



## AVALIAÇÃO DE CAMADA TEMPERADA POR INDUÇÃO USANDO TÉCNICA ULTRASSÔNICA E INTELIGÊNCIA COMPUTACIONAL

<sup>1</sup>Gabriela O. Silva, <sup>2</sup>Jader P. Badaró, <sup>3</sup>Maria Cléa S. Albuquerque, <sup>4</sup>Ivan C. Silva,  
<sup>5</sup>Cláudia T. T. Farias, <sup>6</sup>Eduardo F. S. Filho

### RESUMO

Os tratamentos térmicos ajustam as propriedades dos aços, produzindo componentes de máquinas com boas características mecânicas. No caso dos eixos de colhedeiras, tratamentos térmicos de têmpera e revenimento costumam ser realizados, seguidos de têmpera por indução, na camada externa, combinando a tenacidade do núcleo à dureza superficial elevada. A profundidade da camada temperada por indução costuma ser medida por métodos destrutivos. Inspeções não destrutivas aliadas a técnicas de pré-processamento e aprendizado de máquina podem ser opções promissoras e eficientes. Neste estudo, sinais ultrassônicos Pulso Eco de eixos de aço DIN 42CrMo4, com diferentes espessuras de camada temperada por indução, foram combinados com técnicas de pré-processamento, como a transformada discreta de Fourier e análise de componentes principais para treinar classificadores de aprendizado de máquina. Os resultados indicaram alta acurácia na estimativa da espessura da camada temperada por indução, reforçando o potencial do método para controle de qualidade em máquinas agrícolas.

**PALAVRAS-CHAVE:** Têmpera por Indução, Ultrassom, DFT, Máquinas de Aprendizado.

### ABSTRACT

Heat treatments adjust the properties of steels, producing machine components with good mechanical characteristics. In the case of tractor shafts, quenching and tempering heat treatments are typically performed, followed by induction hardening on the external layer, combining the toughness of the core with high surface hardness. The depth of the induction-hardened layer is usually measured by destructive methods. Non-destructive inspections combined with preprocessing and machine learning techniques can be promising and efficient options. In this study, Pulse-Echo ultrasonic signals from DIN 42CrMo4 steel shafts with different induction-hardened layer thicknesses were combined with preprocessing techniques, such as discrete Fourier transform and principal component analysis, to train machine learning classifiers. The results indicated high accuracy in estimating the thickness of the induction-hardened layer, reinforcing the potential of the method for quality control in agricultural machinery.

**KEYWORDS:** Induction Hardening, Ultrasound, DFT, Machine Learning.

<sup>1</sup> Graduanda em Engenharia Mecânica - GPEND/LABIND/IFBA

<sup>2</sup> Mestrando em Engenharia dos Materiais - PPGEM/IFBA

<sup>3</sup> Dr<sup>a</sup> Enga de Processos - GPEND/LABIND/IFBA

<sup>4,5</sup> Dr e Dr<sup>a</sup>. em Engenharia Metalúrgica e Materiais - GPEND/LABIND/IFBA

<sup>6</sup> Dr. em Engenharia Elétrica - PPGEE/UFBA

## 1. INTRODUÇÃO

As demandas de fabricação de peças, como eixos de máquinas, são atendidas por empresas metalúrgicas por meio da combinação de múltiplos tratamentos térmicos, que ajustam as propriedades mecânicas tanto na região do núcleo quanto na superfície dos componentes (1).

A têmpera por indução é frequentemente utilizada por sua capacidade de aquecer seletivamente áreas específicas da peça, criando uma camada superficial endurecida, resistente ao desgaste e à fadiga, sem comprometer a tenacidade do núcleo. Esse processo envolve o uso de correntes induzidas por um campo eletromagnético de alta frequência que aquece rapidamente a superfície da peça até a faixa de temperatura de austenitização e, em seguida, resfriando-a rapidamente para formar martensita, uma fase cristalina extremamente dura (2).

