função Densidade de Probabilidade (FDP) Gaussiana bivariada, com variâncias σ_1^2 e σ_2^2 descorrelacionadas, iguais e centradas na origem. Nesse caso, onde $\sigma_1^2 = \sigma_2^2$, a distribuição é isotrópica, espalhando-se uniformemente em todas as direções a partir do centro. Visualmente, isso se apresenta como uma FDP com curvas de nível circulares concêntricas. Se a dispersão dos dados ao longo do eixo é muito maior que do outro eixo ($\sigma_1^2 \gg \sigma_2^2$ ou $\sigma_1^2 \ll \sigma_2^2$), a FDP alinha-se na direção do atributo com maior variância.

Figura 5 – Função Densidade de Probabilidade (FDP) Gaussiana bivariada com $\sigma_1^2 = \sigma_2^2$, $\mu = \mathbf{0}$ e $\rho_{12} = 0$.



Fonte: Elaborado pelo autor (2026).

2.4.2.3 Teorema de Bayes e critério de decisão maximum a posteriori (MAP)

O Teorema de Bayes é um conceito fundamental na teoria da probabilidade, amplamente utilizado em classificação de padrões para inferir a probabilidade de uma classe dada uma observação. Ele permite combinar o conhecimento prévio sobre a ocorrência de cada classe com a informação trazida pelos dados (THEODORIDIS; KOUTROUMBAS, 2009). Formalmente, para um conjunto de classes ω_i e um vetor de atributos \mathbf{x} , o teorema de Bayes é expresso como:

$$p(\omega_i|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_i)p(\omega_i)}{p(\mathbf{x})} \quad (2.12)$$

Nesta equação, $p(\omega_i|\mathbf{x})$ é a probabilidade a posteriori da classe ω_i dado o vetor de

atributos \mathbf{x} , $p(\mathbf{x}|\omega_i)$ é a função de verossimilhança, que descreve a probabilidade de observar \mathbf{x} dada a classe ω_i , $p(\omega_i)$ é a probabilidade a priori da classe ω_i , representando nosso conhecimento inicial sobre a frequência de cada classe e por fim, $p(\mathbf{x})$ trás informações sobre os dados sem sua rotulação (THEODORIDIS; KOUTROUMBAS, 2009). Esta equação sintetiza toda a informação possível para uma tomada de decisão baseada em modelos estatísticos dos dados.

O critério de decisão MAP (*maximum a posteriori*) (THEODORIDIS; KOUTROUMBAS, 2009) busca atribuir uma instância \mathbf{x} à classe i que maximiza a probabilidade a posteriori $p(\omega_i|\mathbf{x})$. Assim, uma instância é atribuída à i -ésima classe se $p(\omega_i|\mathbf{x}) > p(\omega_j|\mathbf{x})$ para todo $j \neq i$. Substituindo a expressão do Teorema de Bayes, temos:

$$\frac{p(\mathbf{x}|\omega_i)p(\omega_i)}{p(\mathbf{x})} > \frac{p(\mathbf{x}|\omega_j)p(\omega_j)}{p(\mathbf{x})} \quad (2.13)$$

Ao aplicar a função logaritmo natural a ambos os lados da desigualdade (2.13), é possível obter as funções discriminantes do classificador Bayesiano. A função discriminante para uma classe i é definida como:

$$g_i(\mathbf{x}) = \ln(p(\mathbf{x}|\omega_i)p(\omega_i)) = \ln(p(\mathbf{x}|\omega_i)) + \ln(p(\omega_i)) \quad (2.14)$$

Uma escolha comum para a função de verossimilhança $p(\mathbf{x}|\omega_i)$ é a Função Densidade de Probabilidade (FDP) Gaussiana multivariada, conforme introduzido na Seção 2.4.2.2. Neste caso, assumimos que os dados de cada classe i seguem uma distribuição normal multivariada $\mathbf{x}|\omega_i \sim N(\mu_i, \mathbf{C}_i)$, onde \mathbf{C}_i é a matriz de covariância da classe i . A expressão completa para $p(\mathbf{x}|\omega_i)$ para cada classe i é:

$$p(\mathbf{x}|\omega_i) = \frac{1}{(2\pi)^{p/2}|\mathbf{C}_i|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mu_i)^T \mathbf{C}_i^{-1}(\mathbf{x} - \mu_i)\right\} \quad (2.15)$$

Logo, a função discriminante $g_i(\mathbf{x})$ para classes balanceadas é dada por:

$$g_i(\mathbf{x}) = -\frac{p}{2} \ln(2\pi) - \frac{1}{2} \ln(|\mathbf{C}_i|) - \frac{1}{2}(\mathbf{x} - \mu_i)^T \mathbf{C}_i^{-1}(\mathbf{x} - \mu_i) \quad (2.16)$$

Definindo $Q_i(\mathbf{x}) = (\mathbf{x} - \mu_i)^T \mathbf{C}_i^{-1}(\mathbf{x} - \mu_i)$, que é a distância de Mahalanobis da i -ésima classe, a função discriminante para classes balanceadas pode ser reescrita como:

$$g_i(\mathbf{x}) = -\frac{1}{2}Q_i(\mathbf{x}) - \frac{p}{2} \ln(2\pi) - \frac{1}{2} \ln(|\mathbf{C}_i|) \quad (2.17)$$

Para classes desbalanceadas, a função discriminante completa incorpora o termo da probabilidade a priori:

$$g_i(\mathbf{x}) = -\frac{1}{2}Q_i(\mathbf{x}) - \frac{p}{2}\ln(2\pi) - \frac{1}{2}\ln(|\mathbf{C}_i|) + \ln(p(\omega_i)) \quad (2.18)$$

2.4.2.4 O algoritmo do classificador quadrático

O classificador quadrático é uma abordagem de classificação fundamentada na distância de Mahalanobis, que intrinsecamente considera a estrutura de covariância de cada classe, e sua performance é fortemente dependente da invertibilidade das matrizes de covariância envolvidas (THEODORIDIS; KOUTROUMBAS, 2009).

Para cada classe ω_i , onde $i = 1, \dots, C$, são calculados o vetor centróide (vetor de médias) \mathbf{m}_i e a matriz de covariância \mathbf{C}_i , cuja ambos derivados dos exemplos de treinamento pertencentes a essa classe. Formalmente, estas estimativas são dadas por:

$$\mathbf{m}_i = \frac{1}{N_i} \sum_{\forall \mathbf{x} \in \omega_i} \mathbf{x} \quad \text{e} \quad \mathbf{C}_i = \frac{1}{N_i} \sum_{\forall \mathbf{x} \in \omega_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T \quad (2.19)$$

onde N_i denota o número de exemplos de treinamento associados à classe ω_i .

Após a estimação desses parâmetros, procede-se ao cálculo das distâncias de Mahalanobis do novo vetor de atributos \mathbf{x} em relação a cada centróide de classe. Essa distância $Q_i(\mathbf{x})$, é uma medida ponderada que utiliza a inversa da matriz de covariância \mathbf{C}_i para levar em conta a correlação entre os atributos e suas variâncias. Em seguida, calcula-se a função discriminante $g_i^*(\mathbf{x})$ para cada uma das C classes.

É relevante destacar que, ao contrário de algumas funções discriminantes que visam maximizar probabilidades a posteriori, esta formulação é estruturada para que o vetor \mathbf{x} seja atribuído à classe que resulta no menor valor de $g_i^*(\mathbf{x})$. O critério de decisão para o classificador quadrático, portanto, envolve a identificação da classe ω_i para a qual $g_i^*(\mathbf{x})$ assume o valor mínimo entre todas as classes, como ilustrado por:

$$g_i^*(\mathbf{x}) < g_j^*(\mathbf{x}), \quad \forall j \neq i \quad (2.20)$$

Uma limitação significativa e um aspecto crítico para o desempenho adequado do classificador quadrático é a invertibilidade da matriz de covariância \mathbf{C}_i . A capacidade de uma

matriz ser invertível está intrinsecamente ligada ao seu posto matricial (vetores linearmente independentes). Para que \mathbf{C}_i seja invertível, seu posto deve ser completo, o que significa que deve ser igual à sua dimensão p . Matematicamente, o posto de \mathbf{C}_i é avaliado como:

$$\text{posto}(\mathbf{C}_i) \leq \min(p, p) = p, \quad (2.21)$$

onde p representa a dimensão do vetor de atributos.

Uma matriz é considerada de posto completo e, portanto, invertível, se $\text{posto}(\mathbf{C}_i) = p$. Adicionalmente, a colinearidade entre as linhas ou colunas de uma matriz dificulta sua invertibilidade e resulta em matrizes singulares ou mal-condicionadas.

Para mitigar os problemas de condicionamento, diversas estratégias de regularização podem ser utilizadas. Uma abordagem clássica é a regularização via adição de ruído branco gaussiano, conhecida como regularização de Tikhonov (TIKHONOV, 1963). Neste método, a matriz de covariância regularizada é obtida pela adição de um pequeno múltiplo da matriz identidade à matriz original, sendo expressa por:

$$\mathbf{C}_i(\gamma) = \mathbf{C}_i + \gamma \mathbf{I}_p, \quad (2.22)$$

onde γ é uma constante de regularização pequena. Essa técnica garante a invertibilidade da matriz de covariância e melhora a estabilidade numérica.

Uma segunda abordagem amplamente empregada é a utilização de uma matriz de covariância agregada (*pooled*), denotada por \mathbf{C}_{pool} (DUDA *et al.*, 2001; JOHNSON; WICHERN, 2007). Essa matriz é definida como uma soma ponderada das matrizes de covariância individuais de cada classe:

$$\mathbf{C}_{pool} = \sum_{i=1}^C p(\omega_i) \mathbf{C}_i, \quad (2.23)$$

onde $p(\omega_i) = N_i/N$ corresponde à probabilidade a priori da classe ω_i , com N_i representando o número de amostras da classe i e N o número total de amostras.

Outra variante relevante é o método de regularização proposto por Friedman (1989), que realiza uma combinação ponderada entre a matriz de covariância individual de cada classe e a matriz de covariância agregada. A matriz regularizada $\mathbf{C}_i(\lambda)$ é definida por:

$$\mathbf{C}_i(\lambda) = \frac{(1-\lambda)\mathbf{S}_i + \lambda\mathbf{S}_{pool}}{(1-\lambda)N_i + \lambda N}, \quad (2.24)$$

onde $0 \leq \lambda \leq 1$, $\mathbf{S}_i = N_i\mathbf{C}_i$ e $\mathbf{S}_{pool} = N\mathbf{C}_{pool}$. Para $\lambda = 0$, recupera-se a matriz de covariância individual da classe, enquanto para $\lambda = 1$ obtém-se a matriz de covariância agregada:

$$\mathbf{C}_i(\lambda) = \begin{cases} \mathbf{C}_i, & \lambda = 0 \\ \mathbf{C}_{pool}, & \lambda = 1 \end{cases} \quad (2.25)$$

Por fim, existe uma variante que assume a mesma hipótese do classificador Naive Bayes, considerando apenas os termos da diagonal principal da matriz de covariância (DOMINGOS; PAZZANI, 1997). Nessa abordagem, a matriz de covariância é aproximada por uma matriz diagonal composta exclusivamente pelas variâncias dos atributos, o que implica na suposição de independência estatística entre eles. Essa simplificação reduz o custo computacional e garante a invertibilidade da matriz, desde que as variâncias sejam não nulas.

2.4.3 Análise de Componentes Principais (PCA)

O objetivo primário da Análise de Componentes Principais (PCA) (JOLLIFFE, 2002; PEARSON, 1901) é transformar um conjunto de dados original, representado por vetores de dimensão p , em um novo conjunto de dimensão q , tal que $q \leq p$. Os dados são organizados na matriz $\mathbf{X} \in \mathbb{R}^{p \times N}$, onde cada coluna é um vetor de atributos. O processo inicia-se com a centralização dos dados através da subtração do vetor-médio $\bar{\mathbf{x}}$, definido por:

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \quad (2.26)$$

Com os dados centralizados, a matriz de covariância \mathbf{C}_x é estimada pela média amostral:

$$\mathbf{C}_x \approx \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \mathbf{x}_k^T \quad (2.27)$$

O cerne do algoritmo reside na resolução do problema de autovalor e autovetor a partir da matriz de covariância:

$$\mathbf{C}_x \mathbf{v} = \Lambda \mathbf{v} \quad (2.28)$$

A matriz \mathbf{C}_x é simétrica e positiva definida. Seus autovetores \mathbf{v}_i formam uma base ortonormal, onde são dispostos como colunas para formar a matriz \mathbf{V} , sendo a matriz de transformação linear \mathbf{Q} definida por:

$$\mathbf{Q} = \mathbf{V}^T \quad (2.29)$$

A transformação para os dados originais é então aplicada de forma matricial:

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} \quad (2.30)$$

Esta operação resulta na diagonalização da matriz de covariância dos dados transformados, \mathbf{C}_z , cujos elementos da diagonal são os autovalores:

$$\mathbf{C}_z = \mathbf{V}^T \mathbf{C}_x \mathbf{V} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_p^2) = \text{diag}(\Lambda_1, \Lambda_2, \dots, \Lambda_p) \quad (2.31)$$

A transformação linear da PCA pode ser entendida como uma mudança de base (BISHOP, 2006; STRANG, 2016). Uma base em um espaço \mathbb{R}^n é um conjunto de n vetores linearmente independentes que pode ser usado para representar qualquer vetor naquele espaço.

A PCA projeta os dados em uma nova base, que é formada pelos autovetores ortonormais da matriz de covariância \mathbf{C}_x . Enquanto no espaço original os atributos podem ser correlacionadas, no novo espaço transformado, as componentes principais são por construção, decorrelacionadas. Geometricamente, o processo de decorrelação realizado pela PCA corresponde a uma rotação do sistema de coordenadas original para um novo sistema alinhado com as direções de máxima variância dos dados.

A informação total contida nos dados originais pode ser quantificada pela variância total (VT), definida como a soma das variâncias de cada componente, que é igual ao traço da matriz de covariância e, conseqüentemente, à soma de todos os seus autovalores (ABDI; WILLIAMS, 2010; HASTIE *et al.*, 2009):

$$VT = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_p^2 = \Lambda_1 + \Lambda_2 + \dots + \Lambda_p \quad (2.32)$$

Considerando que os autovalores representam a variância dos dados ao longo das novas direções (componentes principais), é possível criar uma medida de quanta informação do conjunto original é capturada por cada componente principal. De forma análoga, a porcentagem da variância total dos dados explicada pelos primeiros q autovalores (e, portanto, pelas primeiras q componentes principais) é dada pela variância explicada acumulada, $VE(q)$:

$$VE(q) = 100 \times \frac{\sum_{i=1}^q \Lambda_i}{VT} = 100 \times \left(\frac{\Lambda_1 + \Lambda_2 + \dots + \Lambda_q}{\Lambda_1 + \Lambda_2 + \dots + \Lambda_p} \right). \quad (2.33)$$


Dessa forma, a redução de dimensionalidade é obtida ao selecionar $q < p$, permitindo a representação do conjunto de dados com menor custo computacional e preservando a estrutura principal da informação.

2.4.4 Redes neurais artificiais

2.4.4.1 Perceptron simples

A estrutura de um *perceptron* simples é constituída por um conjunto de entradas x_1, x_2, \dots, x_p , que são ponderadas por pesos sinápticos w_1, w_2, \dots, w_p . Adicionalmente, há um termo de polarização (bias), representado por w_0 com uma entrada fixa x_0 , frequentemente definida como 1. A simplicidade desse modelo está no fato de possuir um único neurônio artificial. A figura 6 ilustra sua arquitetura básica (HAYKIN, 2008).

Figura 6 – Representação da rede Perceptron simples.



Fonte: Elaborado pelo autor (2026).

O funcionamento do *perceptron* baseia-se no cálculo do potencial de ativação v , obtido pela soma ponderada das entradas, seguido da aplicação de uma função de ativação $f(\cdot)$:

$$v = \sum_{i=0}^p w_i x_i = \mathbf{w}^T \mathbf{x} \quad (2.34)$$

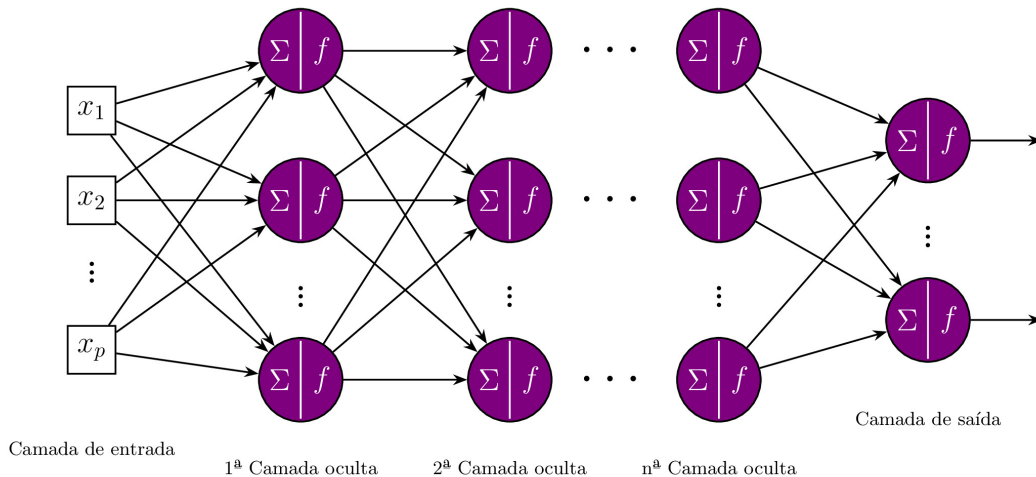
$$y = f(v) \quad (2.35)$$

onde $\mathbf{w} = [w_0, w_1, \dots, w_p]^T$ representa o vetor de pesos e $\mathbf{x} = [1, x_1, \dots, x_p]^T$ o vetor de entrada aumentado. Podem ser utilizadas funções de ativação do tipo degrau ou degrau bipolar, resultando em saídas binárias. A principal limitação desse modelo é sua incapacidade de resolver problemas que não são linearmente separáveis (HAYKIN, 2008).

2.4.4.2 Perceptron de Múltiplas Camadas

Para superar a limitação do perceptron simples, foram desenvolvidas as redes *Perceptron* de Múltiplas Camadas (MLP, do inglês *Multi-Layer Perceptron*), que são caracterizadas pela presença de uma ou mais camadas ocultas entre a camada de entrada e a camada de saída (HAYKIN, 2008; BISHOP, 2006). A figura 7 apresenta uma arquitetura genérica desse modelo.

