

## **BLOCO: REFINO**

# DETERMINAÇÃO DA CAMADA DE ÓXIDO EM TUBOS DE CALDEIRAS UTILIZANDO PROCESSAMENTO DE SINAIS ULTRASÔNICOS E APRENDIZADO DE MÁQUINAS

*Data de aceite: 02/06/2023*

### **Ana Eliza S. S. Melo**

Graduanda em Engenharia Química –  
GPEND/LABIND/IFBA

### **Filipe L. Oliveira**

Engenheiro Mecânico – SENAI-CIMATEC

### **Hugo D. A. Silva**

Mestrando, Engenharia de Materiais –  
GPEND/LABIND/IFBA

### **Luiz Antônio P. Cavalcanti**

Dr. em Engenharia Química - GPEND/  
LABIND/PPGEM/IFBA

### **Cláudia Teresa T. Farias**

Dra em Engenharia Metalúrgica e  
Materiais - GPEND/LABIND/PPGEM/IFBA

### **Ivan Costa da Silva**

Dr em Engenharia Metalúrgica e Materiais  
- GPEND/LABIND/PPGEM/IFBA

**ABSTRACT:** Water-tube boilers are employed in the steam generation process in chemical and petrochemical industries. One of the major causes of failures in this equipment is related to the overheating of its tubes. This phenomenon occurs due to the formation of oxide layer on the inner wall of the carbon steel tubes, where above a certain thickness, it begins

to decrease the thermal efficiency of the boiler. Measurement methods for this layer are typically destructive or non-destructive, employing ultrasound with frequencies greater than 20MHz. Faced with this reality, this study presents the results of oxide layer measurement using non-destructive ultrasonic technique, with a transducer operating at a frequency of 10MHz, coupled with digital signal processing: fast Fourier transform, principal component analysis, and machine learning. Three samples were extracted from the test specimens, for oxide layer measurement by optical microscopy and divided into three classes: CPSOX - without oxide, CP4 - with 100  $\mu\text{m}$ , and CP7 - 200  $\mu\text{m}$  of internal oxide layer. The data processed in MATLAB® software were used as input for machine learning classifiers for determining the thickness of the oxide layer. The tests conducted showed that the Quadratic Discriminant and Support Vector Machine classifiers achieved accuracy values exceeding 97%. The results obtained indicate that the non-destructive ultrasonic technique with 10 MHz, combined with signal processing, proved promising in determining the thickness range of the oxide layer inside water-tube boiler tubes.

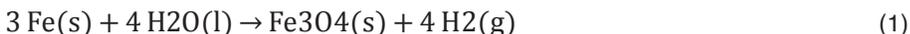
**KEYWORDS:** Water tube boilers, Oxide layer, Ultrasound, Signal Processing and Classifiers.

# 1 . INTRODUÇÃO

## 1.1 Equipamento de Caldeiras

As caldeiras aquatubulares possuem em sua configuração construtiva diversos conjuntos de tubos, os quais podem ser citados os seguintes: tubos do superaquecedor, do evaporador, do economizador e também as paredes de tubos que envolvem a fornalha. Esses elementos construtivos são fundamentais para o funcionamento eficiente da caldeira, os quais podem estar susceptíveis a ocorrência de falhas devido a corrosão interna proveniente do tratamento de água inadequado, proporcionando assim a formação de camada de óxido de ferro na parte interna dos tubos, o que contribui para redução da vida útil do equipamento podendo gerar paradas não programadas da caldeira devido rupturas dos tubos [1].

A camada de óxido formada na superfície interna de tubos de aço de baixa liga (até 3% Cr) expostos ao vapor gerado nas caldeiras consiste em uma camada composta por diferentes níveis. Quando a temperatura do metal está abaixo de aproximadamente 560°C e há uma alta pressão parcial de oxigênio, uma camada dupla composta por um filme de magnetita (Fe<sub>3</sub>O<sub>4</sub>) e outro de hematita (Fe<sub>2</sub>O<sub>3</sub>) é encontrada. Em altas temperaturas, uma camada adicional de wustita (FeO) pode se formar. Se o aço do tubo contiver elementos de liga, um óxido spinel (Fe,Cr,Mo)<sub>3</sub>O<sub>4</sub> pode se formar à medida que a camada de óxidos cresce em direção à parede do tubo [2]. A reação simplificada é mostrada na equação 1 [3].