A profundidade da camada temperada por indução é tradicionalmente medida por meio de perfis de dureza ou preparação metalográfica, utilizando um processo de ataque químico com um reagente específico, o qual resulta na visualização de tons de cinza distintos nas regiões modificadas pelo tratamento endurecedor e no núcleo da peça. Posteriormente, a medição da espessura da camada temperada por indução pode ser efetuada utilizando instrumentos como paquímetros, ou através de meios digitais, com analisadores de imagens (3-5).

Esses métodos, embora comuns, apresentam desafios, como a dificuldade em medir a dureza em camadas finas ou regiões de transição, tornando-os pouco precisos. Além dessas, há limitações relacionadas ao desperdício de matéria-prima, demanda de tempo para a usinagem de amostras e infraestrutura para realização de cortes e ensaios.

A associação entre as características mecânicas e a microestrutura no emprego de aços modificados pelo tratamento térmico de indução é essencial para avaliar o desempenho previsto das ligas e se puder ser feita de forma econômica e com otimização do tempo, garantirá a competitividade em mercados cada vez mais exigentes.

Nesse contexto, as técnicas de inspeção ultrassônica estão emergindo como opções promissoras, em substituição aos métodos destrutivos, proporcionando velocidade, confiabilidade e custo acessível. Sua integração com técnicas computacionais de aprendizado de máquina tem se mostrado relevante no

desenvolvimento de algoritmos para pré-processamento, compressão de sinais, identificação e classificação de padrões (6).

Neste estudo, algoritmos de aprendizado de máquina, como *KNN* (do inglês *K-Nearest Neighbors* ou K-Vizinhos Mais Próximos) e *Ensemble Bagged Trees*, (conjunto de várias árvores de decisão) foram utilizados para classificar sinais ultrassônicos obtidos pela técnica Pulso Eco de eixos mecânicos fabricados em aço DIN 42CrMo4, de médio teor de carbono, todos com o mesmo diâmetro nominal, mas com diferentes espessuras de camada temperada por indução. O objetivo foi desenvolver um método mais preciso e eficiente para avaliar a qualidade e a uniformidade das camadas temperadas, especificamente em componentes usados em aplicações agrícolas, onde a resistência ao desgaste e à fadiga são essenciais para garantia de seu desempenho.

## 2. MATERIAL E MÉTODOS

### 2.1 Material

O material utilizado consistiu em um eixo de aço DIN/EN 42CrMo4, usado em equipamentos agrícolas, exibido na Figura 1. O eixo foi tratado termicamente por têmpera e revenimento convencionais em forno a gás e, posteriormente, por têmpera por indução eletromagnética na superfície. Em seguida foi seccionado longitudinal e transversalmente, em 4 corpos de prova com diâmetros nominais de 51 mm, e espessuras de camada temperada distintas.

Figura 1 - Corpos de prova com mesmo diâmetro nominal e diferentes espessuras de camada temperada por indução (3).



A Tabela 1 apresenta as medidas da espessura da camada temperada por indução, obtidas em trabalho anterior (3). As medidas foram obtidas com paquímetro e através de um perfil de microdureza realizado da borda até o centro

da amostra, onde a dureza média observada era de 260 HV. O local onde se observava o decréscimo no valor de dureza coincidia com o final da camada temperada por indução.

Tabela 1 - Valores de espessura da camada temperada (em mm) (3).

Amostra	Obtida com o paquímetro	Perfil de microdureza
1	5,8	5,2
2	6,4	5,5
3	6,6	6,4
4	8,7	7,8

## 2.2 Métodos

A metodologia empregada para o desenvolvimento deste trabalho pode ser descrita no fluxograma exibido na Figura 2:

Figura 2 - Fluxograma com as etapas do trabalho



### 2.2.1 Inspeção Ultrassônica

A técnica de ensaio ultrassônico Pulso Eco foi usada para obtenção dos sinais nos corpos de prova supracitados, a partir das seções longitudinais de cada eixo.