Figura 7 – Representação da rede Perceptron de múltiplas camadas.



Fonte: Elaborado pelo autor (2026).

As redes MLP pertencem à arquitetura *feedforward*, na qual o fluxo de informação ocorre exclusivamente da entrada para a saída, sem realimentação (GOODFELLOW *et al.*, 2016). Para um neurônio j localizado na camada L , o potencial de ativação e a saída são definidos por:

$$v_j^{(L)} = \sum_i w_{ji}^{(L)} y_i^{(L-1)}, \quad (2.36)$$

$$y_j^{(L)} = f(v_j^{(L)}), \quad (2.37)$$

onde $y_i^{(L-1)}$ é a saída do neurônio i da camada anterior, $w_{ji}^{(L)}$ representa o peso sináptico da conexão correspondente e $f(\cdot)$ é uma função de ativação não linear e diferenciável.

Para problemas de classificação com C classes mutuamente exclusivas, utiliza-se tipicamente a codificação *one-hot*, que representa cada classe como um vetor canônico em \mathbb{R}^C . Sendo $k \in \{1, \dots, C\}$ o índice da classe real à qual a instância pertence e $j \in \{1, \dots, C\}$ o índice genérico que percorre todas as classes possíveis, a definição formal do vetor de saída desejado é (BISHOP, 2006; GOODFELLOW *et al.*, 2016):

$$\mathbf{t}_{\text{classe}} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_C \end{bmatrix}, \quad \text{onde } t_j = \begin{cases} 1 & \text{se } j = \text{classe} \\ 0 & \text{caso contrário} \end{cases}$$

Para problemas de classificação, uma possibilidade de função custo recomendada é a entropia cruzada, que mede a divergência entre as distribuições de probabilidade prevista ($\hat{\mathbf{y}}$) e real (\mathbf{t}):

$$J = -\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^C t_{nk} \ln(\hat{y}_{nk}), \quad (2.38)$$

onde N é o número de amostras, C o número de classes, t_{nk} o rótulo verdadeiro em codificação *one-hot* e \hat{y}_{nk} a probabilidade estimada pela rede (GOODFELLOW *et al.*, 2016).

O treinamento de redes MLP é realizado por meio do algoritmo *backpropagation*, que ajusta iterativamente os pesos da rede com base no gradiente descendente da função de custo. Esse processo ocorre em duas fases: propagação direta dos sinais (*forward*) e retropropagação do erro (*backward*) (RUMELHART *et al.*, 1986; HAYKIN, 2008).

O ajuste do peso $w_{ji}^{(L)}$ é proporcional ao gradiente negativo da função custo com respeito a esse peso. Para otimizar a convergência, a regra de atualização é comumente estendida para incluir um termo de *momentum*, que adiciona uma fração do ajuste de peso anterior à

atualização atual, ajudando a suavizar oscilações e acelerar o treinamento. A regra de atualização do peso é dada por:

$$\Delta w_{ji}^{(L)}(\tau) = \eta \delta_j^{(L)} y_i^{(L-1)} + \alpha \Delta w_{ji}^{(L)}(\tau - 1) \quad (2.39)$$

onde τ indica a iteração atual, η é a taxa de aprendizado, α é o termo *momentum*, e $\delta_j^{(L)}$ o gradiente local do neurônio j .

Para um neurônio j na camada de saída, o gradiente local $\delta_j^{(L)}$ é:

$$\delta_j^{(L)} = (t_j - y_j^{(L)}) f'(v_j^{(L)}) \quad (2.40)$$

onde t_j é a saída desejada, $y_j^{(L)}$ é a saída produzida e $f'(\cdot)$ é a derivada da função de ativação.

A complexidade de uma rede MLP pode ser quantificada pelo número total de parâmetros livres W , correspondente à quantidade de pesos e termos de polarização. Para uma rede (uma camada oculta) com p entradas, H neurônios na camada oculta e C neurônios na camada de saída, esse número é dado por:

$$W = (p + 1)H + (H + 1)C. \quad (2.41)$$

Valores elevados de W aumentam o risco de sobreajuste (*overfitting*), situação em que o modelo se ajusta excessivamente aos dados de treinamento. Para mitigar esse problema, os dados são particionados em conjuntos de treinamento e validação. Segundo Haykin (2008), uma heurística para estimar a fração ótima de dados de treinamento é dada por:

$$r_{\text{ótimo}} \approx 1 - \frac{1}{\sqrt{2W}}. \quad (2.42)$$

Essa relação indica que a fração de dados destinada à validação é inversamente proporcional à complexidade do modelo, sendo fundamental para o monitoramento da capacidade de generalização da rede e para a aplicação de técnicas como a parada antecipada (*early stopping*).

2.4.4.3 Funções de ativação

As funções de ativação não-lineares são componentes essenciais das redes MLP, pois introduzem a não-linearidade e garantem a diferenciabilidade necessária para o algoritmo

backpropagation. Suas derivadas, $f'(\cdot)$, são um elemento central no cálculo dos gradientes locais ($\delta_j^{(L)}$). Três funções são particularmente relevantes para o algoritmo:

- **Tangente hiperbólica (Tanh):** Que produz saídas no intervalo $[-a, a]$.

$$f(v) = a \tanh(bv), \quad (2.43)$$

- **Sigmoide logística:** Com saídas no intervalo $(0, 1)$.

$$f(v) = \frac{1}{1 + e^{-cv}}, \quad (2.44)$$

- **Softmax:** Amplamente empregada na camada de saída de classificadores multiclasse.

$$\hat{y}_j = \frac{e^{v_j}}{\sum_{k=1}^C e^{v_k}}, \quad (2.45)$$

Quando a função softmax é utilizada em conjunto com a entropia cruzada, a derivada dessa função custo em relação ao potencial de ativação v_j assume uma forma simples e numericamente estável (BISHOP; BISHOP, 2024):

$$\frac{\partial J}{\partial v_j} = \hat{y}_j - t_j, \quad (2.46)$$

onde \hat{y}_j representa a saída predita pela rede e t_j o rótulo verdadeiro correspondente, codificado no formato *one-hot*.

3 METODOLOGIA

3.1 Sinais simulados

3.1.1 Material da simulação e a peça

Para a modelagem computacional dos cordões de solda contendo as descontinuidades consideradas, bem como a simulação da propagação de ondas ultrassônicas, foi empregado o software COMSOL *Multiphysics*, utilizando o módulo Mecânica estrutural dos sólidos.

O material simulado, um aço carbono (ex. AISI 1020), é tratado como Linear - Elástico com as seguintes propriedades essenciais: densidade (ρ) de 7800 kg/m³, velocidade da onda longitudinal (V_L) de 5900 m/s e velocidade da onda transversal (V_T) de 3200 m/s. A suposição de elasticidade linear implica que o comportamento mecânico é regido pela Lei de Hooke, cuja uma das equação mais importantes é a relação constitutiva entre a tensão e a deformação elástica:

$$S_{el} = C : \varepsilon_{el} \quad (3.1)$$

Nessa relação, S_{el} é o tensor de tensão elástica, ε_{el} é o tensor de deformação elástica, e C é o tensor de elasticidade de quarta ordem, cujos componentes são calculados a partir das velocidades das ondas e da densidade do material modelado.

O comprimento da peça foi determinado para permitir o posicionamento adequado do transdutor emissor e do receptor. A distância entre os transdutores (D_{tr}) foi definida pela equação abaixo para garantir a cobertura da espessura completa da peça pelo feixe ultrassônico:

$$D_{tr} = 2L \tan(\theta_s) \quad (3.2)$$

onde L o comprimento da peça e θ_s o ângulo de incidência do feixe.

Adicionalmente, para a angulação do feixe ultrassônico, foi utilizado o princípio de funcionamento do *Phased Array*, que se baseia no controle eletrônico dos vários elementos do transdutor, excitados em momentos ligeiramente diferentes. Dessa forma, o comprimento da peça necessita ser maior que D_{tr} .

3.1.2 Transdutores e seus parâmetros

Para garantir uma maior qualidade tanto na emissão do feixe ultrassônico quanto na sensibilidade da pressão sonora, é necessário analisar a quantidade de elementos vibrantes e cristais que compõem os transdutores emissores e receptores, a distância entre esses elementos vibrantes, o seu tamanho e como a interação entre os pulsos ultrassônicos irá influenciar no ângulo de incidência (θ_s) da fonte de emissão.

No estudo de Wooh e Shi (1999), quanto maior o número de elementos/cristais piezoelétricos, maior é a amplitude do feixe, o que proporciona uma melhor detecção de possíveis defeitos. Outro fator que afeta positivamente a pressão sonora em uma determinada direção é o aumento da quantidade de cristais. Segundo Wooh e Shi (1999), a equação 3.3 define a distância máxima entre os cristais para a produção de sinais adequados:

$$d_{cr} = \frac{\lambda}{1 + \sin(\theta_s)_{\max}} \quad (3.3)$$

Considerando um ângulo crítico de no máximo 90° , o ideal é que a distância entre os cristais seja de no máximo, a metade do comprimento de onda (λ_L) da onda longitudinal que viaja pelo material. O ângulo de incidência utilizado foi de 60° , o mesmo utilizado para captura dos sinais reais, como será visto posteriormente ainda na metodologia. Portanto, para os objetivos da simulação, cada transdutor terá um total de 8 cristais, onde para o transdutor emissor cada cristal terá 8 pontos vibrantes. A tabela 2 apresenta as dimensões e alguns parâmetros importantes do transdutor emissor e da peça:

Para a formação e simulação dos 8 cristais, utilizou-se 9 pontos igualmente espaçados (d_c). A cada um desses pontos é aplicada uma função trigonométrica dependente do tempo. Esses 9 pontos compõem o transdutor, no qual cada ponto possui um tempo de início e fim de vibração. Os pulsos foram defasados por um Δt de aproximadamente 86,603 ns, obtido através da equação 3.4.

$$\Delta t = \frac{d_c \cdot \sin(\theta_s)}{V_L} \quad (3.4)$$

A equação 3.5 apresenta a função da fonte excitadora dos pontos vibrantes do transdutor.

$$F(t)_k = \left[1 - \cos\left(\frac{2\pi f(t + k\Delta t)}{3}\right) \right] \cos(2\pi f(t + k\Delta t)) \quad (3.5)$$

Tabela 2 – Parâmetros utilizados para modelagem da peça e dos transdutores.

Parâmetro	Variável	Valor
Comprimento da peça	L	100 mm
Densidade do material	ρ	7800 kg/m ³
Velocidade da onda longitudinal	V_L	5900 m/s
Velocidade da onda transversal	V_T	3200 m/s
Frequência de propagação das ondas	f	5 MHz
Número de cristais (Transdutor emissor)	N_{ce}	8
Número de pontos vibrantes (Transdutor emissor)	N_{ve}	8
Distância entre cristais	d_c	$\lambda_L/2$
Espaçamento entre os pontos vibrantes	d_v	$\lambda_L/14$

Fonte: Elaborado pelo autor (2026).

3.1.3 Defeitos, malha e condições de contorno da simulação

O sinal de leitura é sintetizado a partir de 8 cristais leitores (N_{cr}), cada um com 8 sensores (N_{ve}). O construção do A-scan requer a remoção do atraso temporal (Δt) gerado pelos cristais emissores e seus pontos vibrantes.

Matematicamente, o sinal total processado no instante t_i , denominado $S(t_i)$ ou sinal *forward*, é obtido pela soma coerente dos sinais de pressão medidos $P(t, j)$ em todos os sensores j ($N = 64$ sensores), após a correção temporal τ_k . Essa operação é conhecida como soma e atraso (do inglês, *sum-and-delay*) (DRINKWATER; WILCOX, 2006), e pode ser descrita pela seguinte equação:

$$S(t_i) = \sum_{k=1}^{N_c} \left(\sum_{j \in I_k} P(t_i + \tau_k, j) \right) \quad (3.6)$$

No presente trabalho, foram modeladas três descontinuidades tipicamente encontradas em juntas soldadas, sendo elas a falta de penetração (FP), o poro (PO) e a falta de fusão (FF), sendo adicionadas com diferentes dimensões e posições ao longo da peça modelada.

A falta de penetração (FP) foi modelada com 108 combinações de alturas (a) (3 mm a 8 mm, incremento de 1 mm) e larguras (b) (1 mm a 6 mm, incremento de 1 mm), em três posições centrais (p_x) (47 mm, 50 mm e 53 mm no eixo x). Para o poro (PO) utilizou-se uma variação de três diâmetros (d) (1 mm, 2 mm e 3 mm) e tiveram sua localização variada sistematicamente 36 vezes para cada diâmetro. A falta de fusão (FF), com largura fixa (l) de 0,2 mm, onde foram variadas em três alturas (h) (2 mm, 4 mm, e 6 mm) e tiveram sua posição também modificada 36 vezes para cada altura.

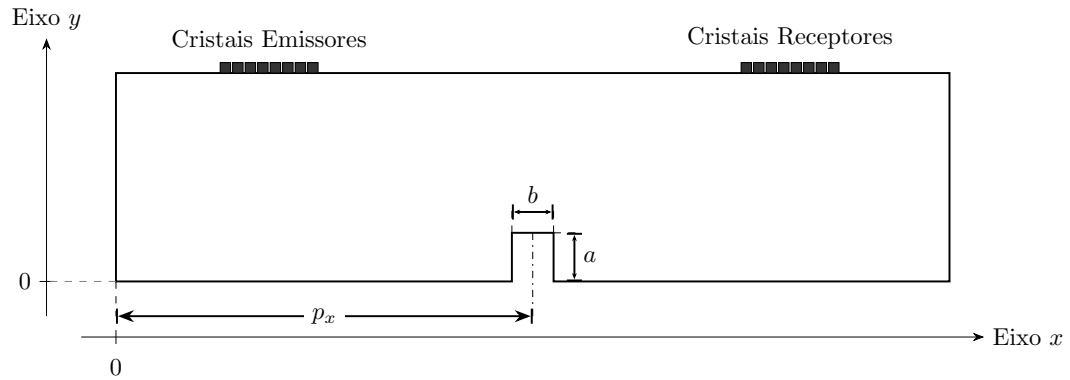
Todas as simulações ocorreram na região entre 33 mm e 66 mm no eixo x , e também foram garantidas restrições de profundidade para o poro e a falta de fusão (parte superior dos defeitos com uma distância de 6 mm da interface superior e 4 mm da interface inferior da peça, em relação ao eixo y). A figura 8 mostra um esquemático de como os defeitos das simulações foram distribuídos ao longo da peça modelada.

Referente às condições de contorno, a interface superior foi definida como livre, visto que é a região de posicionamento dos transdutores, onde não são apresentadas restrições de deslocamento. Nas paredes laterais, aplicou-se a condição de fronteira de baixa reflexão para amortecimento das ondas. Por fim, na parede inferior e nas interfaces das discontinuidades, utilizou-se a condição de deslocamento nulo, onde a grande diferença de impedância acústica entre o aço modelado e o ar provoca a reflexão total da onda.

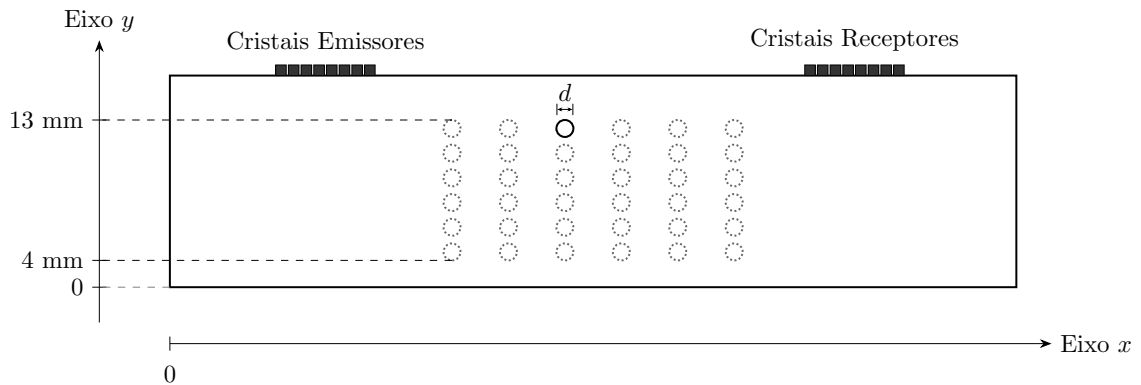
No presente trabalho, testes preliminares foram realizados e o critério do tamanho da malha foi estabelecido. Para o defeito da falta de penetração (FP), o maior elemento de malha utilizado foi $\lambda_L/10$, enquanto que para o poro (PO) e a falta de fusão (FF), o tamanho máximo do elemento de malha foi de $\lambda_L/12$. Para a simulação foi utilizada uma malha triangular adaptável. Cada sinal simulado demorou 1 hora para o defeito da falta de penetração (FP), e de 2 a 3 horas para os defeitos dos poro (PO) e da falta de fusão (FF), respectivamente.

Cada sinal *forward* simulado resultou, originalmente, em um vetor contendo 4831 pontos com uma duração total de 19,32 μs . Apenas a janela de tempo entre 10 μs e 15,12 μs foi utilizada, pois ela contém os eventos de interesse, como a onda lateral, ocorrendo aproximadamente aos 12 μs , a onda difratada pelo defeito e o eco da parede oposta, por volta de 13,5 μs , totalizando uma duração de 5,12 μs , assim como os sinais reais. Este recorte resultou em um vetor de 1280 pontos, o qual foi submetido a uma interpolação *spline* para redimensionamento em 512 pontos (mesmo tamanho dos sinais reais, apresentado na sessão 3.2).


Figura 8 – Esquemático do posicionamento dos defeitos modelados ao longo da peça.