## 1.2 Ensaio Ultrassônico

Ensaaios não destrutivos utilizam a técnica de ultrassom para a medição da espessura dessa camada de óxido baseando-se na técnica de pulso-eco, com um transdutor de ondas longitudinais de alta frequência. A espessura da camada de óxido é determinada pelo tempo medido entre os ecos dividido por dois, posteriormente, o resultado é multiplicado pela velocidade do som na magnetita, o primeiro eco representa a reflexão na interface aço/óxido, e o segundo representa o eco de reflexão da interface óxido/ar [4].

Um fator importante quando se trata da medição de finas camadas é a frequência do transdutor. Frequências maiores proporcionam menores comprimentos de ondas que impactam diretamente na resolução do ensaio. Como o estudo realizado por Cardoso [2], que mediu os sinais provenientes da camada de óxido de tubos de caldeiras empregando 20 MHz e como resultado foram medidas espessuras entre 130 μm a 993 μm.

Trabalhos posteriores a esse, feitos por Silva [5] e Oliveira [6] utilizaram frequências ainda menores com o transdutor de 15MHz para medição da espessura de camada de óxido na faixa de 0 até 300 μm, ambos utilizando o uso de processamento de dados através da aplicação da FFT, PCA e aprendizado de máquina.

### 1.3 Processamento de Sinais

A Transformada de Fourier (FFT, do inglês Fast Fourier Transform) é uma técnica utilizada para decompor um sinal no domínio do tempo em suas componentes no domínio da frequência. Ela converte um sinal de tempo contínuo ou discreto em um espectro de frequências, mostrando os diferentes componentes de frequência presentes no sinal. A FFT é amplamente usada em processamento de sinais ultrassônicos em diferentes materiais: mel [7]; compósito de fibra-resina [8] e metais [9]. Transformadas rápidas de Fourier são eficientes nos casos em que as características do meio sob teste não produz alterações mensuráveis no A-scan tais como alterações na microestrutura [10] e do tamanho de grão [11].

A análise das Componentes Principais (PCA, do inglês Principal Component Analysis), é uma técnica estatística que tem como objetivo identificar a estrutura subjacente e as relações existentes em um conjunto de dados multidimensionais. Ela é amplamente utilizada em diferentes áreas, como estatística, ciência dos dados, reconhecimento de padrões e aprendizado de máquina [6].

No ensaio ultrassônico a PCA pode ser usada para: Extração de características dos sinais contém informações relevantes sobre as características do material e neste caso serão usadas como entrada para classificadores [12]; Classificação e detecção de falhas como uma técnica de análise de padrões para classificar e detectar falhas ou anomalias em ensaios não destrutivos [10], [13].

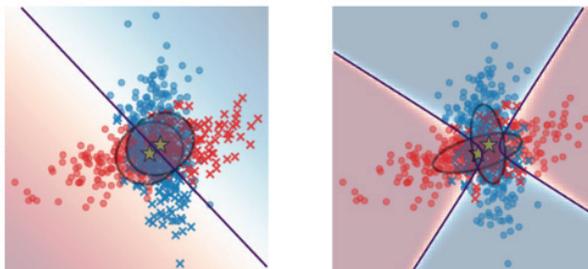
### 1.4 Aprendizagem de Máquina

O termo aprendizado de máquina vem da tradução do termo em inglês machine learning (ML), que representa uma das derivações da inteligência artificial. O método de ML baseia-se no princípio de sistemas computacionais que são capazes de aprender e modificar seu comportamento em respostas a estímulos externos, evoluindo com as experiências acumuladas durante sua operação, portanto, melhorando o desempenho dos algoritmos em função da quantidade de treinamentos realizados. O desenvolvimento dos algoritmos também utiliza conceitos de probabilidade estatística, possibilitando obtenção de informações importantes sobre os dados inseridos, permitindo a tomada de decisões e/ou previsão de resultados [14].

A Análise Discriminante Linear (DL) e a Análise Discriminante Quadrática (DQ), Figura 1, são dois classificadores clássicos e como seus nomes sugerem uma de superfície de decisão linear e outra quadrática, respectivamente. Esses classificadores são atraentes porque possuem soluções de formato fechado que podem ser facilmente computadas, são inerentemente multiclases, provaram funcionar bem na prática e não possuem hiperparâmetros para ajustar [15].

No modelo DQ se assume que as matrizes de covariância são diagonais, então as entradas são assumidas como condicionalmente independentes em cada classe, e o classificador resultante é equivalente ao classificador Gaussian Naive Bayes [15].

Figura 1 - Análise Discriminante Linear e Discriminante Quadrática com dados de covariâncias variáveis.

