

# Classificação de tensões em chapas de Aço IF utilizando aprendizado de máquina aplicado a sinais de correntes parasitas pulsadas

Camilla B. Larocca, Vitor R. de Britto, Eduardo F. de Simas Filho,  
Ygor T. B. Santos, Ivan C. da Silva, Claudia T. T. Farias e Maria C. S. Albuquerque

**Resumo**—Aços IF são empregados na fabricação de peças na indústria automobilística. Ao serem transportados e armazenados em forma de bobinas, suas propriedades mecânicas estão sujeitas a alterações por ação das tensões residuais intensificadas pelo próprio peso, o que pode gerar falhas. Este trabalho pretende classificar amostras de aço IF a partir da posição onde elas foram extraídas de uma bobina de armazenamento. Para isso, foram adquiridos sinais de correntes parasitas pulsadas das amostras e técnicas de aprendizado de máquina foram utilizadas para classificação. Com o método proposto, foi obtida uma acurácia de até 86,10% na identificação das classes de interesse.

**Palavras-Chave**—Aço IF, Correntes Parasitas Pulsadas, SVM, LightGBM, LDA, PCA.

**Abstract**—IF steels are used in the manufacture of components in the automotive industry. When transported and stored in coil form, their mechanical properties are subject to changes due to residual stresses intensified by their own weight, which can cause failures. This work aims to classify IF steel samples according to the position where they were extracted from a storage coil. To accomplish this goal, pulsed eddy currents signals were acquired from specimens and machine learning techniques were used to perform the classification. Using the proposed method, an accuracy up to 86.10% was obtained in identifying the classes of interest.

**Keywords**—IF Steel, Pulsed Eddy Current, SVM, LightGBM, LDA, PCA.

## I. INTRODUÇÃO

Os aços IF (do inglês “*interstitial-free*”) são amplamente empregados na indústria automobilística. São utilizados na manufatura de peças da carroceria com geometrias complexas, tais como para-lama, tampa de porta-malas, assoalho do porta-malas e nas partes internas das portas dianteiras e traseiras. Sua extensa aplicação na indústria ocorre, principalmente, por conta das suas características mecânicas. Devido ao baixo teor de elementos como carbono e nitrogênio em sua composição, tipicamente <0,0030%, o aço apresenta características como elevada conformabilidade, boa resistência mecânica e soldabilidade e baixa susceptibilidade ao envelhecimento quando comparados aos aços anteriormente utilizados na indústria, conhecidos como aço baixo carbono [1].

Camilla B. Larocca, Vitor R. de Britto, e Eduardo F. de Simas Filho estão no Laboratório de Sistemas Digitais - DEEC, Universidade Federal da Bahia, Salvador-BA, e-mails: camilla.larocca@ufba.br, vitorrb@ufba.br e eduardo.simas@ufba.br; Ygor T. B. Santos, Ivan C. da Silva, Claudia T. T. Farias e Maria C. S. Albuquerque estão no GPEND, Instituto Federal da Bahia.

O transporte e armazenamento da chapa do aço IF ocorre no formato de bobinas, sendo constantemente submetido às cargas adicionais, resultantes do próprio peso. Como consequência, tensões residuais podem se intensificar no material e alterar algumas propriedades mecânicas. Estas tensões podem influenciar certas características, como a vida em fadiga, resistência à corrosão e ao desgaste. A problemática das tensões residuais possui ainda como agravante o fato de, na maioria das vezes, permanecerem incógnitas, além de reprimir ou acelerar o início de uma deformação plástica nas camadas superficiais ou sub-superficiais do material [2]. Visto que o material é submetido a processos de conformação mecânica com parâmetros pré-estabelecidos para condições ideais da liga, a identificação de tensões residuais fora do intervalo de tolerância é um importante passo na prevenção de falhas na estampagem.

Para melhorar a qualidade da produção das peças, é necessário eliminar ou compensar as variações das propriedades do aço IF. Há duas formas de atingir este objetivo: classificando o material como inaplicável à produção ou ajustando os parâmetros da produção em relação as propriedades do material atual. Atualmente, a forma convencional para identificação de tensões residuais envolve modelagem matemática ou técnicas de medição no próprio material, a partir de métodos destrutivos e não destrutivos. As técnicas destrutivas alteram a distribuição das tensões residuais, a partir da retirada de camadas ou usinagem da peça. Já as técnicas não destrutivas analisam as relações entre as propriedades físicas ou cristalográficas do material e as tensões residuais.

Em pesquisas associadas à área industrial, as técnicas de inteligência computacional têm sido empregadas extensivamente para processamento de sinais, extração de características e localização de funções [3]. A combinação de técnicas não destrutivas com algoritmos de aprendizado de máquinas tem sido extremamente atraente no desenvolvimento de novas aplicações, como algoritmos de pré-processamento e compressão de sinais, reconhecimento de padrões de análise, classificação e agrupamento de sinais [4], [5]. Uma técnica não destrutiva que vem se destacando para a caracterização de materiais metálicos é a inspeção por correntes parasitas pulsadas (do inglês “*Pulsed Eddy Currents*” - PEC) [6], [7].