(a) Falta de penetração (FP)



(b) Poro (PO)



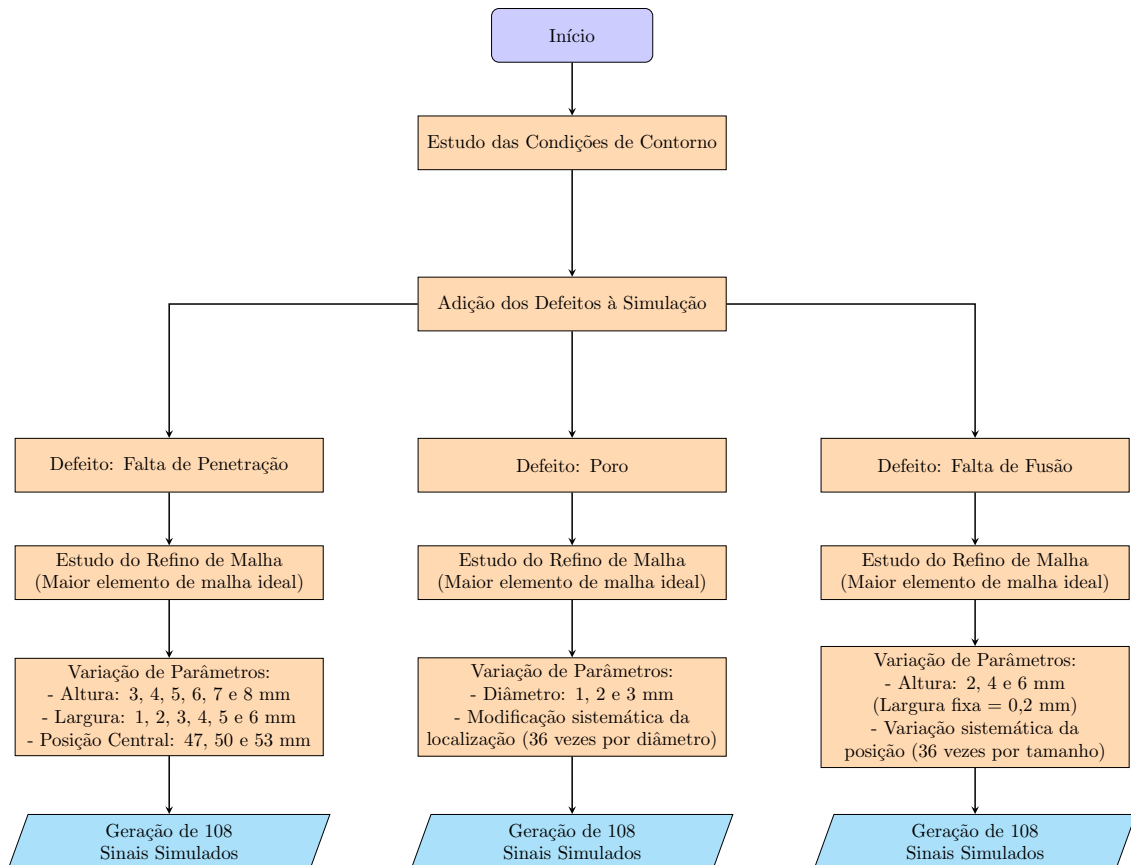
(c) Falta de fusão (FF)

Fonte: Elaborado pelo autor (2026).

O passo de tempo (distância temporal dt entre duas amostras vizinhas de um sinal) dos sinais simulados é de $0,004 \mu\text{s}$, correspondendo a uma taxa de amostragem de 100MSa/s , parâmetros equivalentes aos utilizados na aquisição dos sinais reais, conforme será detalhado ainda na metodologia (sessão 3.2).

A figura 9 apresenta o fluxograma resumido do passo a passo adotado para a geração dos 324 sinais ultrassônicos simulados.


Figura 9 – Fluxograma metodológico para geração dos sinais simulados para diferentes defeitos adicionados a modelagem da peça.




Fonte: Elaborado pelo autor (2026).

A figura 10 apresenta exemplos da interação dos campos de deslocamento resultantes com os três tipos de defeitos simulados em um determinado instante, e os seus respectivos A-scans com a indicação da onda de superfície, o defeito e o eco de fundo (parede oposta). Para o exemplo da falta de penetração, na figura, utilizou-se as dimensões $a = 4$ mm e $b = 3$ mm. Para o poro, a descontinuidade do exemplo foi modelada com diâmetro $d = 3$ mm. Por fim, a falta de fusão foi definida com uma largura de $l = 0,2$ mm e altura $h = 2$ mm.


Figura 10 – Campos de deslocamento simulados para os diferentes defeitos (FP, PO e FF) e seus respectivos A-scans.



(a) Falta de Penetração (FP)



(b) Poro (PO)



(c) Falta de Fusão (FF)

Fonte: Elaborado pelo autor (2026).

3.2 Sinais reais

Os sinais reais experimentais analisados neste estudo foram obtidos durante inspeções ultrassônicas realizadas com a técnica *Time-of-Flight Diffraction* (TOFD) sobre um conjunto de doze 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 graus, 2 mm de distância na raiz, unidos por processo de soldagem a arco com eletrodo revestido (SMAW, do inglês *Shielded Metal Arc Welding*), conforme a metodologia detalhada por Moura *et al.* (2005a).

Durante o processo de soldagem, defeitos do tipo falta de fusão (FF), falta de penetração (FP) e poro (PO) foram intencionalmente inseridos aos cordões de solda, e suas posições, dimensões e tipos posteriormente determinados por ensaios ultrassônicos convencionais e confirmados por radiografias.

A inspeção dos corpos de prova pela técnica TOFD foi realizada com auxílio de um veículo (*scanner*) responsável pelo deslocamento dos transdutores ultrassônicos e pelo melhor acomodamento possível entre eles e a região inspecionada. Foram utilizados transdutores MSW/QC/PC da KRAUTKRAMER, com 6 mm de diâmetro e frequência central de 5 MHz, montados sobre cunhas para produzir ondas longitudinais refratadas no aço com ângulo de incidência de 60 graus. O posicionamento do veículo e o registro dos sinais A-scan foram controlados por computador.

Os sinais A-scan foram registrados a cada 1 mm de deslocamento ao longo da solda. Todos eles foram registrados com 512 pontos e taxa de amostragem de 100 MHz (MOURA *et al.*, 2005b). Após as inspeções dos corpos de prova, e utilizando o resultado das radiografias como gabarito, um total de 180 sinais (A-scan), igualmente divididos entre falta de fusão (FF), falta de penetração (FP) e porosidade (PO) foram selecionados para serem utilizados como instâncias de teste dos algoritmos classificadores.

3.3 Classificação

Os dados simulados foram pré-processados (análise de componentes principais (PCA), redução do número de pontos, transformada de Hilbert e normalizações) e serviram para alimentar os classificadores propostos no trabalho, que são: *K-Nearest Neighbors* (KNN), classificador quadrático e redes neurais artificiais.

3.3.1 *K-Nearest Neighbors* (KNN)

O algoritmo *K-Nearest Neighbors* (KNN) foi utilizado para tarefa de classificação. Como apresentado pela tabela 1 e pela equação 2.4, para cada parâmetro m é possível encontrar um caso particular da distância de Minkowski. Por consequência geométrica, a variação dessa

distância implica (como dito na seção 2.4.1.4 e evidenciado na figura 3) na variação dos lugares geométricos, impactando diretamente no modelo de classificação KNN. Por esse motivo, para o trabalho em questão, foram utilizadas 3 distâncias $m \in \{1/2, 1, 2\}$, visando explorar diferentes aspectos geométricos dos vizinhos mais próximos.

Além da métrica das distâncias de Minkowski, a classificação foi avaliada considerando a variação do número de vizinhos mais próximos (K). Para este estudo, o parâmetro K foi sistematicamente analisado, empregando-se os valores $K \in \{1, 3, 5\}$. A classificação da nova instância x_{new} é determinada por um processo de votação majoritária entre os rótulos de classe dos K vizinhos mais próximos. A estratégia de classificação empregada é baseada em uma lógica de votação para garantir a decisão por:

1. **Votação e critério de maioria absoluta:** Identifica-se a classe com o maior número de votos (V_c), designada \hat{y}_{voto} . A classificação é considerada final se a classe \hat{y}_{voto} obtiver a maioria dos votos, isto é:

$$V_{\hat{y}_{\text{voto}}} > \frac{K}{2} \quad (3.7)$$

2. **Lógica de desempate:** Se a condição de maioria absoluta não for atendida ($V_{\hat{y}_{\text{voto}}} \leq K/2$), o que pode ocorrer em casos de empate, o desempate é resolvido pela classe do vizinho mais próximo.

3.3.2 Classificador quadrático

Para o classificador quadrático, foram investigadas quatro variantes descritas nas referências teóricas. A tabela 3 apresenta a numeração e as siglas adotadas para as matrizes de covariância associadas a cada variante. A função discriminante do classificador quadrático possui, como um de seus termos fundamentais, a distância de *Mahalanobis*, a qual é ponderada pela inversa da matriz de covariância. Dessa forma, diferentes mecanismos de regularização dessa matriz foram adotados, visando melhorar o desempenho do classificador.

Vale ressaltar que para a variante Friedman, o λ foi variado de 0,1 até 0,9, com espaçamento de 0,1. O objetivo é encontrar uma matriz de covariância que melhor combine a matriz de covariância original das classes (C_x) e a agregada (C_{pool}).

Tabela 3 – Variantes de Regularização da Matriz de Covariância do classificador quadrático.

Variante	Siglas das matrizes de covariância	Numeração
Regularização de Tikhonov	$C_i(\gamma)$	1
<i>Pooled</i>	C_{pool}	2
Friedman	$C_i(\lambda)$	3 (λ)
Naive Bayes	$C_{i,\text{diag}}$	4

Fonte: Elaborado pelo autor (2026).

3.3.3 *Redes neurais artificiais*

No trabalho foram utilizados dois algoritmos baseados em redes neurais artificiais: o *perceptron* de camada única (*Single-Layer Perceptron* (SLP), do inglês) e o *perceptron* de múltiplas camadas (MLP) com até duas camadas ocultas. O objetivo principal disto é avaliar a melhora no desempenho dos modelos em função do aumento de sua complexidade e análise do custo benefício entre desempenho de classificação e eficiência computacional. A taxa de aprendizado (η) foi variada entre 0,01 e 0,001, e o termo *momentum* (α) entre 0,99, 0,95 e 0,90, sendo esses parâmetros variados em todos os modelos neurais citados.

3.3.4 *Perceptron de camada única (SLP)*

Para o SLP, foram exploradas diversas combinações de funções de ativação e seus parâmetros para a camada única de saída, com a entropia cruzada fixada como função custo. As funções de ativação testadas para a camada única foram a tangente hiperbólica (tanh), a sigmoide logística e a softmax. Para a tanh, os parâmetros a e b foram variados nos pares [1 ; 1] e [1,7159 ; 2/3] (HAYKIN, 2008). Para a função logística, o parâmetro c foi variado entre 1 e 2,2 (HAYKIN, 2008). A função softmax foi utilizada sem variação de parâmetros.

3.3.5 *Perceptron de múltiplas camadas (MLP)*

No MLP, a função softmax foi fixada na camada de saída. Para a(s) camada(s) oculta(s), a função de ativação foi variada entre a tangente hiperbólica (tanh) e a sigmoide logística empregando-se as mesmas constantes de variação paramétrica definidas para o *Perceptron* de camada única e mesma função custo. A estimação do número de neurônios da(s) camada(s) oculta(s) foi realizada utilizando uma das heurística presente no trabalho de Syaharuddin *et al.* (2022). Esta heurística é creditada a Laurence (1994) e é conhecida como a fórmula de Lawrence

& Fredrickson:

$$N_z = \frac{N_x + N_y}{2} \quad (3.8)$$

Nesta equação, N_z representa o número de neurônios da camada oculta, o N_x é o número de neurônios da camada de entrada e N_y é o número de neurônios da camada de saída. A fórmula foi aplicada sequencialmente para a arquitetura de duas camadas ocultas onde o número de neurônios da segunda camada oculta foi calculado utilizando o número de neurônios da primeira camada oculta como a nova entrada (N_x), mantendo-se o número de saídas (N_y) original.

3.3.6 *Pré-processamento e subdivisão dos conjuntos de treino e teste*

A avaliação dos classificadores ocorreu em duas etapas. A primeira, denominada "Simulados X Simulados", avaliou o desempenho dos classificadores apenas com os dados simulados, separando 80% das instâncias do conjunto para treinar o modelo e as demais para testá-lo. Isso foi executado 100 vezes, selecionando as instâncias de treino e teste aleatoriamente (balanceadas por classe) em cada rodada. Ao final das 100 execuções, foram computadas as acurácias médias, medianas, máximas, bem como as acurácias por classe, para a avaliação do desempenho dos classificadores.

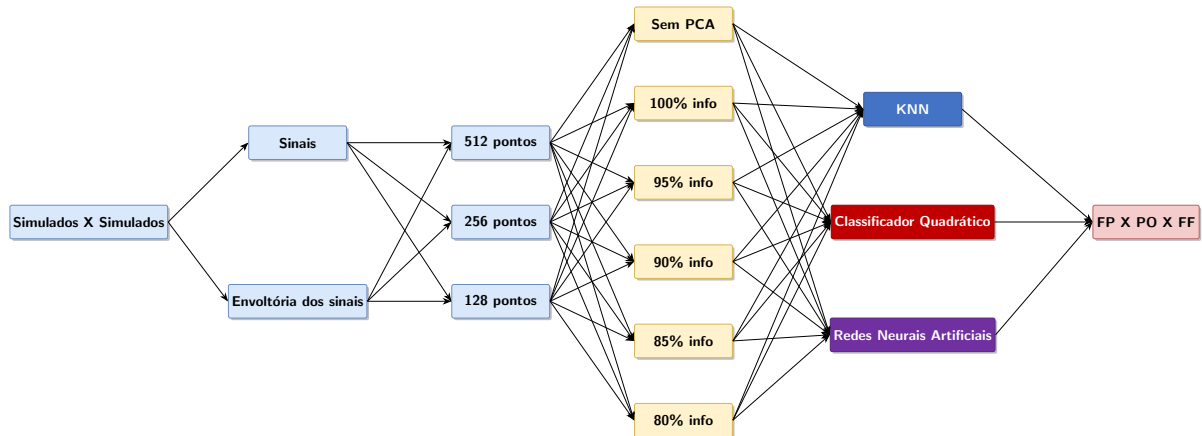
Conforme ilustrado no fluxograma da figura 11, foi investigado o impacto das diferentes técnicas de pré-processamento dos dados no desempenho dos classificadores para "Simulados X Simulados". Inicialmente, aplicou-se uma redução dimensional no domínio do tempo para avaliar a relação entre eficiência computacional e a manutenção da acurácia média e por classe. Partindo da quantidade original de 512 pontos, geraram-se vetores de 256 e 128 pontos através da retenção de amostras ímpares e remoção das amostras pares, conforme a Equação 3.9:

$$y[n] = x[2n - 1], \quad \text{para } n = 1, 2, \dots, \frac{P}{2} \quad (3.9)$$

Após isso, aos sinais com 512, 256 e 128 pontos foram aplicadas a transformada de Hilbert, para geração do envelope desses sinais. Na sequência, os dados (tanto os sinais simulados quanto as suas envoltórias) foram submetidos à análise de componentes principais (PCA),

variando-se a variância explicada acumulada em: 100%, 95%, 90%, 85% e 80%. Essa varredura busca identificar e quantificar a robustez dos modelos frente à compressão da informação.

Figura 11 – Fluxograma do planejamento do trabalho (Simulados X Simulados).



Fonte: Elaborado pelo autor (2026).

O objetivo desta etapa (Simulados X Simulados) é selecionar as configurações de pré-processamento (aplicação da transformada de Hilbert aos sinais ou não, quantidade de pontos utilizadas e percentual de informação da PCA) que ofereçam o melhor balanço entre eficiência computacional e acerto médios (tanto por classe quanto geral). Os pré-processamentos validados com melhor custo benefício na etapa Simulados X Simulados serão utilizados para a etapa subsequente de generalização denominada "Simulados X Reais", onde os classificadores foram treinados com dados dos sinais simulados e testados com os dados dos sinais reais.

A avaliação dos modelos quando testados com os dados dos sinais reais foi realizada em classificações binárias, ternárias e hierárquicas, utilizando a configuração de pré-processamento escolhida em Simulados X Simulados. Para as classificações ternárias, o objetivo é a distinção simultânea entre os três defeitos. Já nas classificações binárias (FP X PO, FP X FF e PO X FF), a finalidade é analisar separação de cada par de defeitos.

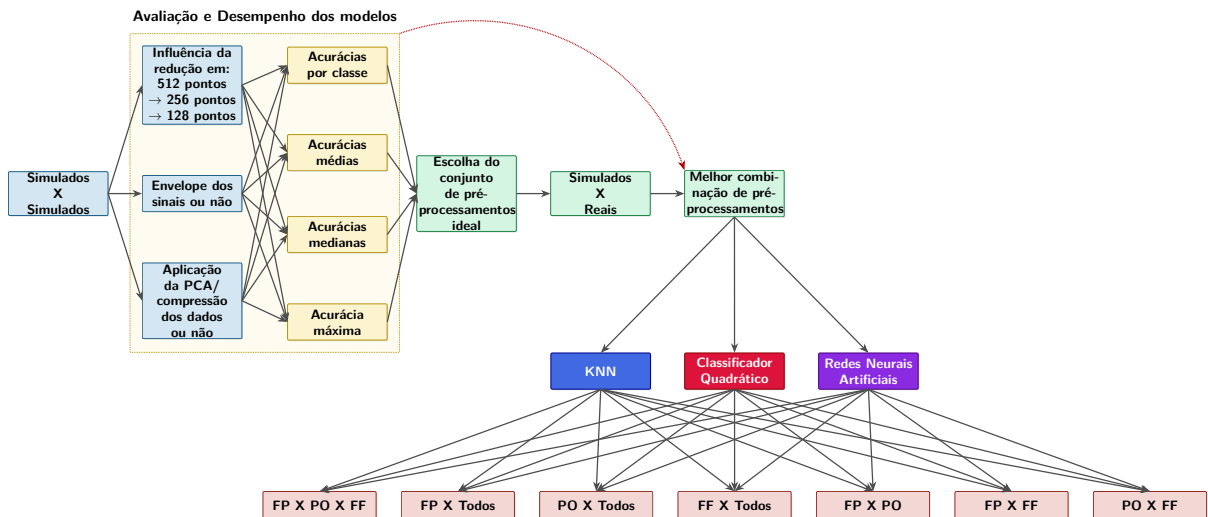
Nessas duas formas de classificação (binárias e ternárias), para o KNN e o classificador quadrático, em cada rodada, 80% dos dados simulados foram sorteados por classe para o treino, com 100% dos dados reais para o teste, buscando encontrar um conjunto de instâncias simuladas que combinadas, gerem o melhor desempenho de classificação (acurácia máxima) para classificação dos defeitos a partir dos dados reais utilizados no conjunto de teste.