Para o ensaio ultrassônico, foram usados um gerador de pulso *Olympus® modelo 5077PR*, um osciloscópio *Tektronix® TDS-2024B* e transdutores de 15 MHz *Olympus®* com 0,25 cm de diâmetro. Para permitir melhor apoio do transdutor ao eixo e facilitar a coleta dos sinais, foi usado um suporte circular, impresso em impressora 3D, marca *Ender3 S1*. Para reduzir a impedância acústica, foi utilizado o acoplante *Sonotech Ultragel II*. A Figura 3 exibe a imagem da configuração experimental.

Figura 3 - Configuração experimental para o ensaio de inspeção ultrassônica. 1) gerador de pulsos; 2) osciloscópio; 3) transdutor; 4) suporte do transdutor; 5) amostra de um dos eixos; 6) notebook com programa LabView® (3).



### 2.2.2 Pré-Processamento dos Sinais

Foram obtidos 100 sinais em locais diferentes dos quatro corpos de prova, totalizando 400 sinais. Cada sinal foi exportado como um vetor com 2500 amostras. Dessa forma, para cada corpo de prova foi criada uma matriz de 2500 linhas por 100 colunas (uma para cada sinal). Em seguida, os sinais foram transferidos por meio de um aplicativo do LABVIEW® que faz a interface do osciloscópio com o computador, onde, através do MATLAB®, foram plotados gráficos amplitude x tempo (A-scan), com 2500 amostras, para análise dos dados.

Através do MATLAB®, foi gerado um algoritmo que implementa a Transformada Discreta de Fourier (*Discrete Fourier Transform - DFT*) (7). Esse algoritmo foi responsável pelo pré-processamento dos conjuntos de sinais A-scan, correspondentes a cada classe de corpo de prova, com diferentes espessuras de camadas temperadas por indução. O pré-processamento permitiu converter os sinais no domínio do tempo para o domínio da frequência, facilitando a extração de características relevantes e análise de classificação subsequente dos corpos de prova. Após a aplicação da DFT, obteve-se 2500 coeficientes no domínio da frequência.

### 2.2.3 Compactação dos Sinais

Para a análise dos componentes principais (*Principal Component Analysis - PCA*) (8), foi criada uma matriz de 2500 linhas (representando os coeficientes da DFT) por 400 colunas (representando as 100 aquisições de sinal para cada um dos 4 corpos de prova). Após a aplicação da PCA, a matriz original de 2500x400 foi

reduzida para uma matriz de 400x400. Nessa nova matriz, as linhas de 1 a 100, 101 a 200, 201 a 300 e 301 a 400 eram representadas respectivamente pelos componentes principais dos corpos de prova 01, 02, 03 e 04.

Estudos têm mostrado que a PCA pode aumentar a precisão dos classificadores ao eliminar redundâncias e reduzir o risco de *overfitting*, facilitando a interpretação dos dados e melhorando o desempenho do classificador (6).

#### **2.2.4 Projeto dos Sistemas de Classificação**

Após a aplicação da PCA e a geração de uma matriz de 400x400, foi acrescentada uma coluna com os rótulos de classificação, a coluna 401, onde foram adicionados os números 1, 2, 3 e 4 nas linhas de 1 a 100, de 101 a 200, de 201 a 300, de 301 a 400 para identificar os corpos de prova 1, 2, 3 e 4 respectivamente.

Essa matriz foi então carregada no aplicativo *Classification Learner* do MATLAB®, realizando-se o treinamento com todos os classificadores disponíveis no aplicativo, por meio de suas configurações padrão para os hiperparâmetros de cada modelo de aprendizagem de máquina. Variou-se a quantidade de componentes principais, iniciando com 2 e finalizando com 10 componentes. Em seguida, foram realizados testes nos classificadores, buscando-se identificar aqueles que obtiveram 100% de acerto.

