

ganhado destaque na caracterização de materiais metálicos é a inspeção por correntes parasitas pulsadas (PEC, do inglês *Pulsed Eddy Currents*) [7], [8].

Com o objetivo de diferenciar sinais provenientes de diferentes pontos da bobina, este estudo explorou a combinação de um dos aços mais comumente utilizados na fabricação de chassis e carrocerias da indústria automotiva com uma técnica emergente de inspeção não destrutiva baseada em princípios magnéticos. Além disso, buscou analisar, de forma mais detalhada, o efeito dos métodos de transformação de sinais, extração de características e a otimização de hiperparâmetros, explorando aspectos que não foram abordados anteriormente [9]. Utilizando um algoritmo de aprendizado de máquina baseado em árvores de decisão, impulsionadas por gradiente (*Gradient Boosted Decision Trees - GBDT*), as classificações das diferentes condições da amostra foram realizadas com base em um conjunto específico de sinais, obtidos por meio da técnica de inspeção por correntes parasitas pulsadas (PEC). Adicionalmente, foram aplicados métodos avançados de transformação de sinais, como a Transformada de Fourier [10], bem como técnicas de extração de características, incluindo Análise de Componentes Principais e Análise de Discriminante Linear [11]. Os resultados alcançados indicaram a eficácia do método proposto.

II. FUNDAMENTAÇÃO TEÓRICA

A. Técnica de Corrente Parasita Pulsada

A técnica de correntes parasitas é amplamente utilizada como um ensaio não destrutivo para inspecionar materiais metálicos, baseando-se no princípio da indução eletromagnética e correntes de Foucault [12]. Ao aplicar uma corrente alternada a uma bobina de teste, é gerado um campo magnético alternado com densidade de fluxo B . O fluxo magnético total (ϕ_p) contido dentro da bobina é calculado multiplicando-se B pela área da bobina. Quando a bobina de teste se aproxima de um material metálico, o campo eletromagnético induz correntes circulares no material, fluindo em planos paralelos às espiras da bobina. Essas correntes parasitas induzidas geram um campo magnético secundário que se opõe ao campo magnético primário. Consequentemente, o fluxo magnético induzido (ϕ_s) contrapõe-se ao fluxo magnético primário, conforme ilustrado na Figura 1. Tal natureza pode ser descrita pela lei de Faraday, evidenciada na Equação 1.

$$\oint \vec{E} \cdot d\vec{s} = -\frac{\partial \phi_p}{\partial t} \quad (1)$$

Onde \vec{E} é o campo elétrico induzido através variação do fluxo magnético e $d\vec{s}$, é o elemento de comprimento ao longo da curva de integração. A interação entre os campos magnéticos primário e secundário resulta em uma força eletromotriz que afeta a bobina, levando a uma mudança aparente em sua impedância [12]. Essa mudança é causada pelas variações nas propriedades elétricas, magnéticas e geométricas do material.

A técnica de correntes parasitas pulsadas utiliza uma ampla gama de frequências, por meio de pulsos repetidos de ondas

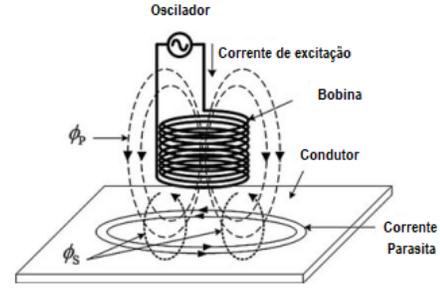


Figura 1: Diagrama do princípio do teste por corrente parasita, adaptado de [12].

quadradas de curta duração, para estimular a bobina [13]. Essa configuração proporciona uma abordagem ampla para a obtenção de informações precisas sobre as condições do teste, resultando em uma maior sensibilidade quando comparado ao ensaio por correntes parasitas convencional, que utiliza um sinal de excitação senoidal. Quando ocorrem modificações na microestrutura ou surgem falhas mecânicas no material, tais alterações refletem-se no campo magnético, uma vez que estão estreitamente relacionadas à condutividade elétrica, permeabilidade magnética e disposição do campo [14]. Essa técnica oferece uma abordagem abrangente e eficiente para a inspeção de materiais, contribuindo para a detecção precisa de anomalias e proporcionando informações valiosas para a avaliação das propriedades dos materiais.

Devido ao constante avanço da capacidade computacional, as análises feitas a partir da técnica de correntes parasitas pulsadas têm se beneficiado da associação entre os domínios do tempo e da frequência, além do uso de algoritmos de processamento de sinais. Essa combinação permite a extração de novos parâmetros e informações relevantes para a detecção e avaliação de defeitos em materiais. Ao utilizar técnicas de aprendizado de máquina, como parte desse processo, é possível obter uma ampla gama de dados relacionados a defeitos entre camadas, propriedades magnéticas, perda de material e diferenças de *lift-off*¹ [15]. Tal abordagem integrada promove uma análise mais abrangente e precisa, contribuindo para a identificação eficiente de falhas e facilitando a tomada de decisões. Com isso, é possível otimizar os processos de inspeção e manutenção, garantindo a qualidade e confiabilidade dos materiais utilizados.