Em contraste, para o SLP e o MLP, nas classificações binárias e ternárias, todo o conjunto de dados simulados foi utilizado, sendo que em cada rodada, esse mesmo conjunto foi

subdividido, com uma parte destinada ao treinamento e outra parte sendo sorteada para compor o conjunto de validação (definida pela equação 2.42). Vale ressaltar que, é necessário 100 rodadas de avaliação de desempenho do SLP e do MLP, pois além da distinta subdivisão do conjunto de validação por rodada, os valores dos pesos são inicializados com valores diferentes.

A classificação hierárquica (FP X Todos, PO X Todos, FF X Todos) foi utilizada para avaliar os modelos de classificação em relação a um defeito de interesse em específico. Para o treinamento desses modelos, foi utilizado 100% das instâncias simuladas da classe principal (a classe de interesse). As classes restantes eram sorteadas com 50% de suas instâncias e, em seguida, fundidas para formar a nova classe "Todos". Isso garantiu que o número de instâncias na classe Todos fosse igual ao da classe principal, ou seja, balanceando as classes. O principal objetivo proposto para este tipo de classificação no trabalho, é observar qual defeito real é mais facilmente separado a partir dos modelos de classificação treinados com dados simulados. A figura 12 resume o fluxo operacional completo do trabalho para os cenários Simulados X Simulados e Simulados X Reais.

Figura 12 – Fluxograma da metodologia proposta para avaliação dos modelos empregados para Simulados X Simulados e Simulados X Reais.



Fonte: Elaborado pelo autor (2026).

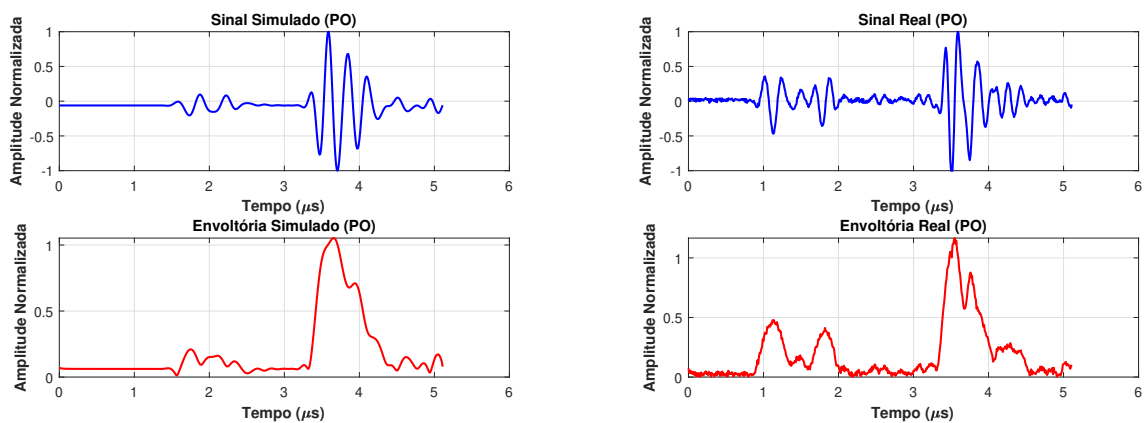
4 RESULTADOS

4.1 Dados simulados e reais

Os sinais simulados correspondem a campos de deslocamento no domínio do tempo, conforme ilustrado na figura 10. Esses deslocamentos apresentam ordem de grandeza da ordem de 10^{-6} m. Em contrapartida, os transdutores ultrassônicos utilizados em inspeções experimentais registram variações de pressão. Além disso, devido ao fato dos equipamentos empregados na inspeção por ultrassom realizarem o registro dos sinais experimentais com resolução de 8 bits, isto é, utilizando apenas valores inteiros entre 0 e 255 para representar as amplitudes dos sinais, tornou-se necessária a normalização das amplitudes tanto dos sinais simulados quanto dos sinais experimentais.

Dessa forma, cada sinal foi normalizado individualmente para o intervalo $[-1, 1]$, utilizando seus respectivos valores máximo e mínimo de amplitude, por meio do método de normalização máximo–mínimo. Para exemplificar o procedimento adotado, a figura 13 apresenta a comparação entre os sinais normalizados e suas respectivas envoltórias para o defeito poro (PO).

Figura 13 – Comparação dos sinais normalizados e suas envoltórias para o defeito poro (PO), obtidos de maneira simulada e real.



(a) Sinal Simulado e Envoltória (PO)

(b) Sinal Real e Envoltória (PO)

Fonte: Elaborado pelo autor (2026).

A Análise de Componentes Principais (PCA) foi aplicada aos 324 sinais simulados normalizados, sendo avaliada a variância explicada acumulada em função do número de componentes principais (k), conforme ilustrado na figura 14. Ao analisar os sinais simulados normalizados com 512 pontos, observa-se que um número reduzido de componentes principais é

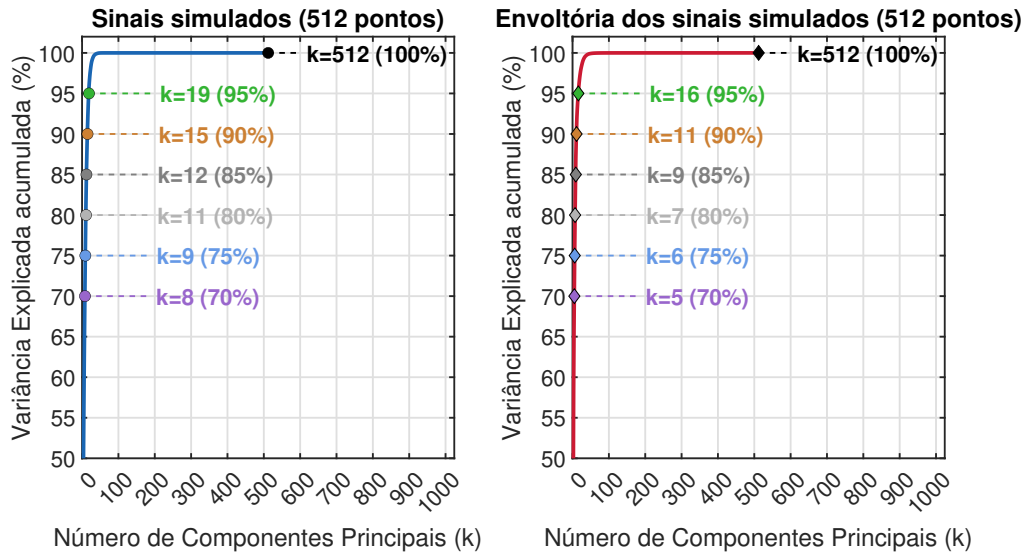
suficiente para reter grande parte da informação contida nos dados. Por exemplo, aproximadamente 95% da variância é preservada com apenas 19 componentes principais. Para a envoltória dos sinais, a retenção do mesmo percentual de variância requer um número ainda menor de componentes, sendo suficientes 16 componentes para alcançar 95% de variância explicada acumulada.

Esse comportamento é consistente com as características dos sinais analisados. Os sinais ultrassônicos normalizados apresentam valores positivos e negativos, os quais carregam informações mais complexas associadas aos fenômenos físicos e às interações das ondas ultrassônicas com o meio inspecionado. Em contraste, as envoltórias representam apenas o contorno da amplitude do sinal ao longo do tempo, resultando em uma representação mais compacta e menos complexa, o que justifica a necessidade de um menor número de componentes principais para descrever a mesma quantidade de informação.

A mesma análise foi realizada para os sinais normalizados e reamostrados e para suas respectivas envoltórias, considerando representações com 512, 256 e 128 pontos. Para os percentuais de variância explicada acumulada de 95%, 90%, 85% e 80%, verificou-se que o número de componentes principais necessário para atingir esses níveis de retenção foi o mesmo para os sinais e suas envoltórias, independentemente da dimensionalidade original dos dados. Assim, por exemplo, o número de componentes requerido para reter 95% da variância nos sinais com 512 pontos foi idêntico ao observado para os sinais reamostrados com 256 e 128 pontos.

Em contrapartida, para a retenção de 100% da variância explicada acumulada, o número de componentes principais passou a depender diretamente da dimensionalidade original dos dados. Nesse caso, a PCA não promove redução de dimensionalidade, assumindo exclusivamente o papel de transformação linear destinada à decorrelação dos pontos do sinal, de modo que são empregados 512, 256 e 128 componentes para os sinais e suas envoltórias com essas respectivas quantidades de pontos.

Figura 14 – Variância explicada acumulada (%) vs Número de Componentes Principais para os Sinais Simulados e suas Envoltórias, com 512 pontos.



Fonte: Elaborado pelo autor (2026).

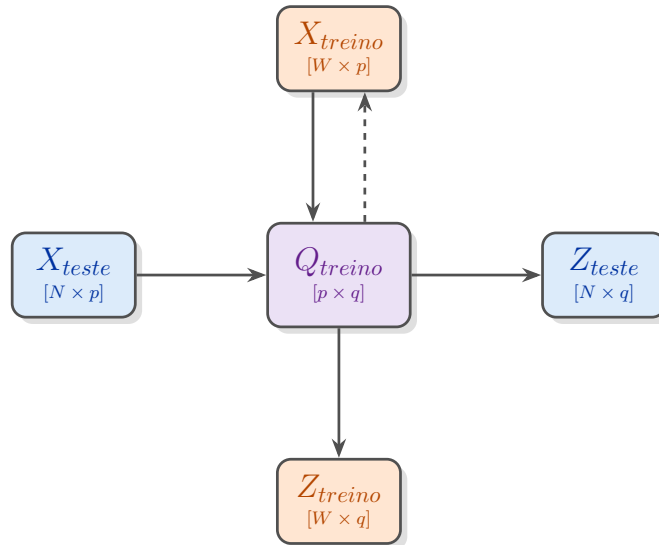
Além da análise apresentada anteriormente, torna-se fundamental esclarecer a forma como a matriz de transformação \mathbf{Q} , obtida por meio da PCA, foi utilizada nos processos de treinamento e teste dos classificadores. Essa matriz é responsável por realizar a transformação linear associada à mudança de base para as direções de máxima variância explicada dos dados.

Dessa forma, foi garantida a independência entre os conjuntos de treinamento e teste, uma vez que a matriz de transformação \mathbf{Q} foi estimada exclusivamente a partir dos dados de treinamento ($\mathbf{X}_{\text{treino}}$). Adicionalmente, o conjunto de teste ($\mathbf{X}_{\text{teste}}$) foi centralizado utilizando a média calculada a partir do próprio conjunto de treinamento (μ_{treino}), assegurando a consistência do processo de transformação.

A figura 15 ilustra esse procedimento por meio de um diagrama de blocos, evidenciando que a matriz $\mathbf{Q}_{\text{treino}}$ é aplicada tanto ao conjunto $\mathbf{X}_{\text{treino}}$, gerando as componentes principais $\mathbf{Z}_{\text{treino}}$, quanto ao conjunto $\mathbf{X}_{\text{teste}}$, resultando em $\mathbf{Z}_{\text{teste}}$. Esse procedimento garante que a transformação aplicada aos dados de teste seja baseada exclusivamente nas características estatísticas extraídas dos dados destinados ao treinamento, evitando vazamento de informação.

O procedimento ilustrado na figura 15 foi adotado tanto na etapa Simulados X Simulados, em que os modelos são treinados e testados com componentes principais extraídas dos dados simulados, quanto na etapa Simulados X Reais, na qual os classificadores são treinados com as componentes principais dos dados simulados e testados com as componentes principais dos dados reais, obtidas por meio da transformação linear utilizando a matriz $\mathbf{Q}_{\text{treino}}$ (ou $\mathbf{Q}_{\text{simulados}}$).

Figura 15 – Diagrama de blocos da transformação linear do conjunto de treino (X_{treino}) e teste (X_{teste}) nas componentes principais de dimensão q (Z_{treino} e Z_{teste}), a partir da matriz de transformação (Q_{treino}).



Fonte: Elaborado pelo autor (2026).

4.2 Simulados X Simulados

As taxas de acerto máximas e médias obtidas pelos diferentes algoritmos classificadores treinados e testados com sinais ultrassônicos simulados ou suas componentes principais, ou ainda, treinados e testados com as envoltórias dos sinais simulados ou as componentes principais das envoltórias, e calculadas sobre 100 conjuntos de testes sorteados aleatoriamente, são apresentadas pelas tabelas 4 a 11 e figuras 16 a 23, e merecem os seguintes comentários.

De um modo geral, observa-se que, quando os algoritmos analisados foram empregados na classificação dos sinais ou suas envoltórias, a redução de 512 para 256 e de 256 para 128 no número de pontos dos sinais não provocou reduções no desempenho máximo e médio, indicando que representações mais compactas dos sinais preservam as informações essenciais para a classificação. Esse resultado é particularmente relevante do ponto de vista computacional, pois demonstra a viabilidade de reduzir a dimensionalidade das entradas sem comprometer a qualidade da classificação.

No entanto, a redução do número de componentes principais (de 19 para 8 componentes principais no caso dos sinais simulados e de 16 para 5 componentes no caso das envoltórias dos sinais simulados) provoca uma leve redução nas taxas de acerto máximas e médias. Duas exceções foram observadas para o classificador quadrático que apresentou os piores desempenhos na classificação de sinais com 512 pontos e classificação das envoltórias

dos sinais com 512 pontos. Essa piora no desempenho pode ser justificada pela alta quantidade de vetores linearmente dependentes das matrizes de covariância por classe geradas a partir dos 512 pontos, tanto do sinal quanto da envoltória, dificultando a invertibilidade da matriz de covariância.

Enquanto a compressão da informação, associada à redução do número de componentes, piorou o desempenho do classificador *K-Nearest Neighbors* (KNN) e dos classificadores baseados em redes neurais, como o *Perceptron* de Camada Única (SLP) e o *Multilayer Perceptron* (MLP), a redução das componentes principais proporcionou uma melhoria significativa, até certo limite, no desempenho do classificador quadrático. Esse comportamento decorre do fato de que as componentes principais são mutuamente ortogonais e não correlacionadas, o que resulta em matrizes de covariância estimadas em um espaço transformado melhor condicionado, com postos matriciais mais adequados, favorecendo o cálculo de suas inversas e, conseqüentemente, a tomada de decisão pelo classificador.

Para todos os classificadores, os melhores desempenhos máximos e médios aparecem, respectivamente, destacados em amarelo e verde. Para esses casos são apresentados também as matrizes de confusão médias e máximas. Nessas matrizes, os elementos da diagonal principal representam os acertos, ao passo que os elementos fora da diagonal denotam os erros de classificação. As linhas representam o defeito ao qual as instâncias pertencem, enquanto as colunas indicam o defeito ao qual as instâncias foram classificadas pelo modelo.

A análise das matrizes de confusão médias e máximas, apresentadas pelas figuras 16, 17, 18, 19, 20, 21, 22 e 23, permitem verificar a elevada taxa de acerto associada à classe falta de penetração (FP), que atinge valores próximos ou iguais a 100% em praticamente todos os cenários analisados, independentemente do classificador, do tipo de dado de entrada ou do nível de compressão da informação. Em contraste, para todos os classificadores, os maiores erros de classificação estão associados à distinção entre as classes falta de fusão (FF) e poro (PO), cuja confusão aparece de forma sistemática nas matrizes de confusão.


Tabela 4 – Melhor desempenho médio no conjunto de teste do KNN "treinado" e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Vizinhos Próximos (K)	Parâmetro m	Acurácias		
					Média	Mediana	Máxima
Sinal	512	512	1	1/2	88,77%	89,39%	100,00%
	256	256	1	1/2	88,85%	89,39%	98,48%
	128	128	1	1/2	88,74%	89,39%	100,00%
100% de info.	512	512	1	1/2	86,79%	86,36%	98,48%
	256	256	1	1	86,64%	86,36%	96,97%
	128	128	1	1	87,02%	86,36%	98,48%
95% de info.	512	19	1	2	83,70%	83,33%	95,45%
	256	19	1	2	83,65%	84,85%	96,97%
	128	19	1	2	84,32%	84,85%	100,00%
90% de info.	512	15	1	2	83,29%	83,33%	95,45%
	256	15	1	2	82,79%	83,33%	95,45%
	128	15	1	2	83,26%	83,33%	95,45%
85% de info.	512	12	1	1	80,95%	81,82%	95,45%
	256	12	1	2	81,24%	81,82%	96,97%
	128	12	1	1	81,32%	81,06%	95,45%
80% de info.	512	11	1	2	79,15%	78,79%	93,94%
	256	11	1	1	78,77%	78,79%	90,91%
	128	11	1	2	78,82%	78,79%	92,42%


Fonte: Elaborado pelo próprio autor (2026).

Figura 16 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" e testado com Sinais Simulados (512, 256 e 128 Pontos).

512 pontos (Sinal)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (Sinal)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (Sinal)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 5 – Melhor desempenho médio no conjunto de Teste do KNN "treinado" e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Vizinhos Próximos (K)	Parâmetro m	Acurácias		
					Média	Mediana	Máxima
Envoltória	512	512	1	1	86,70%	86,36%	98,48%
	256	256	1	1	86,91%	86,36%	98,48%
	128	128	1	1	87,47%	87,88%	100%
100% de info.	512	512	3	2	85,73%	86,36%	98,48%
	256	256	3	2	85,98%	86,36%	96,97%
	128	128	3	2	85,36%	86,36%	96,97%
95% de info.	512	16	3	2	83,80%	84,85%	96,97%
	256	16	1	2	84,70%	84,85%	95,45%
	128	16	1	1	84,65%	84,85%	96,97%
90% de info.	512	11	3	2	82,92%	83,33%	95,45%
	256	11	1	2	83,39%	83,33%	95,45%
	128	11	1	1	83,08%	83,33%	96,97%
85% de info.	512	9	1	2	80,15%	80,30%	93,94%
	256	9	3	2	80,65%	80,30%	95,45%
	128	9	1	1	82,02%	81,82%	95,45%
80% de info.	512	7	5	2	81,50%	81,82%	93,94%
	256	7	3	2	81,15%	81,82%	95,45%
	128	7	3	1	81,95%	81,82%	96,97%


Fonte: Elaborado pelo autor (2026).

Figura 17 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" e testado com a envoltória dos Sinais Simulados (512, 256 e 128 Pontos).