Para a realização desse experimento, 90% dos sinais foram utilizados para treino e 10% para teste, com a escolha dos exemplos para teste, feita automaticamente pelo *Classification Learner*. Os resultados do treino foram apresentados sob a forma de matrizes de confusão, onde cada uma foi dividida em duas classes: reais (classificação verdadeira) e preditas (classificações estimadas pelo modelo).

#### **2.2.5 Análise Metalográfica**

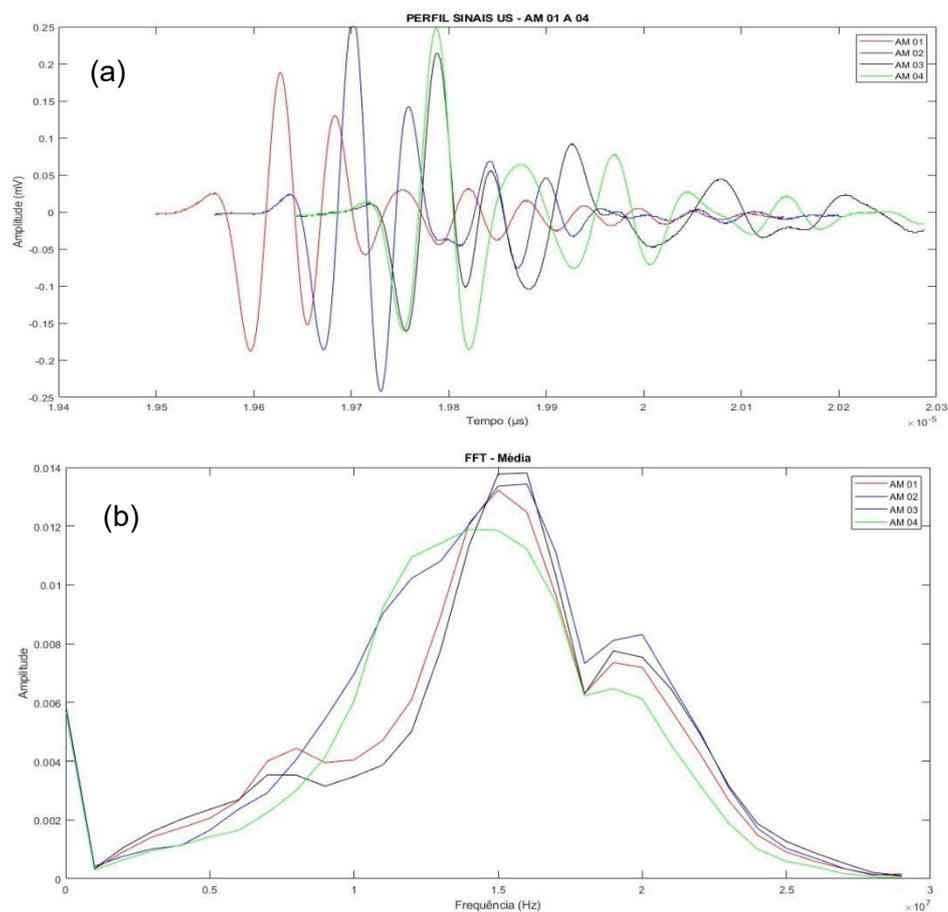
Simultaneamente às etapas de inspeção, análise e classificação de sinais, foi realizada uma análise metalográfica no material, com o objetivo de caracterizar os microconstituintes presentes na camada temperada por indução, no núcleo temperado e revenido e na interface entre ambos os tratamentos. A metodologia de preparação das amostras envolveu as seguintes etapas: seccionamento do eixo (longitudinal e transversal), embutimento em baquelite, lixamento a úmido com lixas

de granulometrias variando de 80 a 1200 mesh, polimento usando alumina em suspensão com partículas de 0,3  $\mu\text{m}$ , ataque químico com Nital, diluído a 2% em álcool etílico e, por fim, análise por microscopia óptica.