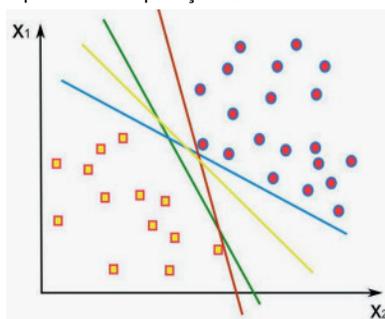


Fonte: Scikit-learn: Classificador Discriminante Quadrático [15].

O gráfico mostra limites de decisão para Análise Discriminante Linear e Análise Discriminante Quadrática. A linha inferior demonstra que a Análise Discriminante Linear só pode aprender limites lineares, enquanto a Análise Discriminante Quadrática pode aprender limites quadráticos e é, portanto, mais flexível [15].

O SVM foi introduzido por Vapnik como um modelo de aprendizado de máquina, baseado em Kernel para tarefas de classificação e regressão. A sigla SVM vem da tradução do inglês Support Vector Machine (SVM), que é um algoritmo que se caracteriza por usar um modelo treinado, retirado de um conjunto de dados rotulados e, a partir de então, prever rótulos para novos dados [16].

Figura 2 - Hiperplanos de separação linear dos classificadores SVM.



Fonte: Cervantes et al. [17].

A Figura 2 ilustra o processo de separação entre as classes por meio da criação de hiperplanos em um espaço bidimensional, onde há um conjunto de classificadores lineares responsáveis pela separação das duas classes, enquanto outro conjunto busca maximizar a margem de separação.

Diante das informações impostas, o presente trabalho tem como objetivo determinar a espessura da camada de óxido em tubos de caldeiras aquatubulares utilizando a abordagem não destrutiva com a técnica de ultrassom em baixas frequências, associadas a processamento de sinais e aprendizado de máquina.

## 2. METODOLOGIA

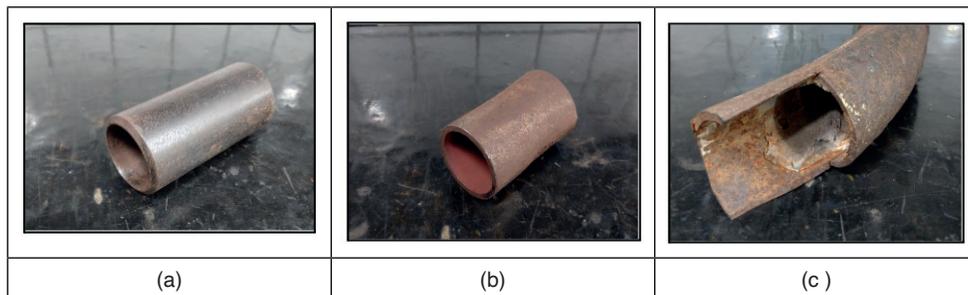
Neste capítulo, serão delineadas as etapas empregadas no desenvolvimento deste estudo, abrangendo: a metodologia adotada para especificar a fase de óxido de ferro presente na superfície interna das amostras; o método utilizado para mensurar a espessura da camada de óxido de ferro; detalhes técnicos dos instrumentos empregados; o software de engenharia utilizado para processar os dados; a abordagem adotada para o processamento dos sinais; a organização e classificação dos dados; e por fim, a metodologia empregada na condução dos testes com os sinais coletados.

### 2.1 Materiais

Neste estudo, foram usados 3 corpos de prova distintos de aço carbono retirados de tubos de caldeiras com diferentes espessuras de camadas de óxido, que estiveram em operação a um tempo superior a dez anos, com histórico de falhas devido ao superaquecimento causado pela elevada espessura de óxido.

O primeiro corpo de prova ensaiado foi um tubo que não entrou em operação e que não possuía nenhuma camada de óxido de ferro, representado na Figura 3(a). O segundo e o terceiro corpo de prova foram de tubos colocados em diferentes tempos de operações na caldeira representados nas Figuras 3 (b) e 3(c).

Figura 3 - Corpos de provas empregados na pesquisa. a) Sem camada de óxido, b) Com camada de 100  $\mu\text{m}$  e c) Com camada de 200  $\mu\text{m}$ .



Fonte: Produzida pelo autor.

### 2.2 Preparação Metalográfica

Para a preparação metalográfica, as amostras foram extraídas, dos corpos de provas, e passaram por três etapas de preparação metalográficas: corte com sistema de refrigeração, embutimento e lixamento de granulometria 80 até 1200 com o objetivo de revelar somente a interface entre o aço e a camada de óxido. Em seguida, as amostras foram observadas em um microscópio óptico, das lentes de aumento de 40 (4x) e 100

(10x) vezes. As medidas de espessura da camada de óxido foram feitas usando o software IMAGEJ® e divididas em três classes: CPSOX - sem óxido, CP4 - com 100  $\mu\text{m}$  e CP7 - 200  $\mu\text{m}$  de camada de óxido interno.