512 pontos (Envoltória do sinal)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (Envoltória do sinal)

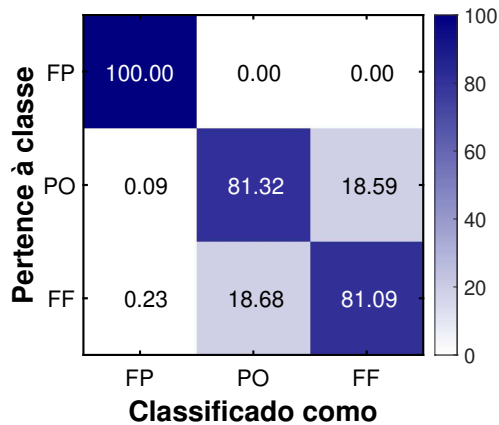


(a) Matriz de confusão média

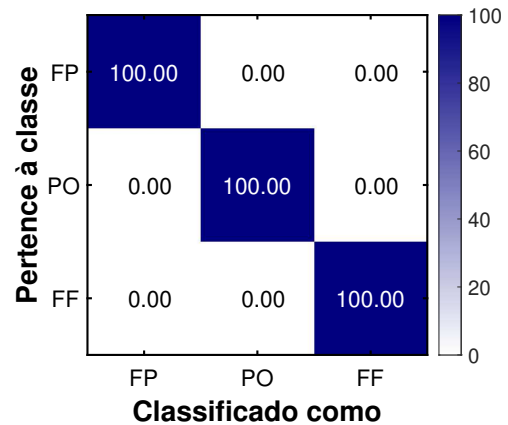


(b) Matriz de confusão máxima

128 pontos (Envoltória do sinal)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 6 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	Variante	Acurácias		
				Média	Mediana	Máxima
Sinal	512	512	2	38,92%	59,09%	81,82%
	256	256	2	40,65%	59,09%	84,85%
	128	128	2	75,03%	75,76%	89,39%
100% de info.	512	512	2	60,68%	66,67%	82,73%
	256	256	2	66,26%	66,67%	86,36%
	128	128	3 ($\lambda = 0.9$)	81,27%	81,82%	93,94%
95% de info.	512	19	3 ($\lambda = 0.1$)	81,48%	81,82%	93,94%
	256	19	3 ($\lambda = 0.1$)	81,73%	81,82%	95,45%
	128	19	3 ($\lambda = 0.1$)	81,56%	81,82%	95,45%
90% de info.	512	15	3 ($\lambda = 0.1$)	80,33%	80,30%	95,45%
	256	15	3 ($\lambda = 0.1$)	81,44%	81,82%	94,45%
	128	15	1	81,35%	81,82%	93,94%
85% de info.	512	12	3 ($\lambda = 0.1$)	79,39%	80,30%	92,42%
	256	12	3 ($\lambda = 0.1$)	79,64%	80,30%	92,42%
	128	12	3 ($\lambda = 0.1$)	79,83%	80,30%	92,42%
80% de info.	512	11	3 ($\lambda = 0.1$)	76,74%	77,27%	89,39%
	256	11	3 ($\lambda = 0.1$)	77,89%	78,79%	92,42%
	128	11	3 ($\lambda = 0.1$)	78,03%	78,03%	92,42%


Fonte: Elaborado pelo autor (2026).

Figura 18 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado e testado com as componentes principais que retém 95% da informação dos sinais simulados (512, 256 e 128 pontos).

512 pontos (95% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (95% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (95% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 7 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	Variante	Acurácias		
				Média	Mediana	Máxima
Envoltória	512	512	2	38,41%	50,00%	84,85%
	256	256	4	75,59%	75,76%	89,39%
	128	128	2	79,41%	80,30%	95,45%
100% de info.	512	512	2	33,82%	31,82%	83,33%
	256	256	2	41,58%	53,79%	83,33%
	128	128	2	79,30%	80,30%	93,94%
95% de info.	512	16	3 ($\lambda = 0.3$)	83,61%	83,33%	96,97%
	256	16	3 ($\lambda = 0.1$)	83,92%	84,09%	96,97%
	128	16	3 ($\lambda = 0.1$)	83,68%	83,33%	96,97%
90% de info.	512	11	1	83,02%	83,33%	93,94%
	256	11	3 ($\lambda = 0.1$)	83,56%	83,33%	95,45%
	128	11	3 ($\lambda = 0.2$)	83,85%	84,85%	96,97%
85% de info.	512	9	3 ($\lambda = 0.2$)	81,76%	81,82%	93,94%
	256	9	3 ($\lambda = 0.2$)	82,76%	81,82%	95,45%
	128	9	3 ($\lambda = 0.2$)	82,95%	83,33%	95,45%
80% de info.	512	7	3 ($\lambda = 0.2$)	81,52%	81,82%	90,91%
	256	7	3 ($\lambda = 0.4$)	81,59%	81,82%	93,94%
	128	7	3 ($\lambda = 0.3$)	80,33%	80,30%	95,45%


Fonte: Elaborado pelo autor (2026).

Figura 19 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado e testado com as componentes principais que retêm 95% (512 e 256 pontos) e 90% (128 pontos) da informação das envoltória dos Sinais Simulados.

512 pontos (95% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (95% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (90% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 8 – Melhor desempenho médio no conjunto de teste do *Perceptron* de camada única treinado e testado com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Neurônios	Taxa de Aprendizado (η)	Momentum (α)	Função da Cam. de Saída	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
Sinal	512	512		0,001	0,90	Tanh	a = 1;b = 1	74,86%	74,60%	87,30%
	256	256	3	0,001	0,90	Tanh	a = 1,7159;b = 2/3	75,21%	74,60%	88,89%
	128	128		0,01	0,90	Tanh	a = 1,7159;b = 2/3	74,60%	74,60%	88,89%
100% de info.	512	512		0,01	0,90	Tanh	a = 1,7159;b = 2/3	76,37%	76,19%	88,89%
	256	256	3	0,01	0,90	Tanh	a = 1,7159;b = 2/3	75,81%	76,19%	90,48%
	128	128		0,01	0,90	Tanh	a = 1,7159;b = 2/3	75,76%	76,19%	88,89%
95% de info.	512	19		0,001	0,90	Tanh	a = 1,7159;b = 2/3	73,40%	73,02%	90,48%
	256	19	3	0,01	0,90	Tanh	a = 1,7159;b = 2/3	73,46%	73,02%	88,89%
	128	19		0,01	0,99	Logística	c = 1	73,44%	73,02%	87,30%
90% de info.	512	15		0,01	0,99	Logística	c = 2,2	71,89%	73,02%	87,30%
	256	15	3	0,01	0,90	Tanh	a = 1;b = 1	72,52%	73,02%	85,71%
	128	15		0,01	0,95	Tanh	a= 1; b = 1	71,89%	71,43%	87,30%
85% de info.	512	12		0,01	0,99	Softmax	-	71,64%	71,43%	85,71%
	256	12	3	0,01	0,90	Tanh	a = 1,7159;b = 2/3	71,94%	71,43%	85,71%
	128	12		0,01	0,95	Tanh	a = 1,7159;b = 2/3	71,65%	71,43%	85,71%
80% de info.	512	11		0,01	0,99	Softmax	-	70,83%	71,43%	85,71%
	256	11	3	0,01	0,99	Softmax	-	71,14%	71,43%	85,71%
	128	11		0,01	0,95	Tanh	a = 1;b = 1	69,59%	69,84%	85,71%


Fonte: Elaborado pelo autor (2026).

Figura 20 – Matrizes de confusão da melhor acurácia média e sua máxima do *Perceptron* de camada única treinado e testado com as componentes principais que retêm 100% da informação dos sinais simulados (512, 256 e 128 Pontos).

512 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (100% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 9 – Melhor desempenho médio no conjunto de teste do *Perceptron* de camada única treinado e testado com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Neurônios	Taxa de aprendizado (η)	Momentum (α)	Função da Cam. de Saída	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
Envoltória	512	512	3	0,01	0,90	Logística	c = 1	81,52%	80,95%	92,06%
	256	256	3	0,01	0,90	Logística	c = 2,2	81,33%	82,54%	95,24%
	128	128	3	0,01	0,95	Logística	c = 2,2	82,14%	82,54%	95,24%
100% de info.	512	512	3	0,001	0,90	Logística	c = 2,2	81,83%	82,54%	95,24%
	256	256	3	0,001	0,90	Tanh	a = 1,7159;b = 2/3	81,89%	81,75%	95,24%
	128	128	3	0,001	0,90	Tanh	a = 1,7159;b = 2/3	82,13%	82,54%	96,83%
95% de info.	512	16	3	0,01	0,90	Logística	c = 1	76,78%	76,98%	92,06%
	256	16	3	0,01	0,90	Softmax	-	76,89%	77,78%	90,48%
	128	16	3	0,01	0,90	Softmax	-	75,40%	76,19%	90,48%
90% de info.	512	11	3	0,01	0,99	Logística	c = 1	74,67%	74,60%	88,89%
	256	11	3	0,001	0,95	Tanh	a = 1,7159;b = 2/3	74,62%	73,81%	88,89%
	128	11	3	0,001	0,95	Tanh	a = 1,7159;b = 2/3	74,56%	74,60%	88,89%
85% de info.	512	9	3	0,01	0,99	Logística	c = 1	72,84%	73,02%	87,30%
	256	9	3	0,01	0,90	Tanh	a = 1,7159;b = 2/3	73,62%	73,02%	87,30%
	128	9	3	0,01	0,90	Tanh	a = 1;b = 1	73,83%	74,60%	87,30%
80% de info.	512	7	3	0,01	0,99	Softmax	-	74,17%	74,60%	88,89%
	256	7	3	0,01	0,99	Softmax	-	74,10%	74,60%	88,89%
	128	7	3	0,01	0,95	Tanh	a = 1,7159;b = 2/3	74,40%	74,60%	88,89%


Fonte: Elaborado pelo autor (2026).

Figura 21 – Matrizes de confusão da melhor acurácia média e sua máxima do *Perceptron* de camada única treinado e testado com a envoltória dos sinais simulados (128 pontos) e as suas componentes principais que retêm 100% da sua informação (512 e 256 pontos).

512 pontos (100% de info.)



(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (Envoltória do sinal)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 10 – Melhor desempenho médio no conjunto de teste da MLP (uma camada oculta) treinada e testada com sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Neurônios	Taxa de aprendizado (η)	Momentum (α)	Função da Cam. Oculta	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
Sinal	512	512	258 - 3	0,001	0,95	Logística	c = 2,2	82,97%	82,54%	95,24%
	256	256	130 - 3	0,001	0,99	Logística	c = 2,2	83,60%	84,13%	95,24%
	128	128	66 - 3	0,001	0,99	Logística	c = 1	83,22%	83,33%	96,83%
100% de info.	512	512	258 - 3	0,001	0,95	Logística	c = 2,2	82,89%	84,13%	95,24%
	256	256	130 - 3	0,001	0,99	Logística	c = 1	83,79%	84,13%	93,65%
	128	128	66 - 3	0,001	0,90	Logística	c = 2,2	83,06%	83,33%	93,65%
95% de info.	512	19	11 - 3	0,001	0,99	Logística	c = 2,2	78,27%	77,78%	90,48%
	256	19	11 - 3	0,001	0,99	Logística	c = 1	80,00%	79,37%	95,24%
	128	19	11 - 3	0,001	0,95	Logística	c = 1	79,81%	80,16%	93,65%
90% de info.	512	15	9 - 3	0,001	0,95	Logística	c= 1	78,51%	78,57%	92,06%
	256	15	9 - 3	0,001	0,95	Logística	c= 1	78,98%	79,37%	92,06%
	128	15	9 - 3	0,01	0,90	Logística	c= 1	79,37%	79,37%	92,06%
85% de info.	512	12	8 - 3	0,001	0,95	Logística	c= 1	78,03%	77,78%	93,65%
	256	12	8 - 3	0,001	0,90	Tanh	a= 1,7159;b = 2/3	78,40%	77,78%	93,65%
	128	12	8 - 3	0,001	0,90	Logística	c= 1	77,79%	77,78%	90,48%
80% de info.	512	11	7 - 3	0,001	0,90	Tanh	a = 1,7159; b = 2/3	75,56%	76,19%	90,48%
	256	11	7 - 3	0,001	0,90	Logística	c = 1	76,75%	76,19%	90,48%
	128	11	7 - 3	0,001	0,90	Tanh	a = 1,7159; b = 2/3	77,51%	76,98%	93,65%


Fonte: Elaborado pelo autor (2026).

Figura 22 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (uma camada oculta) treinado e testado com os sinais simulados (512 e 128 pontos) e as suas componentes principais que retém 100% da sua informação (256 pontos).

512 pontos (Sinal)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (Sinal)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 11 – Melhor desempenho médio no conjunto de teste da MLP (uma camada oculta) treinada e testada com a envoltória dos sinais simulados (512, 256 e 128 pontos) e suas componentes principais.

Entradas	N° de Pontos	N° de Atributos	N° de Neurônios	Taxa de aprendizado (η)	Momentum (α)	Função da Cam. Oculta	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
Envoltória	512	512	258 - 3	0,001	0,90	Logística	c = 2,2	86,05%	86,51%	96,83%
	256	256	130 - 3	0,001	0,90	Logística	c = 2,2	85,90%	85,71%	96,83%
	128	128	66 - 3	0,001	0,99	Logística	c = 2,2	85,94%	85,71%	96,83%
100% de info.	512	512	258 - 3	0,001	0,95	Tanh	a = 1; b = 1	86,08%	85,71%	96,83%
	256	256	130 - 3	0,001	0,99	Logística	c = 1	85,98%	85,71%	96,83%
	128	128	66 - 3	0,01	0,90	Logística	c = 1	85,86%	85,71%	96,83%
95% de info.	512	16	10 - 3	0,001	0,90	Logística	c = 1	81,73%	80,95%	93,65%
	256	16	10 - 3	0,001	0,90	Tanh	a = 1,7159; b = 2/3	82,37%	82,54%	95,24%
	128	16	10 - 3	0,01	0,90	Logística	c = 1	78,51%	79,37%	93,65%
90% de info.	512	11	7 - 3	0,001	0,90	Logística	c = 1	79,78%	79,37%	93,65%
	256	11	7 - 3	0,001	0,95	Logística	c = 1	81,05%	80,85%	95,24%
	128	11	7 - 3	0,001	0,99	Logística	c = 1	81,57%	80,95%	93,65%
85% de info.	512	9	6 - 3	0,001	0,90	Logística	c = 1	80,13%	80,95%	92,06%
	256	9	6 - 3	0,001	0,90	Tanh	a = 1,7159; b = 2/3	80,14%	80,95%	92,06%
	128	9	6 - 3	0,001	0,95	Logística	c = 1	81,90%	82,54%	95,24%
80% de info.	512	7	5 - 3	0,001	0,95	Logística	c = 1	78,22%	77,78%	90,48%
	256	7	5 - 3	0,001	0,95	Logística	c = 1	80,24%	80,95%	95,24%
	128	7	5 - 3	0,001	0,95	Logística	c = 1	80,17%	80,95%	93,65%


Fonte: Elaborado pelo autor (2026).

Figura 23 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (uma Camada Oculta) treinado e testado com a envoltória dos sinais simulados (128 pontos) e as suas componentes principais que retém 100% da informação (512 e 256 pontos).

512 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

256 pontos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

128 pontos (Envoltória do sinal)



(a) Matriz de confusão média




(b) Matriz de confusão máxima

4.3 Avaliação e desempenho dos modelos de classificação: Simulados X Simulados

Esta seção tem como objetivo avaliar o desempenho geral de todos os modelos na etapa Simulados X Simulados. A figura 24 apresenta o gráfico das melhores acurácias médias obtidas pelos classificadores KNN, quadrático (C.Q), SLP e MLP nessa etapa inicial de avaliação.

Figura 24 – Gráfico das melhores acurácias médias dos classificadores para Simulados × Simulados considerando a redução do número de pontos.



Fonte: Elaborado pelo autor (2026).

Ao analisar a figura 24, observa-se que, para um mesmo classificador, não houve redução significativa das acurácias médias com a diminuição do número de pontos dos sinais simulados normalizados ou de suas envoltórias (de 512 para 256 e de 256 para 128 pontos). Diante dessa estabilidade de desempenho e visando maior eficiência computacional, optou-se por utilizar exclusivamente os modelos treinados com sinais contendo 128 pontos na etapa Simulados X Reais.


No que se refere à comparação entre os algoritmos de classificação, os melhores resultados médios globais foram obtidos pelo classificador KNN. Para esse algoritmo, verificou-se elevada similaridade entre os desempenhos alcançados utilizando os sinais normalizados e suas envoltórias, independentemente do número de pontos considerado. Contudo, esse comportamento não se mostrou uniforme para todos os classificadores. Para o classificador quadrático (C.Q),

bem como para o SLP e o MLP com uma camada oculta, os melhores desempenhos foram consistentemente obtidos quando se utilizou a envoltória como entrada, ou ainda as componentes principais extraídas da envoltória, no caso de alguns classificadores. Com base nessa observação, apenas a envoltória dos sinais foi considerada nos testes da etapa Simulados X Reais.

Fixando a análise nas envoltórias dos sinais simulados com 128 pontos, pelos motivos anteriormente discutidos, investigou-se a influência da redução de dimensionalidade por meio da Análise de Componentes Principais (PCA) e seu impacto no desempenho em cada classificador. Conforme ilustrado na figura 25, observam-se comportamentos distintos nas acurácias médias dos algoritmos de classificação em função do percentual de informação utilizado.

Para o KNN, nota-se uma degradação progressiva da acurácia à medida que a variância explicada acumulada é reduzida. Já o SLP e o MLP apresentaram consistentemente seus melhores desempenhos quando utilizadas as componentes principais que retêm 100% da informação da envoltória. Em contraste, o classificador quadrático (C.Q) atingiu seu melhor desempenho com percentuais mais baixos de variância explicada, destacando-se o caso de 90%. Essa ausência de uniformidade no desempenho dos modelos quanto à escolha do percentual de variância explicada motivou a adoção da redução dimensional pela PCA na etapa subsequente de avaliação Simulados X Reais, uma vez que não foi observado consenso entre os classificadores acerca da configuração que maximiza o desempenho.