### 3. RESULTADOS E DISCUSSÃO

A Figura 4 (a) exibe a média dos 100 sinais A-scan típicos dos quatro corpos de prova no domínio do tempo, com 2500 amostras cada, enquanto a Figura 4(b), os mesmos sinais no domínio da frequência, obtidos após a aplicação da Transformada Discreta de Fourier (DFT), fazendo um *zoom* nos 30 primeiros coeficientes.

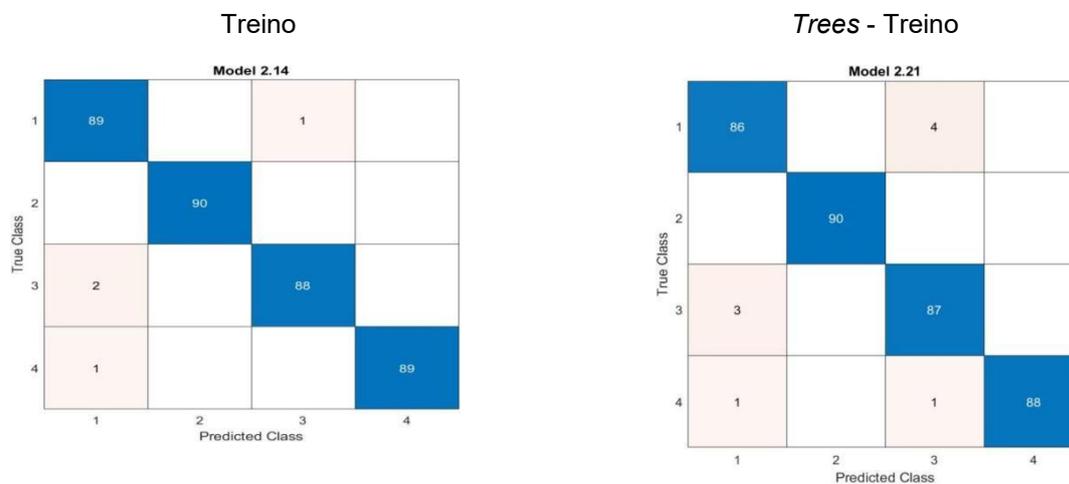
Figura 4: (a) Média dos 100 sinais A-scan dos 4 corpos de prova com espessuras distintas de camadas temperadas por indução (b) Representação dos sinais no domínio da frequência, após transformada discreta de Fourier



Os 4 conjuntos de sinais pré-processados por DFT e com a sua dimensionalidade reduzida através da PCA foram utilizados como entrada para os classificadores automáticos, sendo utilizados 90% dos sinais para treino e 10% para teste.

Durante a análise, ao variar o número de componentes principais, observou-se que a utilização de 5 componentes resultou em 100% de acertos no conjunto de teste para vários classificadores, incluindo KNN:*Fine* e *Ensemble-Bagged Trees* (9). Embora outros classificadores, como KNN *Weighted KNN*, *Ensemble Subspace-KNN* e Redes Neurais (*Medium*, *Wide* e *Trilayered Neural Network*) (9), também tenham exibido o mesmo desempenho, o foco deste trabalho será nos classificadores mencionados anteriormente, para os quais as matrizes de confusão obtidas no treino, exibidas nas Figuras 6 e 7, foram detalhadamente analisadas.

Figura 6 - Matriz de confusão KNN:*Fine*-KNN - Figura 7 - Matriz de confusão *Ensemble-Bagged Trees* - Treino



Cada matriz foi dividida em duas classes, reais (classificação verdadeira dos resultados) e as preditas (classificações que o modelo estimou). O número de acertos para cada classe é demonstrado na diagonal principal da matriz, e os demais, os erros de classificação.

Conforme exibido na Figura 6, a matriz de confusão apresentada para o classificador KNN: *Fine*-KNN demonstra que a maioria das amostras foi corretamente identificada, como evidenciado pelos índices na diagonal principal da matriz, com 89, 90, 88 e 89 acertos para as Classes 1, 2, 3 e 4, respectivamente. No entanto, houve pequenos erros de classificação, onde algumas amostras foram equivocadamente confundidas a classes adjacentes, como observado com a amostra 1, confundida com a amostra 3 e as amostras 3 e 4 confundidas com a amostra 1.