B. Gradient Boosted Decision Trees - GBDT

O algoritmo de árvore de decisão por impulso de gradiente (do inglês, *Gradient Boosting Decision Trees - GBDT*) tem sido amplamente utilizado em máquinas de aprendizado devido à sua eficiência, precisão e capacidade de interpretação [17]. Com ele é possível acelerar o treinamento, reduzir o consumo

¹Varição no afastamento entre a bobina e o objeto em um sistema de medição de correntes parasitas. Isso pode afetar a precisão das medições, pois altera o campo magnético induzido. Logo, minimizar essa diferença é importante para obter resultados mais precisos nas técnicas de inspeção por correntes parasitas.

de memória e combinar diferentes redes para maximizar o aprendizado paralelo, conhecido como algoritmo de árvore de decisão de votação paralela [17]. Devido às suas características promissoras, o GBDT tem obtido bons desempenhos em diversas tarefas de aprendizado de máquina, como classificação multiclasse, regressão e *ranking* [18]. O *LightGBM* é um exemplo de algoritmo de código aberto que utiliza árvores de decisão por impulso de gradiente [19].

Diferentemente de outros algoritmos de árvores de decisão, o *LightGBM* adota uma estratégia de crescimento baseada em folhas (*leaf-wise*) em vez de uma estratégia baseada em níveis (*level-wise*) [19]. Isso permite que a GBDT construa árvores de decisão mais profundas e com menos divisões, o que resulta em um modelo mais preciso e eficiente. Ele seleciona a folha com uma perda máxima para crescer, onde a função de perda é uma medida de ajuste dos coeficientes do modelo e é utilizada para que, nas etapas do reforço de gradiente, os erros sejam minimizados [18]. Assim, a estrutura continua a crescer com os ramos e folhas mais promissores, isto é, nós com a maior perda, mantendo constante o número de folhas de decisão. Além disso, o *LightGBM* incorpora técnicas como amostragem por gradiente (do inglês, “*Gradient-based One Side Sampling*” - GOSS) e exclusão de características (do inglês, “*Exclusive Feature Bundling*” - EFB) para melhorar ainda mais sua eficiência e capacidade de lidar com grandes conjuntos de dados [18]. As Figuras 2 e 3 descrevem o crescimento da árvore por profundidade e por folha respectivamente.

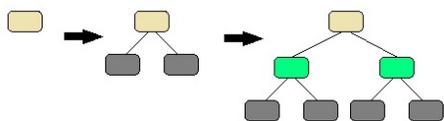


Figura 2: Crescimento da árvore por profundidade.

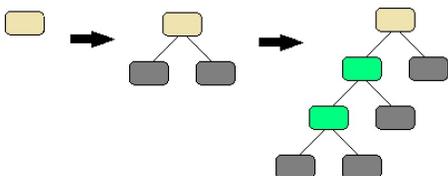


Figura 3: Crescimento da árvore por folha.

Vale explicitar que, para conjuntos de dados limitados, o desenvolvimento em que se utiliza o crescimento por folha pode aumentar a complexidade do modelo e levar ao sobreajuste [18]. Logo, para se evitar isso, é importante modificar os parâmetros ajustáveis do modelo, também conhecidos como hiperparâmetros. Esses hiperparâmetros controlam o comportamento e a complexidade do modelo e podem ter um impacto significativo em seu desempenho. Existem várias técnicas comumente utilizadas para otimizar o ajuste dos hiperparâmetros. Duas delas são a busca em grade (do inglês *Grid Search*) e a busca aleatória (do inglês *Random Search*) [20]. Essas

técnicas ajudam a encontrar a combinação mais promissora de hiperparâmetros que leva ao melhor desempenho do modelo.

C. Técnicas de redução de dimensionalidade

Os métodos de extração de características têm como objetivo revelar informações relevantes, que estavam ocultas no conjunto de dados original. Essas técnicas são aplicadas durante o pré-processamento dos dados, a fim de prepará-los para serem utilizados por algoritmos de aprendizado de máquina. Nesse contexto, a Análise de Componentes Principais e a Análise Discriminante Linear são técnicas lineares de destaque para a extração de características, amplamente discutidas na literatura [21].

1) *Análise de Componentes Principais - PCA*: do inglês, *Principal component Analysis - PCA*, é uma técnica não supervisionada amplamente utilizada para preservar a informação contida em conjuntos de dados originais. O objetivo do PCA é analisar as relações entre um grande número de variáveis e criar um novo conjunto de elementos não correlacionados, que capturem a maior parte da variabilidade e correlação dos dados iniciais. Essa técnica permite reduzir a dimensionalidade dos dados, preservando a estrutura essencial e a sua variância [11].