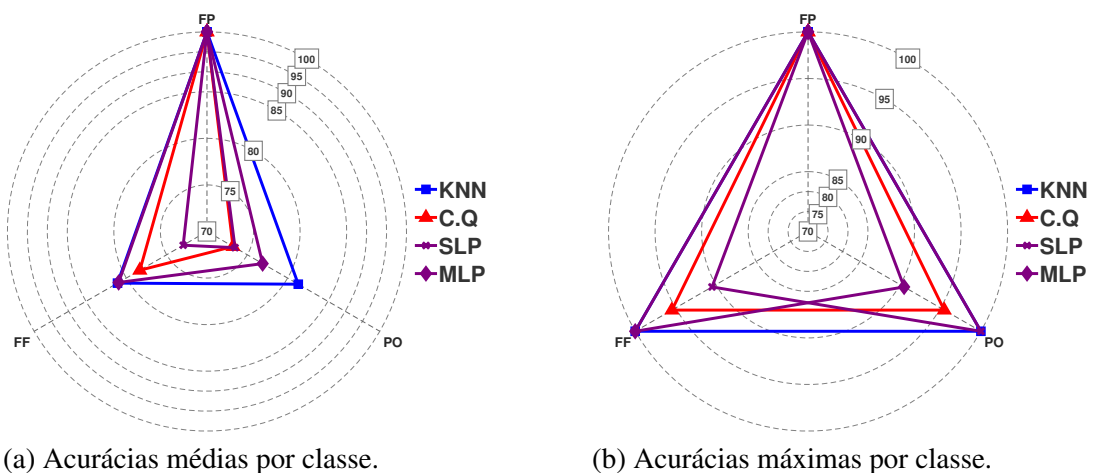
Figura 25 – Melhores acurácias médias dos classificadores em função da redução da dimensionalidade (PCA) da envoltória dos sinais simulados com 128 pontos (Simulados X Simulados).



A análise das acurácias por classe, considerando os melhores desempenhos médios e seus valores máximos para os classificadores alimentados com a envoltória dos sinais simulados com 128 pontos ou suas componentes principais, é apresentada nos gráficos de radar da figura 26. Observa-se que o defeito falta de penetração (FP) foi corretamente classificado por todos os modelos com 100% de acerto, tanto na média quanto na máxima. Para a classe falta de fusão (FF), apenas os classificadores KNN e MLP com uma camada oculta alcançaram acurácia média superior a 80%. No caso do defeito porosidade (PO), somente o KNN obteve acurácia média superior a 80%.

Em relação aos classificadores baseados em redes neurais, verifica-se que o aumento da complexidade do classificador, por meio da adição de uma camada oculta no MLP, favoreceu o desempenho máximo para a classe FF. Entretanto, para a classe PO, o MLP apresentou acurácia máxima inferior à obtida pelo SLP, apesar de apresentar desempenho médio superior a 75% para essa mesma classe. Destaca-se ainda que, considerando as acurácias máximas por classe, nenhum classificador apresentou desempenho inferior a 90%. Diante desses resultados, optou-se por empregar todos os algoritmos de classificação avaliados na etapa Simulados X Simulados na subsequente avaliação Simulados X Reais.

Figura 26 – Acurácias por classe dos melhores desempenhos médios e seus máximos para todos os classificadores alimentados com os dados obtidos pela envoltória dos sinais simulados com 128 pontos.

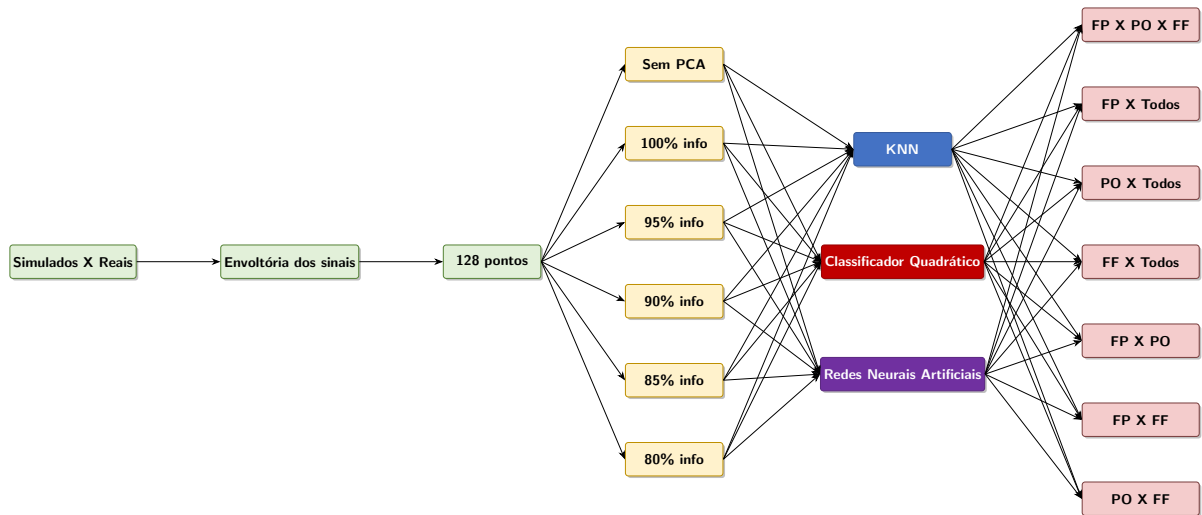


Fonte: Elaborado pelo autor (2026).

A figura 27 apresenta, em forma de fluxograma, um resumo da configuração de pré-processamento selecionada a partir da etapa Simulados X Simulados, a qual foi adotada na etapa Simulados X Reais. Assim, os classificadores foram treinados com as envoltórias dos

sinais simulados contendo 128 pontos, bem como com suas respectivas componentes principais, e testados com as envoltórias dos sinais reais com 128 pontos e suas componentes principais, obtidas a partir da matriz de transformação $Q_{\text{simulados}}$, conforme discutido na Seção 4.1.

Figura 27 – Fluxograma para a etapa Simulados X Reais com a melhor configuração de pré-processamento escolhida em Simulados X Simulados.



Fonte: Elaborado pelo autor (2026).

4.4 Simulados X Real

As tabelas 12 a 16 apresentam os melhores desempenhos médios e máximos obtidos na classificação do conjunto de dados experimentais, após 100 execuções, para os diferentes classificadores avaliados, incluindo o KNN, o classificador quadrático, o *perceptron* de camada única (SLP) e o *Multilayer Perceptron* (MLP) com uma e duas camadas ocultas. Os resultados referem-se ao cenário em que os modelos são treinados com a envoltória dos sinais simulados, ou com suas componentes principais, e testados com a envoltória dos sinais reais, ou com suas respectivas componentes principais, considerando classificações binárias, ternárias e hierárquicas.

De forma consistente, a utilização das componentes principais das envoltórias, em diferentes percentuais de informação, resultaram nos melhores desempenhos médios quando comparada ao uso das próprias envoltórias normalizadas, independentemente do classificador empregado e do tipo de classificação considerada. Esse comportamento contrasta com o observado no cenário em que os modelos são treinados e testados exclusivamente com dados simulados, no qual a redução do número de componentes principais tende, em geral, a provocar uma leve degradação do desempenho para o KNN e os classificadores baseados em redes neurais, em razão da compressão de informação.

Essa diferença de comportamento pode estar diretamente relacionada à variações das ondas de superfície e da parede oposta dos sinais ultrassônicos ao longo do eixo temporal nos conjuntos de treinamento e de teste. No cenário Simulados X Simulados, os sinais de treinamento e de teste são gerados sob as mesmas condições geométricas, não havendo qualquer variação na posição relativa dos transdutores ao longo das simulações. Como consequência, fenômenos como as ondas de superfície e o eco de fundo manifestam-se em posições temporais rigorosamente fixas, em ambos os conjuntos, garantindo um elevado grau de alinhamento temporal entre os sinais utilizados no treinamento e aqueles empregados na avaliação dos modelos.

Em contrapartida, no cenário Simulados X Reais, os sinais experimentais são obtidos a partir de inspeções reais, nas quais pequenas variações na posição dos transdutores e imperfeições geométricas do corpo de prova introduzem deslocamentos na posição temporal desses mesmos fenômenos. Dessa forma, os eventos característicos deixam de ocorrer em instantes rigidamente alinhados com aqueles observados no conjunto de treinamento, o que pode comprometer a correspondência entre os padrões temporais presentes nos dados simulados e reais.

A utilização das envoltórias normalizadas dos sinais simulados no treinamento dos

classificadores também preserva a dependência da posição temporal dos fenômenos ao longo do eixo do tempo, podendo tornar os classificadores excessivamente sensíveis ao alinhamento temporal exato dos eventos característicos dos sinais. Por outro lado, ao serem projetados no subespaço definido pelas componentes principais extraídas das envoltórias dos sinais simulados, por meio da matriz de transformação $\mathbf{Q}_{\text{simulados}}$, as envoltórias dos sinais reais passam a ser representados em um espaço no qual a influência da posição temporal exata dos fenômenos possivelmente foi atenuada. Consequentemente, os classificadores tornam-se mais sensíveis às características globais e estruturais dos sinais, o que pode explicar os ganhos consistentes de desempenho observados no cenário Simulados X Reais ao se utilizar as componentes principais.

Nas tabelas 12 a 16, as melhores acurácias médias e máximas obtidas para cada classificador e para cada tipo de classificação considerada foram destacadas, sendo a melhor acurácia média indicada em verde e a sua acurácia máxima indicada em amarelo, tanto para as classificações ternárias quanto para as classificações hierárquicas e binárias. A partir dessas configurações, foram geradas as matrizes de confusão correspondentes, apresentadas nas figuras 28 a 37, que ilustram de maneira detalhada o comportamento dos classificadores em termos de acertos e erros por classe.

Especificamente, as figuras 28 e 29 apresentam as matrizes de confusão associadas ao KNN, as figuras 30 e 31 correspondem ao classificador quadrático, as figuras 32 e 33 referem-se ao *perceptron* de camada única, as figuras 34 e 35 ilustram os resultados da MLP com uma camada oculta, e as figuras 36 e 37 apresentam as matrizes de confusão da MLP com duas camadas ocultas, contemplando, em todos os casos, as acurácias médias e máximas para os diferentes tipos de classificação analisados.

Para as classificações ternárias, observa-se que o número de componentes principais associado aos melhores desempenhos varia conforme o classificador considerado. O classificador quadrático (C.Q.) e o *perceptron* de camada única (SLP) apresentaram seus melhores resultados médios e máximos quando empregadas 11 componentes principais, as quais retêm aproximadamente 90% da informação contida nas envoltórias dos sinais simulados. Em contraste, os classificadores KNN, MLP com uma camada oculta e MLP com duas camadas ocultas alcançaram seus melhores desempenhos utilizando apenas 7 componentes principais, correspondentes a cerca de 80% da informação, o que sugere que, para esses modelos, uma representação mais compacta é suficiente para preservar as informações relevantes para a separação dos três defeitos, favorecendo simultaneamente a eficiência do modelo e a capacidade de generalização.

De modo geral, para as classificações ternárias (FP X PO X TR), independentemente do classificador empregado, o defeito que consistentemente apresentou as maiores taxas de acerto médias foi a falta de penetração (FP). Esse resultado pode ser justificado pois os defeitos poro (PO) e falta de fusão (FF) são gerados em posições aleatórias ao longo de uma junta soldada, ao passo que a falta de penetração ocorre sistematicamente em uma região fixa e bem definida, correspondente à zona inferior central do cordão de solda. Como consequência, os padrões associados a esse defeito apresentam menor variabilidade no seu posicionamento, o que favorece a sua identificação e contribui diretamente para o melhor desempenho dos classificadores na sua detecção. Esse comportamento também se reflete nos resultados das classificações hierárquicas, nas quais, com algumas exceções para o classificador quadrático, todos os classificadores indicaram a falta de penetração como o defeito mais fácil de ser isolado em relação aos demais.

No contexto das classificações binárias, o confronto entre a falta de penetração e a falta de fusão (FP X FF) apresentou as maiores taxas de acerto, tanto médias quanto máximas. Para todos os classificadores avaliados, os resultados obtidos nesse cenário foram consistentemente elevados, evidenciando a elevada capacidade dos modelos em discriminar esses dois tipos de defeitos.

Em contrapartida, quando o defeito poro (PO) passou a integrar o conjunto de classes a ser discriminado, observou-se uma queda acentuada no desempenho dos classificadores, tanto em termos de acurácia média quanto nas taxas de acerto por classe, independentemente do modelo empregado. Nas classificações ternárias, a classificação desse defeito mostrou-se particularmente desafiadora, apresentando uma confusão mútua recorrente com os demais defeitos, especialmente com a falta de penetração, o que resultou em frequentes erros de classificação, contribuindo para a degradação do desempenho global dos modelos.

A seguir, apresenta-se a discussão detalhada dos melhores resultados médios obtidos para cada uma das classificações binárias, ternárias e hierárquicas. Nesse contexto, inicia-se a análise pelo cenário ternário (FP X PO X FF), na qual os três tipos de defeitos são discriminados simultaneamente. Para essa classificação, o melhor desempenho médio foi alcançado pelo classificador MLP com duas camadas ocultas (tabela 16). Esse resultado foi alcançado com a utilização de 7 componentes principais, correspondentes à retenção de aproximadamente 80% da informação contida nas envoltórias dos sinais simulados. Nessa configuração, foi utilizada a função de ativação sigmoide logística em ambas as camadas ocultas, com parâmetro c igual a 1 em cada uma delas, ao qual foi atingido acurácia média e máxima de 63,13% e 80,57%,

respectivamente.

A análise das matrizes de confusão associadas a esse modelo (figura 36) evidencia que, no desempenho médio, a falta de penetração (FP) apresentou resultados particularmente elevados, atingindo uma taxa de acerto de 86,37%, o que confirma a elevada capacidade do classificador em identificar esse defeito de forma consistente. Ainda na matriz de confusão média, a falta de fusão (FF) apresentou uma taxa de acerto de 60,05%, ao passo que a porosidade (PO) foi a classe com menor desempenho, registrando um acerto médio de 42,97%.

Na melhor rodada, observa-se um ganho expressivo no desempenho global do classificador, refletido diretamente no aumento das taxas de acerto das classificações dos defeitos reais. Nessa condição, a falta de fusão (FF) apresentou desempenho excelente, com taxa de acerto de 93,33%, o que corresponde à correta classificação de 56 dos 60 desse defeito real. De maneira semelhante, a falta de penetração (FP) manteve desempenho igualmente elevado, alcançando 91,67% de acerto, identificando corretamente 55 defeitos. Em contraste, embora a porosidade (PO) apresente melhora em relação ao desempenho médio, com taxa de acerto de 56,70%, isso corresponde à correta classificação de 34 dos 60 defeitos, permanecendo, portanto, como a classe mais desafiadora para o modelo.

Diferentemente do observado na classificação ternária, nas classificações binárias e hierárquicas os melhores desempenhos médios e máximos foram predominantemente alcançados pelos classificadores KNN e quadrático. Para a hierarquia falta de penetração X todos, o melhor desempenho foi obtido pelo classificador KNN, com $K = 1$ e distância euclidiana (parâmetro da distância de Minkowski $m = 2$), empregando 7 componentes principais, correspondentes à retenção de aproximadamente 80% da informação das envoltórias simuladas. Nessa configuração, o modelo atingiu uma acurácia média de 80,35% e uma acurácia máxima de 87,50%, refletindo a elevada capacidade do classificador em isolar a falta de penetração em relação aos demais defeitos.

Na hierarquia porosidade X todos, novamente o KNN apresentou o melhor desempenho médio, utilizando $K = 1$ e parâmetro $m = 1$, porém com o uso de 128 componentes principais, preservando 100% da informação das envoltórias. A acurácia média foi de 55,57% e a máxima de 71,67%, o que reforça a maior complexidade associada à identificação da porosidade, mesmo em um cenário hierárquico. Por sua vez, na hierarquia falta de fusão X todos, o melhor desempenho foi alcançado pelo classificador quadrático, com variante Friedman e $\lambda = 0,1$, utilizando 7 componentes principais (80% da informação). Essa configuração resultou em uma

acurácia média elevada de 86,68% e uma acurácia máxima de 95,00%.

Nos confrontos binários, quando a falta de penetração foi confrontada com a falta de fusão, o KNN com $K = 1$ e distância euclidiana ($m = 2$), utilizando 9 componentes principais, atingiu acurácia média de 97,33% e máxima de 99,17%. No confronto entre a porosidade e a falta de fusão, o classificador quadrático, com a variante Naive Bayes e 7 componentes principais, obteve acurácia média de 55,44% e máxima de 88,33%. Já quando a falta de penetração foi confrontada com a porosidade, o classificador quadrático, com a variante da matriz de covariância agregada (C_{pool}), utilizando 11 componentes principais, alcançou acurácia média de 68,76% e máxima de 75,84%.


Tabela 12 – Melhor desempenho médio no conjunto de teste do KNN "treinado" com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.

Classificação	Entradas	N° de Atributos	N° de Vizinhos Próximos	Parâmetro m	Acurácias		
					Média	Mediana	Máxima
FP X PO X FF	Envoltória	128	1	2	42,81%	43,89%	53,33%
	100% de info.	128	1	1/2	45,69%	46,11%	57,78%
	95% de info.	16	1	1/2	50,96%	51,11%	62,78%
	90% de info.	11	5	1	50,53%	50,00%	62,78%
	85% de info.	9	1	2	53,47%	53,89%	62,22%
	80% de info.	7	1	2	55,26%	55,00%	66,67%
FP X Todos	Envoltória	128	3	1	75,50%	75,00%	83,33%
	100% de info.	128	5	1/2	73,47%	74,17%	81,67%
	95% de info.	16	3	1/2	73,82%	74,17%	82,50%
	90% de info.	11	1	2	77,62%	78,33%	85,83%
	85% de info.	9	1	2	80,18%	80,00%	86,67%
	80% de info.	7	1	2	80,35%	80,42%	87,50%
PO X Todos	Envoltória	128	3	1/2	46,29%	45,83%	60,00%
	100% de info.	128	1	1	55,57%	55,00%	71,67%
	95% de info.	16	1	1	49,45%	50,00%	63,33%
	90% de info.	11	1	2	51,46%	51,67%	65,00%
	85% de info.	9	1	2	49,85%	50,00%	65,00%
	80% de info.	7	1	2	48,85%	48,33%	65,83%
FF X Todos	Envoltória	128	3	2	69,74%	69,17%	86,67%
	100% de info.	128	5	1	72,77%	72,50%	86,67%
	95% de info.	16	5	1/2	77,71%	77,50%	90,83%
	90% de info.	11	5	1	79,23%	80,00%	93,33%
	85% de info.	9	5	2	78,91%	78,33%	92,50%
	80% de info.	7	5	1	76,60%	76,25%	90,83%
FP X FF	Envoltória	128	1	1	88,41%	89,17%	93,33%
	100% de info.	128	3	1	85,99%	86,25%	95,00%
	95% de info.	16	1	2	91,67%	91,67%	97,50%
	90% de info.	11	3	2	93,32%	94,17%	98,33%
	85% de info.	9	1	2	97,33%	97,50%	99,17%
	80% de info.	7	1	2	96,64%	96,67%	99,17%
PO X FF	Envoltória	128	1	2	46,33%	47,50%	63,33%
	100% de info.	128	5	2	50,10%	50,00%	71,67%
	95% de info.	16	1	2	49,77%	48,33%	70,83%
	90% de info.	11	1	2	54,00%	54,17%	72,50%
	85% de info.	9	1	2	53,49%	54,58%	76,67%
	80% de info.	7	1	2	54,65%	55,83%	85,83%
FP X PO	Envoltória	128	3	1	62,29%	62,50%	68,33%
	100% de info.	128	5	1/2	58,45%	58,33%	70,83%
	95% de info.	16	5	1/2	59,19%	59,17%	69,17%
	90% de info.	11	1	2	63,33%	63,33%	73,34%
	85% de info.	9	1	2	63,24%	63,33%	71,64%
	80% de info.	7	1	2	64,41%	65,00%	73,34%


Fonte: Elaborado pelo autor (2026).