## 2.3 Ensaio Ultrassônico

Foram coletados 51 sinais A-Scan em cada um dos três corpos de prova ao longo de toda a circunferência do tubo, posteriormente foram coletados 5 sinais para testes, ao todo foram 56 sinais coletados.

A coleta dos sinais foi realizada nas condições descritas abaixo:

- Ganho: 0.0 (dB);
- Frequência do transdutor: 10 MHz;

Os ensaios ultrassônicos foram realizados por meio de um gerador de pulso ultrassônico, acoplado a um osciloscópio para a captura dos sinais que foram transferidos para armazenamento no notebook. O transdutor utilizado foi do tipo pulso-eco, com frequência de 10 MHz. Para todos os corpos de prova, os procedimentos e parâmetros de configuração dos equipamentos foram mantidos para a realização de ensaios.

Após a captura e o armazenamento dos sinais através do software LabVIEW® instalada no notebook, os dados foram transferidos para o software MATLAB® onde os sinais foram processados e testados, através da elaboração de uma matriz, FFT e PCA para extração dos parâmetros característicos dos sinais, treinamento dos dados, acurácia dos algoritmos e testes dos sinais.

## 2.4 Processamento de sinais

O processamento dos sinais se iniciou já na captura de 56 sinais ultrassônicos, onde 5 deles foram separados para teste dos classificadores e 50 para treino. O conjunto de dados foi composto por uma matriz geral de 51 colunas e 2500 linhas. A elaboração dessa matriz se deu pela concatenação horizontal dos 51 sinais A-scan referentes a cada um dos corpos de prova. Após essa primeira etapa, foram agrupados todos os sinais em uma única matriz, chamada de geral, onde foi processada por meio da Transformada Rápida de Fourier (FFT), a aplicação desse procedimento de gerou um novo conjunto de dados, com informações sobre a frequência dos sinais, constituído por 154 colunas e 2500 linhas de modo que, da coluna 1 até a 50 foram alocados os sinais do CPSOX, da coluna 51 até a 92 foram alocados os sinais do CP4 e por fim, da coluna 93 até a 153 foram alocados os sinais do CP7. A partir da matriz de coeficientes da FFT foi feita a análise das componentes principais (PCA) que serviram de entrada para os classificadores. Para o trabalho de classificação foram utilizados 11 componentes principais. O método de treinamento foi Validação Cruzada com 5 partições do conjunto de dados.

A acurácia foi a métrica para avaliação de cada classificador equação 2.

$$Acurácia = \frac{PV + NV}{PV + NV + FP + FN} \quad (2)$$

Onde: PV = Positivo Verdadeiro ; NV = Negativos Verdadeiros ; FP = Falsos Positivos e FN = Falsos Negativos.

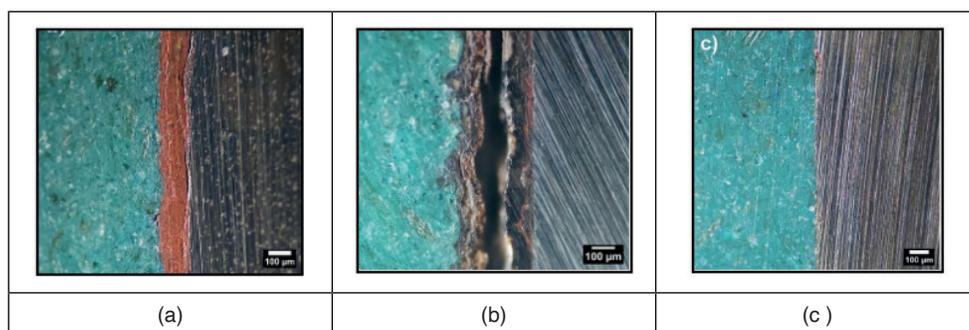
Os resultados das classificações são mostradas na forma de matrizes de confusão para discussão do desempenho de cada classificador.