2) *Análise Discriminante Linear - LDA*: do inglês, *Linear Discriminant Analysis - LDA*, é uma técnica supervisionada utilizada para classificação e visualização de dados. Seu principal objetivo é encontrar uma combinação linear de características que possa descrever ou separar duas ou mais classes de objetos ou eventos. Ao maximizar a diferença entre as classes, o LDA cria um conjunto de características que torna mais fácil a tarefa de classificação e melhora o desempenho dos algoritmos de aprendizado de máquina. Ao contrário da PCA, que é uma técnica não supervisionada, a LDA utiliza informações sobre as classes dos dados para encontrar a melhor representação. Isso faz com que a LDA seja uma técnica valiosa em diversas áreas, incluindo reconhecimento de padrões, processamento de imagens e análise de dados em geral [11].

D. Transformada Rápida de Fourier - FFT

A Transformada Rápida de Fourier (FFT, do inglês “*Fast Fourier Transform*”) é um algoritmo utilizado para calcular a Transformada Discreta de Fourier (DFT, do inglês “*Discrete Fourier Transform*”) e sua inversa. Essa técnica tem como objetivo converter um sinal de seu domínio original, normalmente no domínio do tempo, para sua representação no domínio da frequência. Dessa forma, a DFT permite decompor uma sequência de valores uniformemente espaçados e extrair informações valiosas sobre as diferentes frequências presentes no sinal de interesse. Essa abordagem tem aplicações diversas em áreas como processamento de sinais, comunicações e análise de dados [10].

E. Otimização Bayesiana com métodos Gaussianos

A ideia central por trás da otimização *Bayesiana* é o uso de um modelo probabilístico para representar a função objetivo e iterativamente buscar as melhores configurações

de parâmetros que minimizam ou maximizam essa função. Nesse contexto, os métodos Gaussianos são frequentemente utilizados para modelar a função objetivo desconhecida como um processo Gaussiano [22]. Um processo Gaussiano é uma distribuição de probabilidade sobre funções, em que qualquer subconjunto finito dessas funções segue uma distribuição gaussiana multivariada. Ao usar um processo Gaussiano para modelar a função objetivo, é possível estimar a função em diferentes pontos e quantificar a incerteza associada às previsões. Essa otimização envolve um ciclo iterativo de duas etapas: exploração e exploração. Na etapa de exploração, são selecionados pontos para avaliação com base em uma medida de incerteza, geralmente chamada de aquisição ou função de aquisição [23]. Essa medida indica as regiões onde a função objetivo é mais incerta ou promissora em termos de encontrar melhores soluções. Na etapa de exploração, a função objetivo é avaliada nos pontos selecionados e, com base nesses resultados, o modelo probabilístico é atualizado para melhorar as estimativas da função objetivo e a incerteza associada [24].

III. MATERIAL E MÉTODOS

Três chapas de aço, cada uma medindo 1530×1175 mm, foram retiradas de diferentes posições em uma bobina, como ilustra a Figura 4. A bobina é utilizada na linha de produção para a fabricação de peças por estampagem. De cada chapa, foram extraídas três amostras com dimensões de 300×300 mm. No total, nove amostras foram identificadas e cedidas por uma montadora de automóveis para serem utilizadas como corpos de prova.

Foram coletados 51 sinais em cada um dos corpos de prova usando a técnica PEC. Esses sinais foram obtidos em três partes diferentes da bobina: no início, no meio e no final. Essas áreas representam as diferentes condições de compressão durante o transporte e o armazenamento da bobina. Em cada uma dessas áreas, foram obtidos 153 sinais, o que totaliza 459 sinais no conjunto de dados usado para o desenvolvimento deste trabalho.

O sistema experimental utilizado neste estudo consiste em uma sonda composta por uma bobina geradora de campo magnético e um sensor GMR (*Giant Magneto-Resistance*). A bobina é alimentada por um gerador de função configurado para gerar um pulso de onda quadrada de 12 V, com uma frequência de 500 Hz e um *Duty cycle* de 50%. A resposta magnética captada pelo sensor GMR é digitalizada com uma taxa de amostragem de 200 kHz e uma resolução de 12 bits. Assim, as assinaturas PEC foram registradas com 2500 amostras temporais cada. O diagrama do processo experimental pode ser visualizado na Figura 5.

Após a coleta dos sinais PEC, a DFT foi aplicada ao conjunto de entrada. Isso permitiu avaliar os sinais no domínio da frequência e obter um segundo conjunto de dados de treinamento. O primeiro conjunto consistiu nos sinais PEC sem nenhum processamento adicional, conforme descrito anteriormente e o segundo conjunto, composto pelos primeiros 1250 coeficientes da DFT. Em seguida, os conjuntos de dados passaram por uma etapa de pré-processamento, utilizando as