Figura 28 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" com as componentes principais das envoltória dos sinais simulados e testado as componentes principais das envoltória de sinais reais com classificações ternárias e hierárquicas.

Ternária (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FF X Todos (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X Todos (100% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

Figura 29 – Matrizes de confusão da melhor acurácia média e sua máxima do KNN "treinado" com as componentes principais das envoltória dos sinais simulados e testado as componentes principais das envoltória de sinais reais com classificações binárias.

FP X FF (85% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X PO (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão Máxima

PO X FF (80% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 13 – Melhor desempenho médio no conjunto de teste do classificador quadrático treinado com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.

Classificação	Entradas	N° de Atributos	Variante	Acurácias		
				Média	Mediana	Máxima
FP X PO X FF	Envoltória	128	4	42,90%	43,33%	55,22%
	100% de info.	128	2	34,37%	34,44%	46,67%
	95% de info.	16	1	38,70%	37,22%	66,11%
	90% de info.	11	3 ($\lambda = 0,8$)	55,87%	56,94%	73,33%
	85% de info.	9	3 ($\lambda = 0,9$)	48,99%	48,89%	64,44%
	80% de info.	7	3 ($\lambda = 0,9$)	45,87%	45,56%	60,00%
FP X Todos	Envoltória	128	4	60,02%	60,00%	70,83%
	100% de info.	128	4	61,10%	60,00%	69,17%
	95% de info.	16	2	72,97%	74,17%	83,33%
	90% de info.	11	2	77,82%	77,50%	87,50%
	85% de info.	9	3 ($\lambda = 0,6$)	78,49%	78,33%	87,50%
	80% de info.	7	3 ($\lambda = 0,6$)	78,85%	78,33%	89,17%
PO X Todos	Envoltória	128	2	52,02%	51,67%	70,00%
	100% de info.	128	2	52,37%	52,50%	68,13%
	95% de info.	16	2	51,50%	50,83%	70,83%
	90% de info.	11	2	52,57%	52,50%	70,00%
	85% de info.	9	2	51,82%	51,67%	69,17%
	80% de info.	7	2	51,82%	51,25%	67,50%
FF X Todos	Envoltória	128	4	61,72%	62,50%	89,17%
	100% de info.	128	4	62,13%	62,50%	86,67%
	95% de info.	16	4	62,22%	63,33%	93,33%
	90% de info.	11	3 ($\lambda = 0,3$)	72,33%	72,50%	89,17%
	85% de info.	9	3 ($\lambda = 0,1$)	81,35%	81,67%	92,50%
	80% de info.	7	3 ($\lambda = 0,1$)	86,68%	86,67%	95,00%
FP X FF	Envoltória	128	4	68,92%	68,33%	78,33%
	100% de info.	128	3 ($\lambda = 0,6$)	50,50%	50,00%	67,50%
	95% de info.	16	2	84,23%	82,50%	95,83%
	90% de info.	11	2	91,56%	91,67%	98,33%
	85% de info.	9	3 ($\lambda = 0,9$)	95,81%	96,67%	99,17%
	80% de info.	7	3 ($\lambda = 0,8$)	93,56%	93,33%	98,33%
PO X FF	Envoltória	128	2	52,17%	51,67%	77,50%
	100% de info.	128	2	50,18%	57,50%	75,83%
	95% de info.	16	3 ($\lambda = 0,6$)	42,22%	40,00%	79,17%
	90% de info.	11	3 ($\lambda = 0,4$)	54,47%	50,83%	81,67%
	85% de info.	9	3 ($\lambda = 0,5$)	54,35%	54,17%	85,00%
	80% de info.	7	4	55,44%	55,83%	88,33%
FP X PO	Envoltória	128	2	52,27%	52,50%	66,67%
	100% de info.	128	2	52,08%	51,67%	65,83%
	95% de info.	16	2	64,11%	64,17%	75,84%
	90% de info.	11	2	68,76%	69,17%	75,84%
	85% de info.	9	2	65,72%	65,83%	73,33%
	80% de info.	7	2	66,31%	66,67%	70,83%


Fonte: Elaborado pelo autor (2026).

Figura 30 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais com classificações ternárias e hierárquicas.

Ternária (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FF X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X Todos (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

Figura 31 – Matrizes de confusão da melhor acurácia média e sua máxima do classificador quadrático treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais com classificações binárias.

FP X FF (85% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X PO (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X FF (80% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 14 – Melhor desempenho médio no conjunto de teste do *perceptron* de camada única treinado com a envoltória dos sinais simulados e testado com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.

Classificação	Entradas	N° de Atributos	N° de Neurônios	η	α	Função da Cam. de Saída	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
FP X PO X FF	Envoltória	128	3	0,001	0,95	Softmax	-	43,94%	40,00%	60,00%
	100% de info.	128		0,001	0,90	Softmax	-	41,80%	40,00%	60,00%
	95% de info.	16		0,01	0,95	Softmax	-	44,30%	43,61%	57,78%
	90% de info.	11		0,01	0,99	Softmax	-	49,09%	48,61%	62,78%
	85% de info.	9		0,01	0,99	Softmax	-	49,03%	48,61%	62,22%
	80% de info.	7		0,01	0,99	Softmax	-	48,76%	48,33%	61,11%
FP X Todos	Envoltória	128	2	0,01	0,99	Logística	c = 2,2	72,21%	72,50%	81,67%
	100% de info.	128		0,01	0,99	Softmax	-	72,62%	73,33%	81,67%
	95% de info.	16		0,01	0,95	Softmax	-	72,97%	72,50%	80,00%
	90% de info.	11		0,001	0,90	Logística	c = 1	75,20%	75,00%	82,50%
	85% de info.	9		0,001	0,95	Tanh	a = 1;b = 1	74,22%	74,17%	82,50%
	80% de info.	7		0,001	0,90	Tanh	a = 1,7159;b = 2/3	72,93%	73,33%	78,33%
PO X Todos	Envoltória	128	2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	48,66%	50,00%	65,83%
	100% de info.	128		0,001	0,90	Softmax	-	44,30%	44,17%	59,17%
	95% de info.	16		0,01	0,99	Tanh	a = 1,7159;b = 2/3	44,50%	45,42%	60,83%
	90% de info.	11		0,01	0,95	Tanh	a = 1,7159;b = 2/3	49,04%	47,50%	71,67%
	85% de info.	9		0,01	0,99	Logística	c = 2,2	48,11%	46,67%	67,50%
	80% de info.	7		0,01	0,95	Softmax	-	46,28%	46,67%	54,17%
FF X Todos	Envoltória	128	2	0,01	0,95	Tanh	a = 1;b = 1	66,48%	68,75%	85,00%
	100% de info.	128		0,001	0,90	Softmax	-	58,22%	56,67%	86,67%
	95% de info.	16		0,01	0,99	Tanh	a = 1;b = 1	62,87%	63,33%	84,17%
	90% de info.	11		0,01	0,95	Tanh	a = 1,7159;b = 2/3	66,99%	68,33%	85,83%
	85% de info.	9		0,01	0,90	Tanh	a = 1,7159;b = 2/3	71,53%	72,50%	90,00%
	80% de info.	7		0,01	0,90	Tanh	a = 1,7159;b = 2/3	74,22%	75,83%	90,00%
FP X FF	Envoltória	128	2	0,01	0,99	Logística	c = 2,2	85,52%	85,83%	91,67%
	100% de info.	128		0,01	0,90	Softmax	-	85,54%	85,83%	91,67%
	95% de info.	16		0,01	0,95	Softmax	-	86,07%	85,83%	90,00%
	90% de info.	11		0,001	0,90	Logística	c = 1	88,25%	88,33%	90,00%
	85% de info.	9		0,001	0,95	Logística	c = 2,2	86,60%	86,67%	87,50%
	80% de info.	7		0,001	0,95	Softmax	-	84,41%	85,00%	87,50%
PO X FF	Envoltória	128	2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	48,52%	50,00%	77,50%
	100% de info.	128		0,001	0,90	Logística	c = 1	29,17%	23,33%	68,33%
	95% de info.	16		0,01	0,99	Tanh	a = 1,7159;b = 2/3	33,49%	31,67%	75,00%
	90% de info.	11		0,01	0,99	Tanh	a = 1,7159;b = 2/3	38,03%	37,03%	75,83%
	85% de info.	9		0,01	0,99	Softmax	-	46,09%	47,50%	80,00%
	80% de info.	7		0,01	0,99	Softmax	-	48,66%	49,17%	77,50%
FP X PO	Envoltória	128	2	0,001	0,99	Tanh	a = 1,7159;b = 2/3	61,22%	60,83%	68,33%
	100% de info.	128		0,01	0,99	Softmax	-	60,47%	60,83%	68,33%
	95% de info.	16		0,01	0,99	Softmax	-	61,62%	62,08%	69,17%
	90% de info.	11		0,01	0,95	Softmax	-	62,68%	62,50%	63,33%
	85% de info.	9		0,001	0,99	Tanh	a = 1,7159;b = 2/3	60,81%	60,83%	65,00%
	80% de info.	7		0,01	0,90	Tanh	a = 1,7159;b = 2/3	62,12%	62,50%	65,00%


Fonte: Elaborado pelo autor (2026).

Figura 32 – Matrizes de confusão da melhor acurácia média e sua máxima do *perceptron* de camada única treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.

Ternária (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FF X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X Todos (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X Todos (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

Figura 33 – Matrizes de confusão da melhor acurácia média e sua máxima do *perceptron* de camada única treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.

FP X FF (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X PO (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X FF (80% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 15 – Melhores desempenho no conjunto de teste do MLP (Uma camada oculta) treinada com a envoltória dos sinais simulados e testada com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para classificações binárias, ternárias e hierárquicas.

Classificação	Entradas	Nº de Atributos	Nº de Neurônios	η	α	Função da Cam. Oculta	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
FP X PO X FF	Envoltória	128	66 - 3	0,001	0,99	Tanh	a = 1,7159;b = 2/3	47,66%	46,39%	61,67%
	100% de info.	128	66 - 3	0,01	0,99	Logística	c = 2,2	44,92%	45,28%	65,56%
	95% de info.	16	10 - 3	0,001	0,99	Logística	c = 1	44,57%	45,28%	61,11%
	90% de info.	11	7 - 3	0,001	0,90	Logística	c = 1	52,86%	52,78%	72,22%
	85% de info.	9	6 - 3	0,001	0,90	Logística	c = 1	53,94%	53,89%	72,78%
	80% de info.	7	5 - 3	0,001	0,90	Logística	c = 1	58,13%	57,22%	73,89%
FP X Todos	Envoltória	128	65 - 2	0,01	0,90	Tanh	a = 1,7159;b = 2/3	76,23%	76,25%	84,17%
	100% de info.	128	65 - 2	0,01	0,99	Logística	c = 1	76,22%	76,67%	85,00%
	95% de info.	16	9 - 2	0,01	0,99	Logística	c = 1	78,24%	78,33%	86,67%
	90% de info.	11	7 - 2	0,001	0,90	Logística	c = 1	77,76%	77,50%	88,33%
	85% de info.	9	6 - 2	0,01	0,95	Logística	c = 1	78,26%	78,33%	86,67%
	80% de info.	7	5 - 2	0,01	0,95	Logística	c = 1	79,51%	79,17%	87,50%
PO X Todos	Envoltória	128	65 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	49,26%	50,00%	52,50%
	100% de info.	128	65 - 2	0,01	0,99	Tanh	a = 1;b = 1	46,50%	46,25%	75,83%
	95% de info.	16	9 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	47,35%	47,50%	75,83%
	90% de info.	11	7 - 2	0,001	0,95	Logística	c = 1	51,08%	50,83%	78,33%
	85% de info.	9	6 - 2	0,001	0,90	Tanh	a = 1,7159;b = 2/3	50,59%	50,00%	79,17%
	80% de info.	7	5 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	51,21%	50,83%	83,33%
FF X Todos	Envoltória	128	65 - 2	0,01	0,95	Tanh	a = 1,7159;b = 2/3	68,21%	72,50%	91,67%
	100% de info.	128	65 - 2	0,01	0,95	Tanh	a = 1,7159;b = 2/3	56,39%	55,83%	84,17%
	95% de info.	16	9 - 2	0,01	0,90	Tanh	a = 1,7159;b = 2/3	63,02%	63,75%	87,50%
	90% de info.	11	7 - 2	0,01	0,90	Tanh	a = 1,7159;b = 2/3	64,93%	70,00%	92,50%
	85% de info.	9	6 - 2	0,01	0,95	Tanh	a = 1,7159;b = 2/3	68,07%	73,33%	90,00%
	80% de info.	7	5 - 2	0,01	0,90	Tanh	a = 1,7159;b = 2/3	69,72%	76,25%	91,67%
FP X FF	Envoltória	128	65 - 2	0,01	0,95	Logística	c = 2,2	91,40%	91,67%	96,67%
	100% de info.	128	65 - 2	0,001	0,90	Logística	c = 2,2	91,37%	91,67%	97,50%
	95% de info.	16	9 - 2	0,001	0,90	Logística	c = 2,2	91,83%	91,67%	96,67%
	90% de info.	11	7 - 2	0,001	0,90	Logística	c = 1	91,51%	91,67%	96,67%
	85% de info.	9	6 - 2	0,01	0,95	Logística	c = 1	90,96%	90,83%	96,67%
	80% de info.	7	5 - 2	0,01	0,95	Logística	c = 1	92,07%	92,50%	97,50%
PO X FF	Envoltória	128	65 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	49,88%	50,00%	69,17%
	100% de info.	128	65 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	40,53%	40,83%	74,17%
	95% de info.	16	9 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	48,91%	49,17%	80,00%
	90% de info.	11	7 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	47,86%	47,92%	80,00%
	85% de info.	9	6 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	49,97%	49,58%	86,67%
	80% de info.	7	5 - 2	0,01	0,99	Tanh	a = 1,7159;b = 2/3	49,91%	48,33%	81,67%
FP X PO	Envoltória	128	65 - 2	0,001	0,99	Logística	c = 2,2	59,92%	60,83%	77,50%
	100% de info.	128	65 - 2	0,001	0,99	Logística	c = 2,2	60,54%	61,67%	77,50%
	95% de info.	16	9 - 2	0,01	0,99	Logística	c = 1	64,45%	64,17%	79,17%
	90% de info.	11	7 - 2	0,001	0,99	Logística	c = 1	67,98%	68,33%	81,67%
	85% de info.	9	6 - 2	0,01	0,95	Logística	c = 2,2	65,44%	65,83%	80,00%
	80% de info.	7	5 - 2	0,01	0,95	Logística	c = 1	67,23%	67,50%	79,17%


Fonte: Elaborado pelo autor (2026).

Figura 34 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (Uma camada oculta) treinada com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltória dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.

Ternária (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FF X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X Todos (80% de info.)



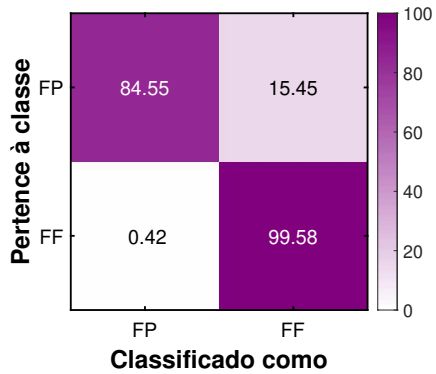
(a) Matriz de confusão média




(b) Matriz de confusão máxima

Figura 35 – Matrizes de confusão da melhor acurácia média e sua máxima da MLP (1 camada oculta) treinada com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.

FP X FF (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X PO (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X FF (85% de info.)



(a) Matriz de confusão média



(b) Matriz de confusão máxima


Tabela 16 – Melhores desempenhos no conjunto de teste do MLP (Duas camadas ocultas) treinada com a envoltória dos sinais simulados e testada com a envoltória dos sinais reais (128 pontos) e suas componentes principais, para as classificações binárias, ternárias e hierárquicas.