### 3 . RESULTADOS

#### 3.1 Medida da Camada de Óxido por Microscopia Óptica.

A Figura 5 mostra as imagens dos corpos de provas CP4, CP7 e CPSOX. As medidas de espessuras foram  $102,88 \pm 4,21 \mu\text{m}$  e  $206,15 \pm 8,40 \mu\text{m}$  e sem formação de óxido, respectivamente. Os valores nominais adotados para as classes foram  $100 \mu\text{m}$  e  $200 \mu\text{m}$  e  $0 \mu\text{m}$ . Na Figura 5a é possível perceber a camada de óxido entre a baquelite de cor verde e o metal de base, onde há continuidade e alta aderência entre o metal e o óxido. Já na Figura 5b há o início do processo de formação da esfoliação do óxido aderido à superfície do metal, indicando uma aderência menor do que em camadas menos espessas.

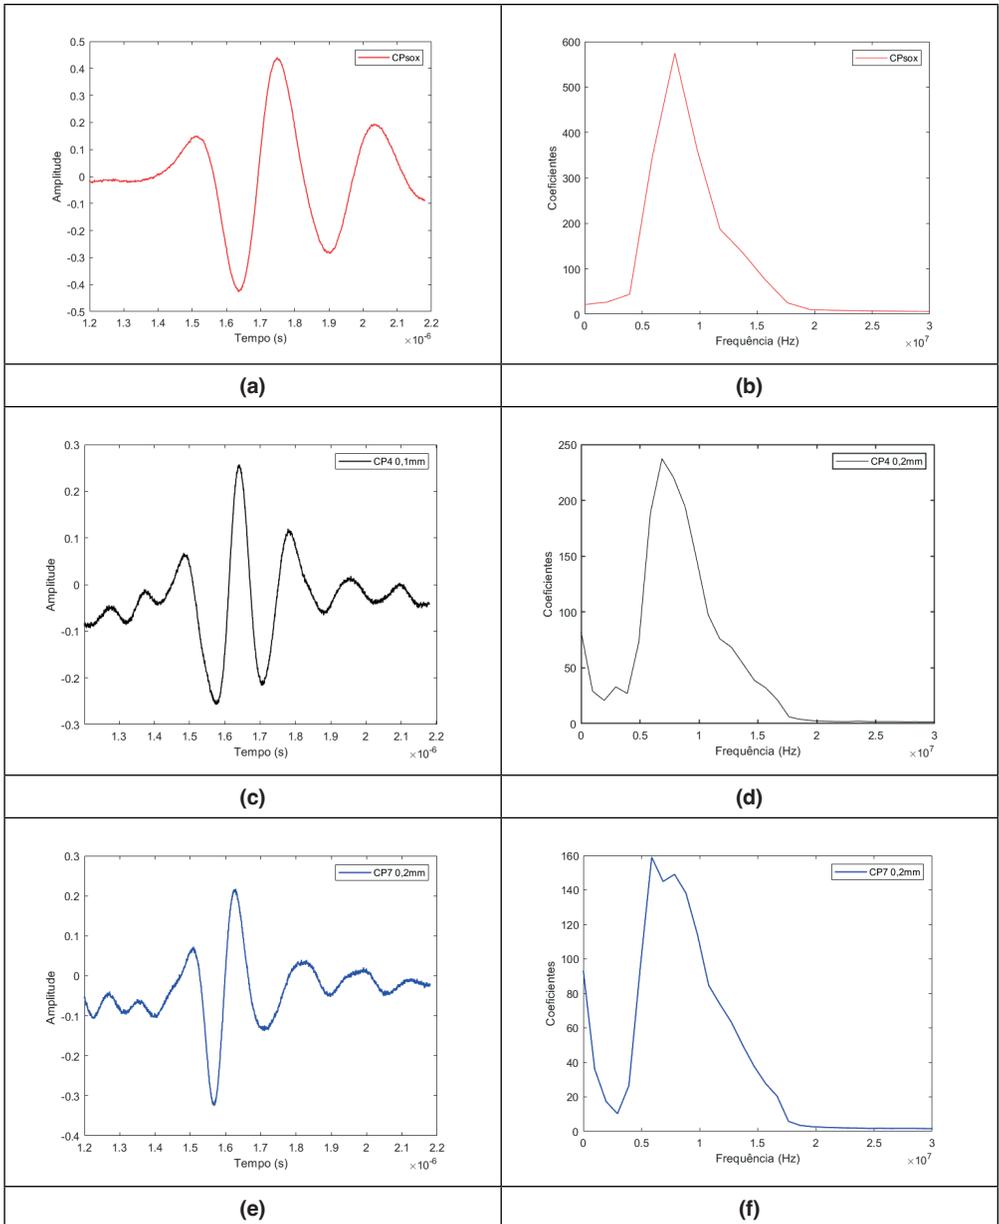
Figura 5 - Imagens microscópicas das amostras. a) CP4, b) CP7 e c) CPSOX.