Na matriz de confusão obtida pelo classificador *Ensemble-Bagged Trees*, exibida na Figura 7, observa-se também um bom desempenho, mas com mais erros de classificação do que na matriz anterior. A amostra 1 obteve 86 acertos e foi 4 vezes

incorretamente atribuída como sendo a amostra 3. A amostra 2 manteve seu bom desempenho, com 90 acertos, sem erros de classificação. A amostra 3 apresentou uma ligeira diminuição na precisão, com 87 acertos e 3 vezes erroneamente classificada como a amostra 1. Por fim, a amostra 4 teve 88 acertos, mas houve 2 erros de classificação confundindo-a às amostras 1 e 3.

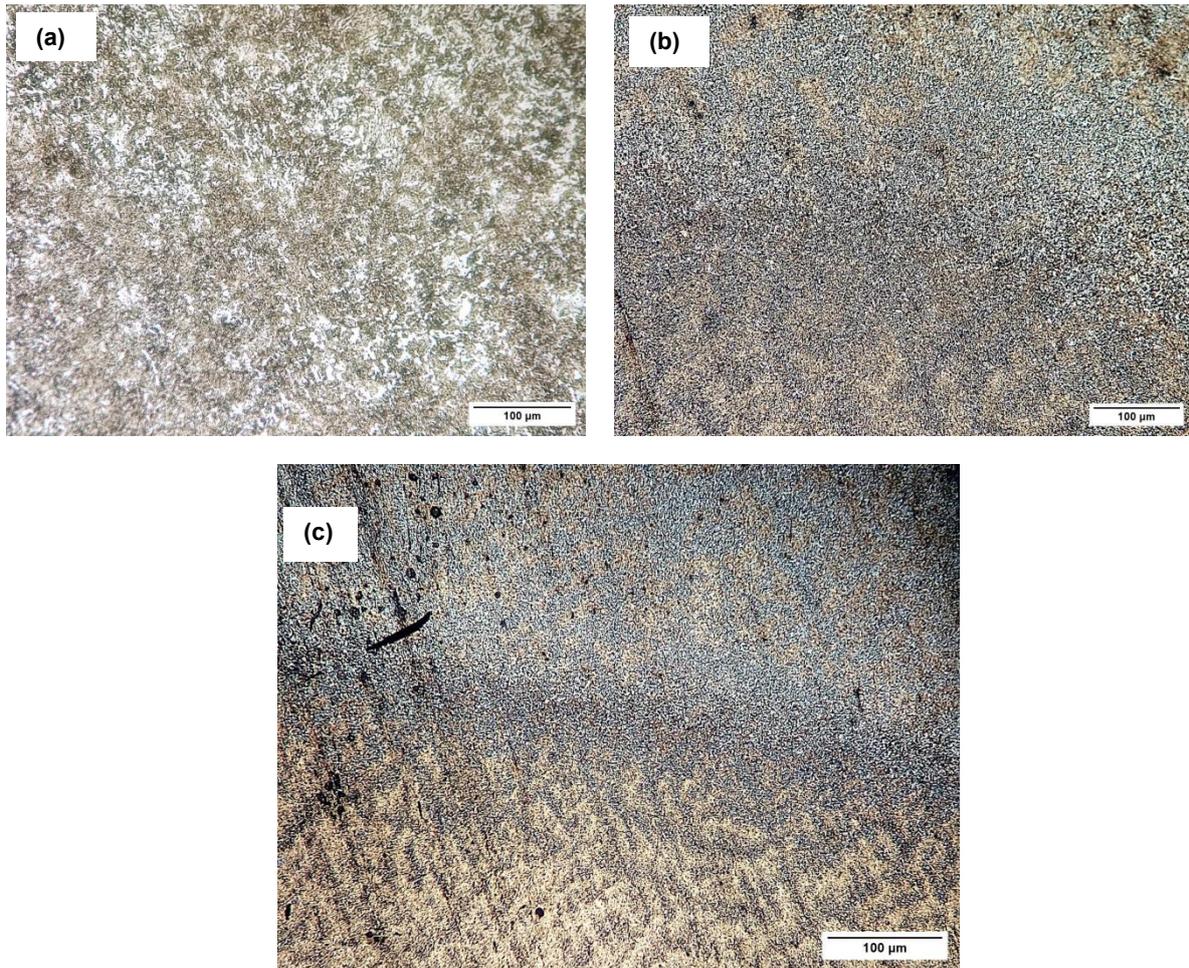
Ao comparar o desempenho de ambas matrizes, o classificador *Ensemble-Bagged Trees* demonstrou uma ligeira redução na precisão geral, especialmente nas Classes 1 e 3, cujos erros aumentaram.