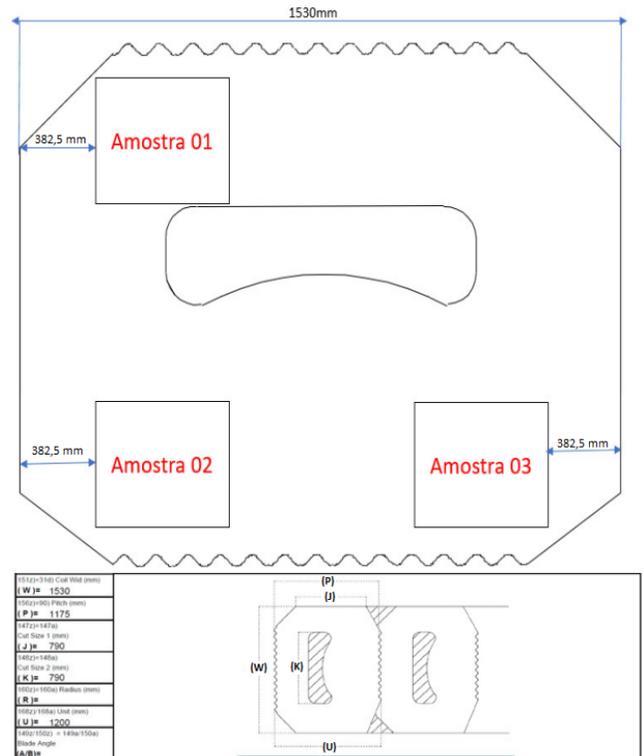


Figura 4: Disposição dos três corpos de prova retirados da chapa para cada situação.

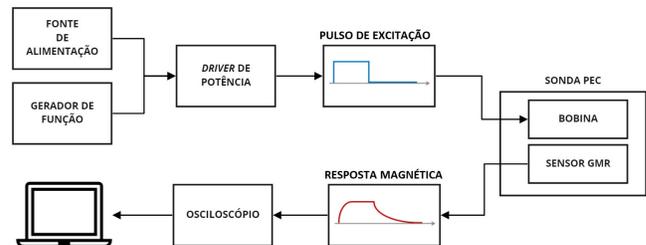


Figura 5: Diagrama do processo experimental.

técnicas PCA e LDA. Para o conjunto de sinais PEC, foram selecionados 220 componentes na PCA, enquanto no conjunto DFT foram escolhidos 365 componentes. Ao final, foram obtidos 6 conjuntos de dados distintos. O processo é ilustrado no diagrama apresentado na Figura 6.

No estudo, o classificador GBDT foi escolhido devido à sua robustez em lidar com conjuntos de dados que possuem um número restrito de exemplos por classe. As assinaturas foram divididas em uma proporção de 80% para treinamento e 20% para teste, não sendo considerado um conjunto de validação devido à quantidade reduzida de dados. Para maximizar os resultados, foi realizado um procedimento de busca aleatória dos hiperparâmetros utilizando otimização *Bayesiana* com processos Gaussianos. A Tabela I evidencia os hiperparâmetros utilizados com os seguintes intervalos de variação:

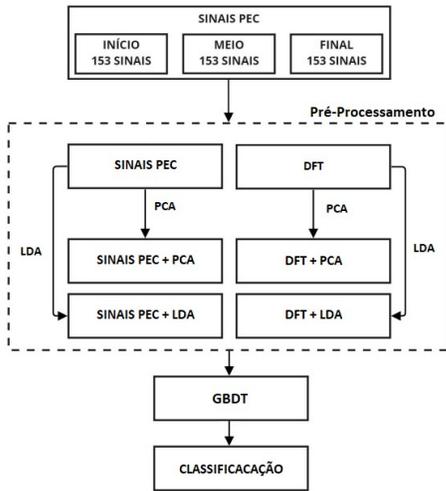


Figura 6: Diagrama da geração dos conjuntos de dados de entradas do algoritmo.

$learning_rate$, entre 10^{-3} e 10^{-1} , num_leaves , variando de 2 a 256, $min_child_samples$, de 1 a 100, $subsample$, de $5 \cdot 10^{-2}$ a 1 e $colsample_bytree$, variando de 10^{-1} a 1, para 200 reinicializações. Nesse sentido, os grupos foram comparados nos termos da média da acurácia e do $F1-score$ das 200 inicializações para GBDT em questão.

Tabela I: Espaço de Hiperparâmetros

Hiperparâmetro	Variação	
	De	Até
$learning_rate$	10^{-3}	10^{-1}
num_leaves	2	256
$min_child_samples$	1	100
$subsample$	$5 \cdot 10^{-2}$	1
$colsample_bytree$	10^{-1}	1

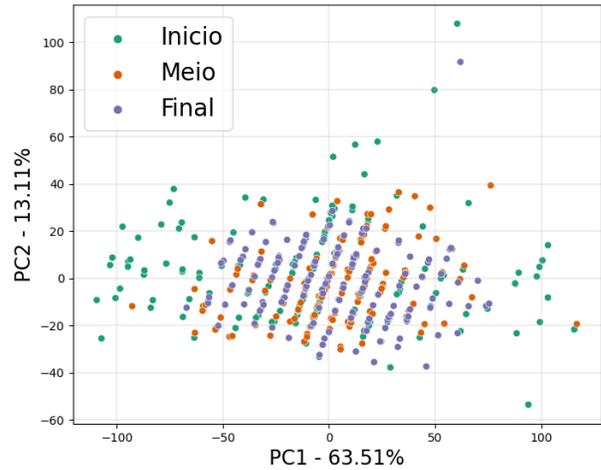
IV. RESULTADOS E DISCUSSÃO

A seleção dos 220 componentes na PCA, aplicada aos sinais PEC, revelou uma confiabilidade de 95,00% e 91,20% de diminuição na dimensão das amostras. Já para a escolha dos 365 componentes, aplicando a PCA ao conjunto de sinais DFT, os resultados explanaram uma confiabilidade de 94,84% e uma redução de 70,78% no tamanho das amostras.