#### 3.2 Medição por Ultrassom

A representação A-scan média obtida da média das 56 capturas de sinais realizadas em cada corpo de prova é mostrada na Figura 6, onde as linhas vermelha, preta e azul representam o eco da superfície interna da parede dos tubos dos corpos de prova CPSOX, CP4 e CP7, respectivamente.

Figura 6 - Sinais A-scan médios dos ecos ultrassônicos e suas respectivas FFT.



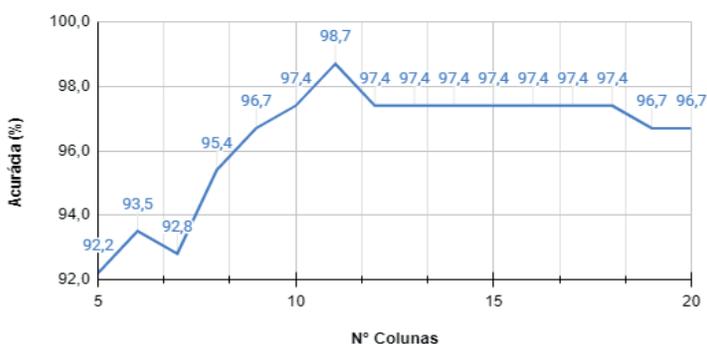
Observando a Figura 6a, 6c e 6e, percebe-se que não é fácil diferenciar os corpos de prova por meio de seus sinais de A-scan. Diante dessa dificuldade de obter informações sobre a camada de óxido, fizemos a FFT dos 55 sinais e elaboramos um novo gráfico do espectro médio de cada corpo de prova, onde novamente as linhas vermelha, preta e azul correspondem aos corpos de prova CPsox, CP4 e CP7, nas figuras 6b, 6d e 6f respectivamente.

Nas FFT's correspondentes aos corpos de prova CP4 e CP7, é evidente uma disparidade nos espectros, notadamente na menor amplitude dos coeficientes quando comparado a condição sem óxido, figura 6b, embora apresentem formas similares em termos de largura.

### 3.3 Testes com os Classificadores

A quantidade de componentes principais escolhidos possui relação direta com desempenho da PCA, podendo ser visualizado a sua diferença por meio do Gráfico 1.

Gráfico 1 - Variação percentual do número de componentes principais para um conjunto com 5 partições

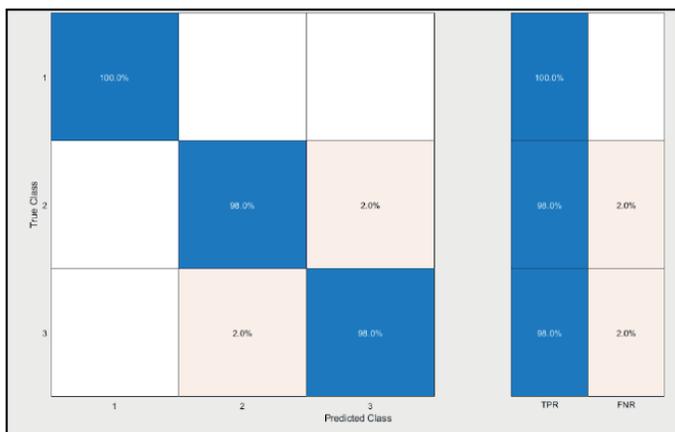


Entre todos os experimentos realizados, os ensaios que evidenciaram os resultados mais promissores foram aqueles que envolveram 11 e 10 componentes principais, os quais apresentaram acurácias de 98,7% e 97,4% , respectivamente, ao utilizar os classificadores Discriminante Quadrático e Máquina de Vetor de Suporte. Nesse contexto, observou-se que o emprego de um número maior de componentes contribuiu para a estabilização da representatividade do conjunto de dados, mantendo-a abaixo do pico alcançado.

### 3.4 Discriminante Quadrático

O classificador do tipo Discriminante Quadrático (DQ), acertou 100%, 98% e 98% para as classes sem óxido (CPSOX), 100  $\mu\text{m}$  (CP4) e 200  $\mu\text{m}$  (CP7) respectivamente, Figura 8. A classe CPSOX foi corretamente classificada com 100% de PV. A classe CP4 confundiu apenas 2% com a classe CP7 e não fez confusão alguma com a classe CPSOX. Já a classe CP7 confundiu também 2% com o CP4 e não teve confusão de dados com o CPSOX. Considerando o desempenho médio para as três classes, DQ obteve 98,7% de PV e 1,3% de FN.