Essa confusão pode estar relacionada às diferenças sutis na espessura e dureza entre as amostras, uma vez que a microdureza e a espessura aumentam gradualmente, conforme dados exibidos na Tabela 1. Por outro lado, o uso de classificadores, como *KNN* e *Ensemble-Bagged Trees*, também se beneficia dessa transição gradual, permitindo que a maioria das amostras seja corretamente identificada, embora com pequenos erros nas classes mais próximas. As transições suaves entre ambas regiões modificadas pelos tratamentos térmicos e a microdureza crescente, como visto nos valores experimentais, são fatores que podem dificultar uma classificação totalmente exata, especialmente em sistemas onde os valores de espessura e dureza se sobrepõem parcialmente.

A análise microestrutural, realizada por microscopia óptica, permitiu revelar as distintas regiões criadas pelos tratamentos térmicos: o núcleo temperado e revenido, a camada superficial temperada por indução e a interface entre essas regiões, conforme imagens exibidas na Figura 8.

No núcleo temperado e revenido esperava-se uma estrutura mais dúctil, com uma possível combinação de martensita revenida, bainita ou perlita, resultado do ciclo de têmpera e revenimento. A martensita revenida é constituída de finos carbonetos dispersos em uma matriz ferrítica (4). Observam-se em meio às referidas microestruturas, a presença de grãos de ferrita envolvendo a perlita, o que indica que o ciclo de revenimento foi suficientemente longo para permitir a sua formação nas regiões de baixa concentração de carbono (10). A ferrita contribui para a ductilidade dessa região, favorecendo o uso em aplicações onde uma combinação de resistência e capacidade de deformação são necessárias.

Figura 8 - Microestrutura óptica do eixo em três regiões (a) núcleo, (b) interface núcleo e (c) superfície temperada por indução.



A presença de uma microestrutura previamente temperada e revenida é considerada mais favorável para o processo de têmpera por indução. Isso ocorre porque essa microestrutura facilita a formação de grãos finos de martensita durante o tratamento, resultando em uma resposta rápida e consistente ao aquecimento e resfriamento característicos da têmpera por indução. Além disso, contribui para minimizar o crescimento de grão e para a obtenção de uma camada superficial endurecida com propriedades mecânicas superiores, mantendo a tenacidade do núcleo (4). Na superfície, a têmpera por indução gerou uma camada de martensita, evidenciada por uma matriz com tons de cinza mais escuros, mais dura, portanto, e resistente ao desgaste. Conforme demonstrado em trabalho anterior (3), os valores de microdureza obtidos nessa região, mostraram que a superfície modificada pela têmpera por indução é cerca de 46 a 66% mais dura que a do núcleo temperado e revenido.

A interface entre as regiões é particularmente importante, pois evidencia uma transição gradual entre o núcleo temperado e revenido e a superfície endurecida pela tempera por indução. Transições bruscas em dureza ou microestrutura podem levar a tensões internas e, eventualmente, a falhas prematuras do componente (4).