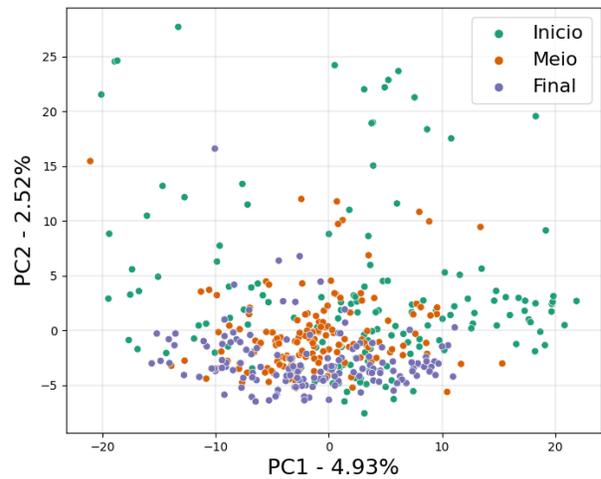
A aplicação da PCA aos sinais FFT, demonstrada pelo gráfico de dispersão na Figura 7b, explicita uma melhoria na separação das classes, em comparação aos sinais PEC, que por sua vez é mostrada na Figura 7a, onde há uma sobreposição mais aparente das classes. Para os sinais PEC, os dois primeiros componentes principais foram responsáveis por explicar 76,6% da variabilidade dos dados, enquanto para os sinais com a transformada rápida de Fourier (FFT), os dois primeiros componentes principais foram responsáveis por explicar 7,45% da variabilidade dos dados.

Na aplicação da LDA aos sinais PEC (Figura 8a) e FFT (Figura 8b), é notável um comportamento mais discriminante

dos sinais, revelando uma maior segregação das classes em comparação à aplicação da PCA aos mesmos conjuntos de dados. De maneira similar, as classes dos sinais FFT com LDA estão mais separadas em relação às classes dos sinais PEC com LDA.



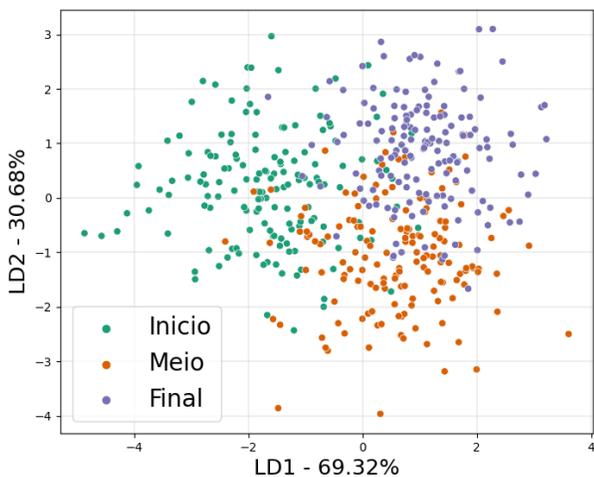
(a) PCA aplicada aos sinais PEC.



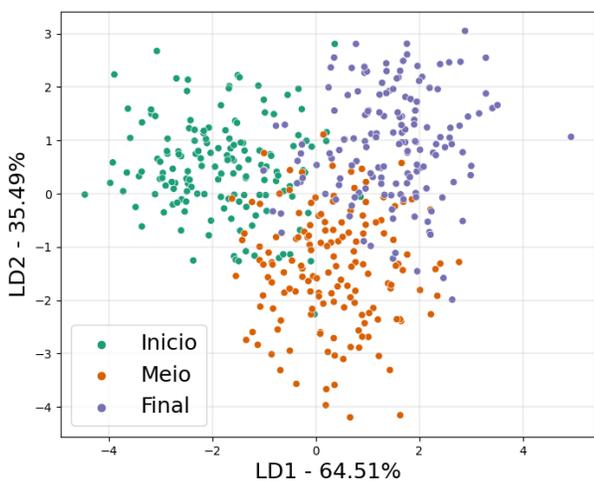
(b) PCA aplicada aos sinais FFT.

Figura 7: PCA aplicada aos sinais PEC e FFT.