Classificação	Entradas	Nº de Atributos	Nº de Neurônios	η	α	Funções das Cam. Ocultas	Parâmetros a, b, c	Acurácias		
								Média	Mediana	Máxima
FP X PO X FF	Envoltória	128	66 - 35 - 3	0,01	0,95	Tanh - Logística	a = 1,7159;b = 2/3 / c = 1	43,34%	41,67%	62,22%
	100% de info.	128	66 - 35 - 3	0,01	0,99	Logística - Logística	c = 1 / c = 2,2	44,78%	43,33%	61,67%
	95% de info.	16	10 - 7 - 3	0,001	0,95	Logística - Logística	c = 1 / c = 2,2	48,35%	48,33%	70,00%
	90% de info.	11	7 - 5 - 3	0,001	0,95	Logística - Logística	c = 1 / c = 2,2	49,49%	51,39%	73,89%
	85% de info.	9	6 - 5 - 3	0,001	0,90	Logística - Logística	c = 1 / c = 2,2	52,72%	52,22%	75,56%
	80% de info.	7	5 - 4 - 3	0,001	0,90	Logística - Logística	c = 1 / c = 1	63,13%	63,11%	80,57%
FP X Todos	Envoltória	128	65 - 34 - 2	0,001	0,90	Logística - Logística	c = 1 / c = 1	76,67%	76,67%	85,00%
	100% de info.	128	65 - 34 - 2	0,01	0,95	Logística - Logística	c = 1 / c = 2,2	76,22%	76,67%	85,00%
	95% de info.	16	9 - 6 - 2	0,001	0,99	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1;b = 1	78,52%	78,33%	89,17%
	90% de info.	11	7 - 5 - 2	0,001	0,90	Logística - Tanh	c = 1/a = 1,7159;b = 2/3	78,07%	78,33%	89,17%
	85% de info.	9	6 - 5 - 2	0,01	0,90	Tanh - Logística	a = 1,7159;b = 2/3 / c = 1	78,58%	78,33%	89,17%
	80% de info.	7	5 - 4 - 2	0,01	0,90	Logística - Logística	c = 1 / c = 1	79,39%	80,00%	89,17%
PO X Todos	Envoltória	128	65 - 34 - 2	0,01	0,99	Logística - Logística	c = 1 / c = 2,	50,03%	50,00%	67,00%
	100% de info.	128	65 - 34 - 2	0,01	0,9	Logística - Logística	c = 2,2 / c = 2,2	46,27%	50,00%	68,33%
	95% de info.	16	9 - 6 - 2	0,01	0,99	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1,7159;b = 2/3	49,97%	50,00%	77,50%
	90% de info.	11	7 - 5 - 2	0,001	0,90	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1,7159;b = 2/3	51,94%	51,67%	84,17%
	85% de info.	9	6 - 5 - 2	0,001	0,90	Tanh - Tanh	a = 1;b = 1 / a = 1,7159;b = 2/3	51,58%	51,25%	80,00%
	80% de info.	7	5 - 4 - 2	0,001	0,90	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1;b = 1	51,26%	51,67%	80,00%
FF X Todos	Envoltória	128	65 - 34 - 2	0,01	0,99	Logística - Logística	c = 1 / c = 2,2	60,95%	59,17%	86,67%
	100% de info.	128	65 - 34 - 2	0,01	0,99	Tanh - Logística	a = 1;b = 1 / c = 1	68,88%	73,75%	89,17%
	95% de info.	16	9 - 6 - 2	0,01	0,99	Logística - Logística	c = 2,2 / c = 2,2	67,22%	72,50%	93,33%
	90% de info.	11	7 - 5 - 2	0,01	0,99	Tanh - Logística	a = 1,7159;b = 2/3 / c = 1	68,02%	72,50%	92,50%
	85% de info.	9	6 - 5 - 2	0,01	0,99	Logística - Tanh	c = 1 / a = 1,7159;b = 2/3	70,63%	77,50%	95,00%
	80% de info.	7	5 - 4 - 2	0,01	0,99	Logística - Logística	c = 2,2 / c = 1	69,73%	75,00%	93,33%
FP X FF	Envoltória	128	65 - 34 - 2	0,001	0,99	Logística - Logística	c = 2,2 / c = 1	91,80%	91,67%	92,50%
	100% de info.	128	65 - 34 - 2	0,001	0,90	Logística - Logística	c = 1 / c = 1	91,59%	91,67%	95,83%
	95% de info.	16	9 - 6 - 2	0,01	0,95	Tanh - Logística	a = 1,7159;b = 2/3 / c = 1	91,93%	91,67%	99,17%
	90% de info.	11	7 - 5 - 2	0,001	0,90	Logística - Logística	c = 1 / c = 1	91,33%	91,67%	98,33%
	85% de info.	9	6 - 5 - 2	0,001	0,95	Logística - Logística	c = 1 / c = 2,2	91,36%	91,67%	98,33%
	80% de info.	7	5 - 4 - 2	0,01	0,90	Logística - Logística	c = 2,2 / c = 1	91,37%	91,67%	97,50%
PO X FF	Envoltória	128	65 - 34 - 2	0,01	0,99	Logística - Logística	c = 2,2 / c = 2,2	50,17%	50,00%	62,50%
	100% de info.	128	65 - 34 - 2	0,01	0,99	Logística - Logística	c = 1 / c = 2,2	50,00%	50,00%	74,17%
	95% de info.	16	9 - 6 - 2	0,01	0,99	Tanh - Tanh	a = 1;b = 1 / a = 1;b = 1	50,15%	50,00%	84,17%
	90% de info.	11	7 - 5 - 2	0,01	0,99	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1,7159;b = 2/3	51,10%	51,67%	86,67%
	85% de info.	9	6 - 5 - 2	0,01	0,99	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1;b = 1	51,20%	50,00%	85,83%
	80% de info.	7	5 - 4 - 2	0,01	0,99	Tanh - Tanh	a = 1,7159;b = 2/3 / a = 1,7159;b = 2/3	50,89%	50,00%	85,00%
FP X PO	Envoltória	128	65 - 34 - 2	0,001	0,99	Logística - Logística	c = 1 / c = 1	61,45%	61,67%	76,67%
	100% de info.	128	65 - 34 - 2	0,001	0,99	Logística - Logística	c = 2,2 / c = 1	61,54%	62,08%	80,30%
	95% de info.	16	9 - 6 - 2	0,01	0,99	Logística - Logística	c = 1 / c = 1	65,68%	65,83%	84,17%
	90% de info.	11	7 - 5 - 2	0,01	0,90	Logística - Logística	c = 2,2 / c = 1	67,55%	67,50%	83,33%
	85% de info.	9	6 - 5 - 2	0,01	0,90	Logística - Logística	c = 1 / c = 2,2	65,34%	65,83%	83,33%
	80% de info.	7	5 - 4 - 2	0,001	0,90	Logística - Logística	c = 1 / c = 1	66,93%	67,50%	81,67%


Fonte: Elaborado pelo autor (2026).

Figura 36 – Matrizes de confusão da melhor acurácia média e sua máxima do MLP (Duas camadas ocultas) treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações ternárias e hierárquicas.

Ternária (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FF X Todos (85% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X Todos (80% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X Todos (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

Figura 37 – Matrizes de confusão da melhor acurácia média e sua máxima do MLP (2 camadas ocultas) treinado com as componentes principais das envoltórias dos sinais simulados e testado com as componentes principais das envoltórias dos sinais reais (128 pontos) com classificações binárias.

FP X FF (95% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

FP X PO (90% de info.)




(a) Matriz de confusão média




(b) Matriz de confusão máxima

PO X FF (85% de info.)



(a) Matriz de confusão média




(b) Matriz de confusão máxima

4.5 Resumo dos resultados na etapa Simulados X Reais para as classificações ternárias

Para uma avaliação e sintetização dos resultados, esta seção apresenta os resultados das classificações ternárias na etapa Simulados X Reais. A figura 38 apresenta, no formato de gráfico de barras, os melhores desempenhos médios e seus valores máximos dos classificadores *K-Nearest Neighbors* (KNN), classificador quadrático (C.Q), *perceptron* de camada única (SLP) e *perceptron* de múltiplas camadas (MLP), com uma (1 C.O) e duas (2 C.O) camadas ocultas.

Todos os resultados apresentados na figura 38 foram obtidos utilizando as componentes principais das envoltórias dos sinais simulados para o treinamento dos modelos e as componentes principais das envoltórias dos sinais reais, geradas a partir da matriz de transformação $\mathbf{Q}_{\text{simulados}}$, para o conjunto de teste.

Figura 38 – Gráfico das melhores acurácias médias e suas máximas dos classificadores para Simulados X Reais com classificações ternárias.



Fonte: Elaborado pelo autor (2026).


Dentre os modelos avaliados na classificação ternária para Simulados X Reais, o *perceptron* de camada única (SLP) apresentou o pior desempenho geral, registrando uma acurácia média de 49,09% e uma acurácia máxima de 62,78%. Em seguida, o *K-Nearest Neighbors* (KNN) apresentou resultados superiores, com 55,26% de acurácia média e 66,67% de acurácia máxima. O classificador quadrático (C.Q) demonstrou desempenho similar ao do KNN em termos de média, alcançando 55,87%, porém com um valor máximo consideravelmente superior, de 73,33%.

Os modelos baseados em MLP superaram os classificadores anteriores. O modelo com uma camada oculta (1 C.O) atingiu 58,13% de acurácia média e 73,89% de acurácia máxima, enquanto o modelo com duas camadas ocultas (2 C.O) destacou-se como o melhor classificador do ponto de vista de desempenho global, alcançando a maior acurácia média, de 63,13%, e a maior acurácia máxima, de 80,57%. A melhora de desempenho observada ao se aumentar o número de camadas ocultas de uma para duas no MLP está associada à maior capacidade de representação do modelo.


Embora redes com uma única camada oculta sejam aproximadores universais e possam aproximar qualquer função contínua, conforme demonstrado por Cybenko (1989) e Hornik *et al.* (1989), no problema em análise o mapeamento entre os dados simulados e os dados reais envolve não linearidades complexas no espaço de características. Redes com duas camadas ocultas apresentam maior flexibilidade estrutural, permitindo a composição de funções e a modelagem de comportamentos mais complexos, incluindo funções não contínuas, em consonância com os resultados teóricos apresentados por Kolmogorov (1957). Essa maior capacidade explica o desempenho superior do MLP com duas camadas ocultas, que apresentou as maiores acurácias média e máxima.

A comparação das acurácias por classe dos melhores desempenhos médios e de seus respectivos máximos no cenário Simulados X Reais, para as classificações ternárias, é apresentada na figura 39. Na análise das acurácias por classe, para o defeito de falta de penetração (FP), o SLP obteve o maior desempenho tanto na média quanto no valor máximo. Para a classificação do defeito poro (PO), o MLP com duas camadas ocultas apresentou o maior desempenho médio, enquanto o MLP com uma camada oculta alcançou o maior desempenho máximo. Já para o defeito falta de fusão (FF), o classificador quadrático (C.Q) destacou-se ao apresentar os maiores valores de acurácia, tanto média quanto máxima.

Figura 39 – Acurácias por classe dos melhores desempenhos médios e seus máximos em Simulados X Reais, para as classificações ternárias.



(a) Acurácias médias por classe.



(b) Acurácias máximas por classe.

Fonte: Elaborado pelo autor (2026).

5 CONCLUSÕES

Os classificadores *K-Nearest Neighbors* (KNN), quadrático e as redes neurais artificiais apresentaram excelentes desempenhos médios, medianos, máximos e por classe na etapa Simulados X Simulados. Observou-se, entretanto, que a transformada de Hilbert melhorou o desempenho do classificador quadrático e das redes neurais artificiais. Para o KNN, o desempenho foi semelhante entre a envoltória e o sinal ultrassônico normalizado, sem ganhos significativos. Além disso, a redução do número de pontos de 512 para 256 e de 256 para 128 não prejudicou a classificação e, em alguns casos, até aprimorou os resultados.

A maior taxa de acerto obtida com a envoltória foi de 87,47% na média, alcançando 100% na melhor rodada para o KNN. O defeito FP mostrou-se o mais fácil de classificado corretamente, atingindo acertos médios de 100%, enquanto a maior confusão foi entre o poro (PO) e a falta de fusão (FF). Observou-se também que a aplicação da PCA melhorou o desempenho para o classificador quadrático e para as redes neurais, mas degradou o desempenho do KNN, reduzindo sua capacidade discriminativa.

Na etapa Simulados X Reais, em que foram classificados os defeitos adquiridos experimentalmente, observou-se que a utilização das componentes principais das envoltórias dos sinais simulados para o treinamento dos modelos melhorou consideravelmente os resultados, em comparação ao uso direto da envoltória dos sinais simulados no conjunto de treino. O melhor desempenho médio foi obtido pelo MLP com duas camadas ocultas, que alcançou 63,13% na média e 80,57% na melhor rodada, utilizando as componentes principais responsáveis por 80% da variância explicada acumulada das envoltórias dos sinais simulados com 128 pontos. Os resultados indicam que essa abordagem apresenta potencial de implementação em sistemas de controle de qualidade em linhas industriais, possibilitando a classificação correta de diferentes defeitos reais de soldagem.

Todos os classificadores apresentaram excelentes resultados na classificação binária entre falta de penetração e falta de fusão, indicando boa separabilidade entre esses dois defeitos. Contudo, o defeito poro permaneceu como o mais difícil de ser classificado corretamente. Nas classificações binárias entre falta de penetração e poro e entre poro e falta de fusão, bem como na classificação hierárquica poro contra todos os demais defeitos, foram registrados os piores desempenhos médios em comparação às demais classificações binárias e hierárquicas, evidenciando a baixa separabilidade do defeito de porosidade em relação aos outros tipos de defeitos reais analisados.

Como perspectiva para trabalhos futuros, os resultados deste estudo para as classificações hierárquicas e binárias apontam para a adoção de uma estratégia hierárquica de classificação de defeitos, aliada ao uso de um *ensemble* de variantes do classificador quadrático. Nesse contexto, sugere-se que a primeira etapa do processo seja a discriminação entre falta de fusão (FF) e todos os demais defeitos, uma vez que, nessa hierarquia, o classificador quadrático com a variante de Friedman, utilizando 7 componentes principais (80% da variância), apresentou desempenho superior, com acurácia média de 86,68% e máxima de 95,00%.

Na segunda etapa, as instâncias não classificadas como FF seriam submetidas à separação entre falta de penetração (FP) e porosidade (PO), na qual o classificador quadrático, empregando a variante da matriz de covariância agregada e 11 componentes principais, alcançou acurácia média de 68,76% e máxima de 75,84%. Assim, uma rota hierárquica baseada em um *ensemble* das variantes dos classificadores quadráticos, explorando diferentes variantes e configurações de redução de dimensionalidade pela PCA, mostra-se promissora para a classificação automática de defeitos de soldagem.

Além disso, recomenda-se investigar técnicas de extração de características aplicadas aos sinais simulados e às suas envoltórias, tanto no domínio do tempo quanto no domínio da frequência, com o objetivo de encontrar semelhanças entre os dados simulados e experimentais, por classe. Outra possibilidade é retornar a simulação, e realizar uma modelagem tridimensional direcionada ao defeito do poro, evidenciando maiores diferenças dimensionais desse defeito em relação aos outros.

REFERÊNCIAS

- ABDI, H.; WILLIAMS, L. J. Principal component analysis. **Wiley Interdisciplinary Reviews: Computational Statistics**, Wiley, v. 2, n. 4, p. 433–459, 2010.
- AGGARWAL, C. C.; HINNEBURG, A.; KEIM, D. A. On the surprising behavior of distance metrics in high dimensional space. In: **Proceedings of the 8th International Conference on Database Theory**. [S.l.]: Springer, 2001. p. 420–434. DOI: 10.1007/3-540-44503-X_27.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine Learning**, Springer, v. 6, n. 1, p. 37–66, 1991. DOI: 10.1007/BF00153759.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer, 2006.
- BISHOP, C. M.; BISHOP, H. **Deep Learning: Foundations and Concepts**. [S.l.]: Springer, 2024.
- British Standards Institution. **Guide to the Calibration and Setting-up of the Time of Flight Diffraction (TOFD) Technique for the Detection, Location and Sizing of Flaws**. London, UK: BSI, 1993.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals and Systems**, v. 2, n. 4, p. 303–314, 1989.
- DOMINGOS, P.; PAZZANI, M. On the optimality of the simple bayesian classifier under zero-one loss. **Machine Learning**, v. 29, n. 2–3, p. 103–130, 1997.
- DRINKWATER, B. W.; WILCOX, P. D. Ultrasonic arrays for non-destructive testing: A review. **NDT & E International**, Elsevier, v. 39, n. 7, p. 525–541, 2006.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York: Wiley-Interscience, 2001.
- FRIEDMAN, J. H. Regularized discriminant analysis. **Journal of the American Statistical Association**, v. 84, p. 165–175, 1989.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. New York: Springer, 2009. ISBN 978-0-387-84858-7.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Upper Saddle River, NJ: Pearson, 2008. ISBN 978-0-13-147139-9.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359–366, 1989.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4–37, 2000. DOI: 10.1109/34.824819.
- JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**. 6th. ed. Upper Saddle River: Pearson Prentice Hall, 2007.

JOLLIFFE, I. T. **Principal Component Analysis**. 2nd. ed. New York: Springer, 2002.

KOLMOGOROV, A. N. On the representation of continuous functions of several variables by superposition of continuous functions of one variable and addition. **Doklady Akademii Nauk SSSR**, v. 114, p. 953–956, 1957.

KRAUTKRAMER, J.; KRAUTKRAMER, H. **Ultrasonic Testing of Materials**. 4. ed. Berlin, Germany: Springer-Verlag, 1990. ISBN 978-3540512343.

LAURENCE, J. **Introduction to Neural Networks: Design, Theory, and Applications**. Nevada City: California Scientific Software, 1994.

MOURA, E. P. de; SIQUEIRA, M. H. S.; SILVA, R. R. da; REBELLO, J. M. A.; CALÔBA, L. P. Welding defect pattern recognition in tofd signals. part 1: Linear classifiers. **Insight – Non-Destructive Testing and Condition Monitoring**, v. 47, n. 12, p. 777–782, 2005.

MOURA, E. P. de; SIQUEIRA, M. H. S.; SILVA, R. R. da; REBELLO, J. M. A. Welding defect pattern recognition in tofd signals. part 2: Non-linear classifiers. **Insight**, v. 47, n. 12, p. 735–739, dez. 2005.

OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time Signal Processing**. 3rd. ed. Upper Saddle River, NJ: Pearson, 2010. ISBN 978-0131988422.

PEARSON, K. On lines and planes of closest fit to systems of points in space. **Philosophical Magazine**, Taylor & Francis, v. 2, n. 11, p. 559–572, 1901.

REDDY, J. N. **An Introduction to the Finite Element Method**. 4th. ed. New York: McGraw-Hill Education, 2019. ISBN 978-1259861901.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

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

STRANG, G. **Introduction to Linear Algebra**. 5th. ed. [S.l.]: Wellesley-Cambridge Press, 2016. ISBN 978-0-9802327-7-6.

SYAHARUDDIN; FATMAWATI; SUPRAJITNO, H. The formula study in determining the best number of neurons in neural network backpropagation architecture with three hidden layers. **JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi)**, v. 6, n. 3, p. 397–402, 2022. ISSN 2580-0760. Disponível em: <<http://jurnal.iaii.or.id>>.

THEODORIDIS, S. **Machine Learning: A Bayesian and Optimization Perspective**. 2nd. ed. [S.l.]: Academic Press, 2020. ISBN 978-0-12-818803-3.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4. ed. [S.l.]: Academic Press, 2009.

TIKHONOV, A. N. Solution of improperly stated problems and the regularization method. **Soviet Mathematics - Doklady**, v. 4, p. 1035–1038, 1963.

WEBB, A. R. **Statistical Pattern Recognition**. 2nd. ed. [S.l.]: Wiley, 2002.

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

WORKMAN, G. L.; KISHONI, D.; MOORE, P. O. (Ed.). **Nondestructive Testing Handbook, Third Edition: Volume 7, Ultrasonic Testing**. 3rd. ed. Columbus, OH: American Society for Nondestructive Testing, 2007. 600 p. ISBN 978-1-57117-283-9.