#### **4. CONCLUSÕES**

Os resultados das matrizes de confusão indicam que as amostras de eixos mecânicos com diferentes espessuras de camadas temperadas possuem características suficientemente distintas para serem diferenciadas por classificadores, como o KNN: *Fine-KNN*. No entanto, a presença de erros de classificação, especialmente verificada pelo classificador *Ensemble-Bagged Trees*, sugere que as diferenças nas espessuras podem não ser totalmente identificadas por todos os modelos, possivelmente devido às diferenças sutis entre as amostras. Isso pode indicar a necessidade de um modelo mais sofisticado ou de uma maior quantidade de dados para aumentar a precisão da classificação entre amostras com espessuras de camada temperada semelhantes.

Esse estudo também destacou a importância da precisão na medição das espessuras de camada e da escolha cuidadosa de classificadores adequados para distinguir características discretas em materiais tratados termicamente. A tendência a erros de classificação nas amostras com espessuras próximas pode ser uma área a ser investigada em trabalhos futuros, considerando ajustes nos modelos ou técnicas adicionais de pré-processamento dos sinais.

#### **5. AGRADECIMENTOS**

Os autores agradecem a FAPESB, pelo suporte financeiro e à Forja Bahia, pela concessão do material destinado ao estudo.

#### **6. REFERÊNCIAS BIBLIOGRÁFICAS**

1. TENÓRIOA et al. Têmpera por Indução Eletromagnética Aplicada em Virabrequim de Motocicleta. HOLOS, Ano 31, Vol. 3. DOI: 10.15628/holos.2015.2917. p. 82-92, 2015.

2. FERREIRA, C. R et al. Tratamento térmico por indução eletromagnética em tubos de aço SAE 1045 para produção de hastes de sondagem geológica. *Metalurgia & Materiais*, DOI: 10.1590/S0370-44672004000100005. 2004.
3. GOMES, I. S. Associação de Parâmetros do Sinal Ultrassônico à Espessura da Camada Temperada por Indução de Eixos de Máquinas Agrícolas. In: XXXVIII Congresso Nacional de Ensaio Não Destrutivo e Inspeção, 20 a 22 de setembro de 2023, São Paulo, SP, Brasil.
4. SILVA JARDIM, M. V. Estudo do Tratamento Térmico Superficial por Indução Eletromagnética de Alta Frequência para Hastes de Sondagem Geológica. Dissertação de Mestrado. Programa de Pós graduação em Engenharia de Materiais, UFOP, 2018. 84p.
5. FELIPPE, D.M. et al. Comparação entre os Processos de Têmpera (Tratamento Térmico) Convencional e por Indução de Rolamentos do Aço Din 100 Cr6. In: 64º Congresso Anual da ABM, 13 a 17 de julho de 2009, Belo Horizonte, MG, Brasil.
6. MACEDO, L.T. et al. Avaliação de Diferentes Técnicas de Pré Processamento para um Sistema Neural de Apoio à Decisão em Inspeções por Ultrassom. In: XVI Congresso Brasileiro de Inteligência Computacional (CBIC), 08 a 11 de outubro de 2023, Salvador, BA, Brasil.
7. DINIZ, P.D. SILVA, E. A. B. da Silva, NETTO, S. L. *Processamento Digital de Sinais: Projeto e Análise de Sistemas*. Porto Alegre: Bookman, 2014. 585p.
8. JOLLIFFE, I. T. *Principal Component Analysis*. New York: Springer, 2nd. 2002.
9. NORO, M.R.F et al. O Efeito do Tratamento Térmico de Revenimento em Chapas Grossas Sobre as Propriedades Mecânicas de Aços Martensíticos de Baixo Teor de Carbono. In: 64º Congresso Anual da ABM, 13 a 17 de julho de 2009, Belo Horizonte, MG, Brasil.
10. THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. San Diego, California: Elsevier, 4<sup>th</sup> ed. 2009.