Em relação às diferentes inicializações de treinamento utilizando o GBDT, a Tabela II apresenta os melhores hiperparâmetros para cada conjunto de teste com diferentes inicializações de treinamento. No conjunto de sinais PEC sem processamento, a acurácia foi de 30,85% e o $F1-score$ de 17,98%. Após a aplicação da PCA a esse conjunto, houve um aumento nas métricas, alcançando uma acurácia média de 40,29% e um $F1-score$ médio de 35,87%. A aplicação da LDA aos mesmos dados iniciais resultou em um novo aumento na acurácia e no $F1-score$, com valores de 72,10% e 69,95%, respectivamente. No grupo de sinais PEC com a aplicação da DFT, a acurácia foi de 73,42% e o $F1-score$ de 70,28%. No entanto, ao combinar DFT e PCA, houve



(a) LDA aplicada aos sinais PEC.



(b) LDA aplicada aos sinais FFT.

Figura 8: LDA aplicada aos sinais PEC e FFT.

uma redução nas métricas, alcançando valores de 67,96% e 63,89%, respectivamente. Por outro lado, ao aplicar a LDA ao grupo de sinais de entrada DFT, obteve-se um aumento significativo, com a maior acurácia média e *FI-score* para o GBDT, atingindo 85,28% e 84,91%, respectivamente.

Os resultados obtidos indicaram que o pré-processamento dos dados utilizando a transformada discreta de Fourier (DFT) proporcionou uma melhora significativa na capacidade de classificação do sistema. A aplicação da DFT permitiu uma melhor representação dos sinais, revelando informações importantes no domínio da frequência que foram relevantes para a separação e identificação das classes. Além disso, ao empregar a técnica de análise discriminante linear (LDA) ao conjunto de dados de entrada, observou-se um aumento substancial no desempenho do algoritmo de classificação. A LDA foi capaz de encontrar projeções no espaço de características que maximizaram a separação entre as classes, tornando-as mais

Tabela II: Médias das acurácias e *FI-score* para GBDT.

Entrada	Acurácia (%)	<i>FI-score</i> (%)	Hiperparâmetros
PEC	30,85 ± 1,64	17,98 ± 1,74	<i>learning_rate</i> = 0,005, <i>num_leaves</i> = 42, <i>min_child_samples</i> = 71, <i>subsample</i> = 0,97, <i>colsample_bytree</i> = 1
DFT	73,42 ± 0,46	70,28 ± 0,51	<i>learning_rate</i> = 0,1, <i>num_leaves</i> = 128, <i>min_child_samples</i> = 1, <i>subsample</i> = 0,91, <i>colsample_bytree</i> = 0,68
PEC + PCA	40,29 ± 1,38	35,87 ± 1,25	<i>learning_rate</i> = 0,10, <i>num_leaves</i> = 239, <i>min_child_samples</i> = 14, <i>subsample</i> = 1, <i>colsample_bytree</i> = 0,31
DFT + PCA	67,96 ± 0,58	63,89 ± 0,66	<i>learning_rate</i> = 0,03, <i>num_leaves</i> = 206, <i>min_child_samples</i> = 10, <i>subsample</i> = 0,54, <i>colsample_bytree</i> = 0,88
PEC + LDA	72,10 ± 0,52	69,95 ± 0,56	<i>learning_rate</i> = 0,02, <i>num_leaves</i> = 256, <i>min_child_samples</i> = 100, <i>subsample</i> = 0,90, <i>colsample_bytree</i> = 1
DFT + LDA	85,28 ± 0,32	84,91 ± 0,34	<i>learning_rate</i> = 0,1, <i>num_leaves</i> = 198, <i>min_child_samples</i> = 45, <i>subsample</i> = 0,99, <i>colsample_bytree</i> = 0,25

distintas e facilitando a tarefa de classificação.

A Figura 9 apresenta as matrizes de confusão com as melhores inicializações do GBDT para as entradas PEC, FFT, PEC + PCA, FFT + PCA, PEC + LDA e FFT + LDA, tendo em vista o conjunto de melhor desempenho em acurácia e *FI-score*.

A matriz de confusão dos sinais PEC, conforme mostra a Figura 9a, apresentou um percentual total de acerto de 45,00%. O algoritmo obteve a maior taxa de acerto, de 58%, para a classe “Final”, assim como o maior percentual de falsos positivos para essa mesma classe, obtendo 36% em relação à categorização da classe “Meio”. No geral, o algoritmo teve um desempenho inadequado para esse conjunto de sinais, não conseguindo separar bem nenhuma das classes.

Ainda na imagem 9a, a matriz de confusão dos sinais FFT apresentou um percentual total de acertos de 82,33%, mostrando um desempenho superior em relação ao conjunto de sinais PEC. Além disso, o maior percentual de acertos ocorreu na classe “Final”, com 88%, enquanto a taxa mais elevada de falsos positivos foi de 25% para a classe “Final” no que se refere à classificação da classe “Meio”. Em resumo, o algoritmo apresentou uma melhor separação das classes “Início” e “Final” no conjunto de sinais.