Aliando o uso de um dos aços mais utilizados na fabricação de chassis e latarias da indústria automobilística com uma das técnicas magnéticas emergentes de inspeção não destrutiva, este trabalho busca comparar os resultados de dois algoritmos de aprendizado de máquina na classificação de diferentes

condições da amostra a partir de um conjunto restrito de sinais extraídos com a técnica PEC, com o auxílio de métodos de transformação de sinais e extração de características. Os resultados obtidos indicaram a eficiência do método proposto.

## II. FUNDAMENTAÇÃO TEÓRICA

### A. Correntes Parasitas Pulsadas

A técnica de correntes parasitas é um ensaio não destrutivo baseado no princípio da indução eletromagnética e correntes de Foucault e utilizada na inspeção de materiais metálicos. A corrente alternada, que flui através de uma bobina de teste, produz um campo magnético alternado de densidade de fluxo  $B$ . O fluxo magnético total ( $\phi_p$ ) contido dentro da bobina é o produto de  $B$  pela área da bobina. Ao aproximar a bobina de teste de um material metálico, o campo eletromagnético gerado irá induzir correntes circulares que fluem em planos paralelos às espiras da bobina. Estas correntes parasitas induzidas irão gerar um campo magnético secundário, que se opõe ao campo magnético primário. Dessa forma, o fluxo magnético induzido ( $\phi_s$ ) se opõe ao fluxo magnético primário, conforme Figura 1. A interação entre os dois campos resulta em uma força eletromotriz que irá influenciar a bobina, ocasionando uma mudança aparente de sua impedância [8]. Esta mudança ocorre devido as variações nas propriedades elétricas, magnéticas e geométricas do material.




Fig. 1. Diagrama do princípio do teste por corrente parasita, adaptado de [8].

A técnica de correntes parasitas pulsadas utiliza um espectro contínuo de frequências, onde repetitivos pulsos de ondas quadradas de curta duração irão excitar a bobina [9]. Esta configuração potencializa as informações sobre as condições do teste, possibilitando uma maior sensibilidade. Caso haja alguma alteração na microestrutura ou falhas mecânicas no material, o campo também sofrerá variações, dado que essas características são altamente correlacionadas à condutividade elétrica, permeabilidade magnética ou disposição do campo magnético [10].

A análise da resposta de PEC é feita, na grande maioria dos casos, no domínio do tempo, onde o foco é a avaliação do formato da curva-resposta e sua variação. Com o avanço computacional, análises envolvendo a associação entre o domínio do tempo e da frequência e algoritmos de processamento de sinais para extração e definição de novos parâmetros se tornaram possíveis. Essas novas configurações, associadas às

técnicas de aprendizagem de máquinas, fornecem uma ampla gama de informações relacionadas a defeitos entre camadas, propriedades magnéticas, perda de material, diferenças de *lift-off*, entre outros [11].

### B. Máquina de vetores de suporte

Máquina de vetores de suporte (do inglês “*Support Vector Machine*” - SVM) é uma técnica de aprendizado de máquina cuja finalidade é separar duas ou mais classes através de uma função obtida a partir dos exemplos conhecidos na fase de treinamento. Seu objetivo é mapear a amostra de entrada em um espaço de características de  $n$  dimensões e encontrar um hiperplano ótimo com margem máxima entre os pontos mais próximos de cada classe que minimize o erro de reconhecimento [12], [13].

A complexidade do treinamento da SVM é altamente dependente do tamanho do conjunto de dados de entrada [14] e seu desempenho está diretamente relacionada à escolha de uma função denominada *Kernel*, do parâmetro de penalidade  $C$  e do parâmetro  $\gamma$ . O parâmetro  $C$  controla o balanço entre os valores classificados incorretamente e a maximização de margem ao hiperplano. Com um parâmetro  $C$  maior, obtém-se uma margem de maior valor, que pode gerar uma alta penalidade para os pontos não separáveis ou um aumento na quantidade de vetores-suporte usados para construir a função de decisão. O parâmetro  $\gamma$  está presente na função de alguns *Kernels* e é um hiperparâmetro que define a curvatura em um limite de decisão. Em relação aos *Kernels*, aqueles frequentemente utilizados são o base radial, linear, polinomial e sigmoide [15].

A SVM vem sendo utilizada por pesquisadores para a identificação, classificação e quantificação de defeitos na área de ensaios não destrutivos [16], [17]. Adicionalmente, existem diversos estudos na área que demonstram uma alta taxa de sucesso quando combinados à técnica PEC [18].