Figura 8 - Matriz de confusão para DQ e taxas de positivo verdadeiro (PV) e falso negativo (FN).



Após coletar cinco sinais adicionais de cada corpo de prova para fins de validação dos classificadores, os resultados obtidos foram os seguintes: os sinais corretamente validados pelo classificador DQ são ressaltados em verde (OK), enquanto os incorretamente classificados são identificados em vermelho (-), de acordo a Tabela 1.

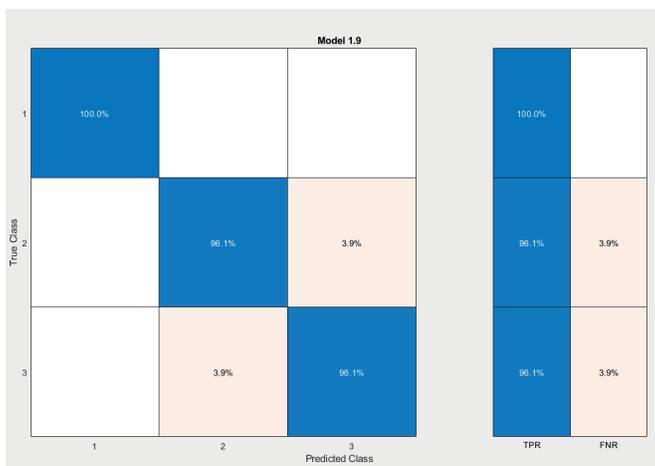
Tabela 1 - Validação do Classificador DQ

Discriminante Quadrático (98,7%) - 11 Componentes Principais			
Sinal	CPSOX	CP4	CP7
51	ok	ok	ok
52	ok	ok	-
53	ok	ok	ok
54	ok	ok	ok
55	ok	ok	ok

### 3.5 Máquina de Vetor de Suporte

O classificador do tipo Máquina de Vetor de Suporte (SVM), acertou 100%, 96,1% e 96,1% para as classes sem óxido (CPSOX), 100  $\mu\text{m}$  (CP4) e 200  $\mu\text{m}$  (CP7) respectivamente, Figura 9. A classe CPSOX foi corretamente classificada com 100% de PV. A classe CP4 confundiu apenas 3,9% com a classe CP7 e não fez confusão alguma com a classe CPSOX. Já a classe CP7 confundiu também 3,9% com o CP4 e não teve confusão de dados com o CPSOX. Considerando o desempenho médio para as três classes, SVM obteve 97,4% de PV e 2,6% de FN.

Figura 9 - Matriz de confusão para SVM e taxas de positivo verdadeiro (PV) e falso negativo (FN).



Validação dos cinco sinais do corpo de prova do classificador SVM. Os resultados obtidos foram os seguintes: os sinais corretamente validados são ressaltados em verde (OK) na tabela, enquanto os incorretamente classificados são identificados em vermelho (-), de acordo com a Tabela 2.

Tabela 2 - Validação do Classificador SVM.

SVM (97,4%) - 10 Componentes Principais			
Sinal	CPSOX	CP4	CP7
51	ok	ok	ok
52	ok	ok	-
53	ok	ok	-
54	ok	ok	-
55	ok	ok	ok

#### 4. CONCLUSÃO

Os resultados obtidos neste trabalho foram promissores, visto que as classificações dos sinais dos três corpos de prova apresentaram bons desempenhos com o transdutor de 10MHz. Dentre os diversos tipos de classificadores de aprendizagem de máquina disponíveis, o que se destacou foi os Discriminante Quadrático (DQ) e Máquina de Vetor de Suporte (SVM). Esses classificadores atingiram níveis de acurácia superiores a 97% na distinção das diferentes espessuras de camada óxido. Com base nisso, foi possível demonstrar a capacidade do método em avaliar tubos de caldeiras através da utilização de transdutores ultrassônicos de 10MHz com frequência menor do que as convencionalmente empregadas.