Nesse sentido, ao analisar os conjuntos envolvendo PCA (Figura 9b) e LDA (Figura 9c), notou-se que, além de o algoritmo obter um desempenho melhor, o uso da FFT e da LDA diminuíram bastante a confusão entre as classes “Início” e “Final”, alcançando 92% de taxa de acertos para essas classes. Esse resultado pode ser atribuído ao fato de que

as amostras das classes “Início” e “Final” foram coletadas nos extremos da bobina, enquanto a classe “Meio” representa uma situação intermediária entre essas duas classes. Foi percebido também na Figura 9 que, com exceção dos sinais PEC sem processamento, o algoritmo obteve os maiores pontos percentuais de falsos positivos para a classe “Final”, no que concerne à classificação dos sinais relacionados às amostras retiradas do meio da bobina. Isso indica uma dificuldade do algoritmo em diferenciar essas duas classes, devido a proximidade da posição dessas duas amostras na bobina.

Em razão das características específicas do transporte e armazenamento do aço IF, é razoável esperar que os resultados obtidos a partir dos sinais coletados dessa bobina sejam semelhantes aos sinais extraídos de amostras obtidas de bobinas diferentes. Isso ocorre porque as condições de compressão durante o transporte e armazenamento tendem a ter padrões similares em materiais de natureza semelhante, como o aço IF, independentemente da origem da bobina. Portanto, a base de dados composta por esses sinais pode ser representativa de maneira geral para o desenvolvimento deste estudo.

		SINAIS PEC					SINAIS FFT		
		CLASSE PREDITA					CLASSE PREDITA		
CLASSE REAL		INÍCIO	MEIO	FINAL	CLASSE REAL		INÍCIO	MEIO	FINAL
	INÍCIO	0,39	0,25	0,36		INÍCIO	0,84	0,08	0,08
	MEIO	0,31	0,38	0,31		MEIO	0,00	0,75	0,25
	FINAL	0,17	0,25	0,58		FINAL	0,04	0,08	0,88

(a) Melhores resultados do GBDT para sinais PEC e FFT.

		SINAIS PEC + PCA					SINAIS FFT + PCA		
		CLASSE PREDITA					CLASSE PREDITA		
CLASSE REAL		INÍCIO	MEIO	FINAL	CLASSE REAL		INÍCIO	MEIO	FINAL
	INÍCIO	0,75	0,11	0,14		INÍCIO	0,92	0,00	0,08
	MEIO	0,25	0,41	0,34		MEIO	0,13	0,59	0,28
	FINAL	0,04	0,08	0,88		FINAL	0,04	0,04	0,92

(b) Melhores resultados do GBDT para sinais PEC e FFT com PCA.

		SINAIS PEC + LDA					SINAIS FFT + LDA		
		CLASSE PREDITA					CLASSE PREDITA		
CLASSE REAL		INÍCIO	MEIO	FINAL	CLASSE REAL		INÍCIO	MEIO	FINAL
	INÍCIO	0,86	0,06	0,08		INÍCIO	0,92	0,03	0,05
	MEIO	0,00	0,69	0,31		MEIO	0,03	0,84	0,13
	FINAL	0,08	0,04	0,88		FINAL	0,08	0,00	0,92

(c) Melhores resultados do GBDT para sinais PEC e FFT com LDA.

Figura 9: Resultado das melhores configurações do GBDT.

V. CONCLUSÕES

A utilização do GBDT foi avaliada como suporte à decisão no diagnóstico PEC em chapas de aço IF. Verificou-se que o classificador apresentou um desempenho superior quando alimentado com conjuntos de dados derivados da DFT. No entanto, ao aplicar a PCA a esses sinais, observou-se uma redução no desempenho do GBDT. Em contrapartida, o uso da LDA demonstrou um aumento no desempenho do algoritmo, tanto para os sinais PEC quanto para os sinais da DFT. Portanto, as características extraídas dos sinais FFT, em conjunto com a LDA, proporcionaram uma diferenciação mais clara entre as classes, tornando-as mais facilmente distinguíveis e facilitando o processamento do algoritmo. Com o método proposto, foi obtida uma acurácia de até 85,28% e um *F1-score* de 84,91% na identificação das classes de interesse.

Em conclusão, este trabalho oferece uma análise preliminar que valida a hipótese de classificação dos sinais, porém a rede não apresenta uma configuração ótima, no que se refere a classificação de falhas em peças que podem ter impactos na segurança se não forem devidamente detectadas. Como perspectivas futuras, há o interesse em investigar novas metodologias para extrair informações dos sinais de correntes parasitas pulsadas, o que poderá aumentar ainda mais a relevância na busca pelo melhor algoritmo de aprendizado de máquina. A análise dos sinais que apresentam confusões entre classes pode revelar características que, por meio de tratamentos específicos com técnicas de processamento digital de sinais, aprimorem o desempenho na classificação. Além disso, visa-se a implementação do sistema de classificação em um dispositivo portátil, permitindo a realização da inspeção em campo. Essas abordagens ampliariam as opções de algoritmos e proporcionariam maior mobilidade e praticidade no processo de diagnóstico PEC em chapas de aço IF. Tais investigações visam aprimorar ainda mais a eficiência e aplicabilidade desse sistema de apoio à decisão.

AGRADECIMENTOS

Os autores deste artigo expressam seus agradecimentos ao CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo financiamento parcial para este trabalho.

REFERÊNCIAS

- [1] A. F. Oliveira. “Caracterização de um aço IF após a relaminação no laminador de encruamento”. Dissertação de Mestrado. Universidade de São Paulo, 2010.
- [2] A. B. Norcino. “Uma contribuição ao estudo das tensões residuais no fresamento”. Dissertação de Mestrado. Universidade Estadual Paulista, 2013.
- [3] J. Heingärtner, M. Born e P. Hora. “Online acquisition of mechanical material properties of Sheet metal for the prediction of product quality by eddy current”. 10th European Conference on NDT, vol. 1, 2010.
- [4] C. Wunderlich, C. Tschöpe e F. Duckhorn. “Advanced methods in NDE using machine learning approaches.. 44th Annual Review of Progress in Quantitative Nondestructive Evaluation, AIP Conference Proceedings 1949, 020022, vol. 37, 2018.
- [5] A. Niccolai *et al.* “Machine learning-based detection technique for NDT in industrial manufacturing. Mathematics, vol. 1251(9), pp. 1 - 16, 2018.
- [6] G. F. da Silva, *et al.* “Constrained neural classifier training method for flaw detection in industrial pipes using particle swarm optimisation.” *Int. J. Innovative Computing and Applications*, vol. 13, no. 3, pp. 150–160, 2022.

- [7] M. M. Silva *et al.* "Intelligent embedded system for decision support in pulsed eddy current corrosion detection using Extreme Learning Machine". *Measurement*, 110069, vol. 185, 2021.
- [8] L. Kaiyu *et al.* "Estimation method of mechanical properties of ferromagnetic materials based on pulsed eddy current.". *Russian Journal of Nondestructive Testing*, v. 57(2), p. 170–179, 2021.
- [9] C. B. Larocca *et al.*, "Classificação de tensões em chapas de Aço IF utilizando aprendizado de máquina aplicado a sinais de correntes parasitas pulsadas", in *XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT 2022*, September 25-28, 2022, Santa Rita do Sapucaí, MG.
- [10] L. Marple, "Computing the Discrete-Time Analytic Signal via FFT," *IEEE Transactions on Signal Processing*, vol. 47, no. 9, pp. 2600–2603, 1999. doi:10.1109/78.782222
- [11] F. Anowar, S. Sadaoui e B. Selim. "Conceptual and empirical comparison of dimensionality reduction algorithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA, t-SNE)". *Computer Science Review*, 100378, vol. 40, 2021.
- [12] Z. Chen, C. Jomdecha e S. Xie. "Eddy Current Testing". *Handbook of Advanced Nondestructive Evaluation*, Springer International Publishing, pp. 645-728, 2019.
- [13] V. Arjun *et al.* "Optimisation of pulsed eddy current probe for detection of sub-surface defects in stainless steel plates". *Sensors and Actuators A: Physical*, vol. 226, pp. 69-75, 2015.
- [14] A. Sophian, G. Tian e M. Fan. "Pulsed eddy current non-destructive testing and evaluation: A review". *Chinese Journal of Mechanical Engineering*, vol. 30, pp. 500-514, 2017.
- [15] M. Fan *et al.* "Frequency optimization for enhancement of surface defect classification using the eddy current technique". *Sensors*, vol. 649, 2016.
- [16] K. Alsabti, S. Ranka e V. Singh. "Clouds: A decision tree classifier for large datasets.". *Proceedings of the 4th Knowledge Discovery and Data Mining Conference*, pp. 2–8, 1998.
- [17] D. Wang, Y. Zhang, e Y. Zhao, "Lightgbm: An effective miRNA classification method in breast cancer patients.". *International Conference on Computational Biology and Bioinformatics*, pp. 7–11, 2017.
- [18] G. Ke *et al.* "A Highly Efficient Gradient Boosting Decision Tree.". *AI Communications, Advances in Neural Information Processing Systems* 30, pp. 3149-3157, 2017.
- [19] LightGBM Documentation: <https://lightgbm.readthedocs.io/en/latest/Features.html#references>
- [20] J. Bergstra and Y. Bengio, "Random search for hyper-parameter optimization", *Journal of Machine Learning Research*, vol. 13, no. Feb, pp. 281-305, 2012.
- [21] A. Tharwat *et al.* "Linear discriminant analysis: A detailed tutorial". *AI Communications*, vol. 30, pp. 169–190, 2017.
- [22] J. Snoek, H. Larochelle, and R. P. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms", in *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 2012.
- [23] B. Shahriari *et al.*, "Taking the Human out of the Loop: A Review of Bayesian Optimization", in *Proceedings of the 26th Conference on Artificial Intelligence*, 2016.
- [24] E. Brochu, V. M. Cora, and N. de Freitas, "A Tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning," in *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*, 2010.