## 5 . REFERÊNCIAS

- [1] LABRECK, S.; KASS, D.; NELLIGAN, T. Ultrasonic thickness measurement of internal oxide scale in steam boiler tubes. 9th European Conference on NDT - September, (2006).
- [2] Cardoso, B. R., Comeli, F. W., Santana, R. M., & Furtado, H. C. . Previsão de vida em tubos de caldeiras com base na medição da espessura da camada de óxido por ultrassom. *Matéria*, Rio De Janeiro, (2011). 16(4), 819–829. DOI: 10.1590/S1517-70762011000400003
- [3] Raman, B., Hall, D. M., Shulder, S. J., Caravaggio, M. F., & Lvov, S. N. (2016). An experimental study of deposition of suspended magnetite in high temperature-high pressure boiler type environments. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 508, 48-56. DOI: 10.1016/j.colsurfa.2016.08.018
- [4] Vesela J., Mares P., Janura R., Internal oxide thickness measurement by ultrasonic method. *Materials at High Temperature*, (2019).
- [5] Silva, H. D. A. Determinação da espessura da camada de óxido ferro em tubos de radiant shield presente em caldeiras aquatubulares através de processamento de sinais de ultrassom e uso de classificadores. Dissertação para Obtenção do Título de Mestre, Engenharia de Materiais, PPGEM - Instituto Federal Da Bahia, Salvador (2023). <https://repositorio.ifba.edu.br/jspui/handle/123456789/541>
- [6] Oliveira, F.L. Determinação da camada de óxido em tubos de caldeira aquatubular utilizando técnica não destrutiva ultrassônica. Dissertação de conclusão de curso em Engenharia Mecânica - Instituto Federal Da Bahia, Salvador (2023). <http://repositorio.ifba.edu.br/jspui/>
- [7] Rufo, M., Jiménez, A., Paniagua, J. M., & González-Mohino, A. (2021). Ultrasound Assessment of Honey Using Fast Fourier Transform. *Sensors*, 21(20), 6748.
- [8] Bayat, S., Jamzad, A., Zobeiry, N., Poursartip, A., Mousavi, P., & Abolmaesumi, P. (2023). Temporal enhanced Ultrasound: A new method for detection of porosity defects in composites. *Composites Part A: Applied Science and Manufacturing*, 164, 107259.
- [9] Lin, Y. J., Yang, C. H., & Huang, J. Y. (2020). Influence of Microstructural Changes' Effects on the Linear and Nonlinear Ultrasonic Parameters of Cast Stainless Steels. *Applied Sciences*, 10(10), 3476.
- [10] Oliveira, M. A., Simas Filho, E. F., Albuquerque, M. C. S., Santos, Y. T. B., Silva, I. C. d., & Farias, C. T. T. (2020). Ultrasound-based identification of damage in wind turbine blades using novelty detection. *Ultrasonics*, 108, 106166. DOI: 10.1016/j.ultras.2020.106166
- [11] Xue, R., Wang, X., Yang, Q., Xu, D., Sun, Y., Zhang, J., & Krishnaswamy, S. (2021). Grain size distribution characterization of aluminum with a particle swarm optimization neural network using laser ultrasonics. *Applied Acoustics*, 180, 108125.
- [12] Simas Filho, E. F., Souza, Y. N., Lopes, J. L. S., Farias, C. T. T., & Albuquerque, M. C. S. (2013). Decision support system for ultrasound inspection of fiber metal laminates using statistical signal processing and neural networks. *Ultrasonics*, 53(6), 1104-1111. DOI: 10.1016/j.ultras.2013.02.005
- [13] Sarr, C. A. T., Chataigner, S., Gaillet, L., & Godin, N. (2021). Nondestructive evaluation of FRP-reinforced structures bonded joints using acousto-ultrasonic: Towards diagnostic of damage state. *Construction and Building Materials*, 313, 125499. DOI: 10.1016/j.conbuildmat.2021.125499
- [14] ALPAYDIN, E. *Introduction to Machine Learning*. MIT Press, 2a Edição, 2010.

[15] Scikit-learn: Classificador Discriminante Quadrático. Disponível em: [https://scikit-learn.org/stable/modules/lda\\_qda.html#id1](https://scikit-learn.org/stable/modules/lda_qda.html#id1)

[16] JIMÉNEZ A. A.; GÓMEZ MUÑOZ C. Q.; GARCÍA MÁRQUEZ, F.P. Dirt and mud detection and diagnosis on a wind turbine blade employing guided waves and supervised learning classifiers. Reliability Engineering System Safety, 184, 2-12, 2019.

[17] CERVANTES, J., LAMONT, F. G., MAZAHUA, L. R., LOPEZ, ASDRUBAL. A comprehensive survey on support vector machine Classification: Applications, Challenges and trends. Neurocomputing, v. 408, p. 189-215, 2020.

## **6 . AGRADECIMENTOS**

Os autores agradecem à Fundação de Apoio a Pesquisa da Bahia (FAPESB) pelo apoio na forma de bolsa de iniciação científica.