### C. Light Gradient Boosting Machine - LightGBM

O *LightGBM* é um algoritmo de código aberto que utiliza árvores de decisão com reforço de gradiente (do inglês *Gradient boosting decision trees*- GBDT) [19]. Com ele é possível acelerar o treinamento, reduzir o consumo de memória e combinar diferentes redes para maximizar o aprendizado paralelo, conhecido como algoritmo de árvore de decisão de votação paralela [20]. Devido à sua eficiência, precisão e interpretabilidade, o GBDT alcança alto desempenho em muitas tarefas de aprendizado de máquina, como classificação multiclasse e predição [21].

O *LightGBM* divide a árvore folha por folha, ao contrário de outros algoritmos de GBDT que desenvolvem a árvore por nível [22]. 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 [21]. Assim, a estrutura continua a crescer com os ramos e folhas mais promissoras, isto é, nós com a maior perda, mantendo constante o número de folhas de decisão. Em conjuntos de dados limitados, o desenvolvimento em que se utiliza o crescimento

por folha pode aumentar a complexidade do modelo e levar ao sobreajuste [21]. É possível encontrar mais detalhes sobre o tipo de crescimento por folha do *LightGBM* na própria documentação, disponível em [22].

Para se evitar o sobreajuste, faz-se necessário modificar os parâmetros ajustáveis do modelo, também conhecidos como hiperparâmetros. Com isso, é comum serem utilizadas técnicas para a otimização desse ajuste, tais como a busca em grade (do inglês *Grid Search*) e a busca aleatória (do inglês *Random Search*), de tal forma a encontrar a configuração mais promissora que resulte no melhor desempenho para o modelo.

#### D. Métodos de redução de dimensionalidade

Os métodos de extração de características tem como objetivo a estimação de informações relevantes que estavam ocultas no conjunto de dados original. Tais métodos são utilizados em etapas de pré-processamento, na preparação do conjunto de entrada para os algoritmos de aprendizado de máquinas. A Análise de Componentes Principais e Análise Discriminante Linear são exemplos de técnicas lineares de extração de características que se destacam na literatura [23].

1) *Análise de Componentes Principais*: do inglês *Principal component Analysis* - PCA [24], é uma técnica não supervisionada que visa preservar a reprodução das informações contidas nos dados originais. É utilizada para analisar as relações entre um grande número de variáveis e, a partir de transformações lineares, criar um conjunto de elementos não correlacionados que retenham a maior parte do arranjo de variabilidade (no sentido do erro médio quadrático de reconstrução) e correlação da matriz de dados iniciais.

2) *Análise Discriminante Linear*: do inglês “*Linear Discriminant Analysis*” - LDA [24], é uma técnica supervisionada, também utilizada para classificação e visualização de dados, cujo objetivo é encontrar uma combinação linear de características que descrevem ou separam duas ou mais classes de objetos ou eventos.

### III. MATERIAL E MÉTODOS

Três chapas com dimensões de  $1530 \times 1175$  mm foram retiradas de diferentes posições em uma bobina de aço: uma no início da bobina, uma no meio e uma chapa no final. Esta bobina é utilizada na fabricação das peças na linha de produção e exemplifica as condições do material como recebido para estampagem. Em cada chapa, três amostras com dimensões de  $300 \times 300$  mm foram extraídas. As nove amostras foram identificadas e cedidas por uma montadora de automóveis e utilizadas como corpos de prova.

Em cada amostra, foram coletados 51 sinais, utilizando a técnica PEC em posições aleatórias, resultando em 153 sinais para cada condição: início, meio e final da bobina, e representam amostras que sofreram, respectivamente, baixa, média e alta compressão durante o transporte e armazenamento. No total, 459 sinais serviram como o conjunto de dados para desenvolvimento deste trabalho.

O sistema experimental utilizado consiste em uma sonda composta por uma bobina geradora de campo magnético e um sensor GMR (*Giant Magneto-Resistance*). A bobina foi

alimentada por um gerador de função, ajustado para produzir um pulso de onda quadrada de 12 V, com uma frequência de 100 Hz e *Duty cycle* de 50%. A resposta magnética, lida pelo sensor GMR foi digitalizada com uma frequência de amostragem de 200 KHz e 12 bits de quantização. Ao final, cada assinatura PEC foi gravada com 2500 amostras temporais. O diagrama do processo experimental é mostrado na Figura 2.




Fig. 2. Diagrama do processo experimental.

A Transformada Discreta de Fourier (*Discrete Fourier Transform* - DFT) foi aplicada ao conjunto de entrada para avaliação do domínio da frequência, resultando em um segundo conjunto de dados de treinamento. O primeiro, formado pelos sinais de PEC sem processamento conforme descrito anteriormente e o segundo, contendo os primeiros 1250 coeficientes da DFT.

Posteriormente, foi aplicado aos dois conjuntos de dados a PCA e a LDA. Para a PCA, foram escolhidos 220 componentes para o conjunto de sinal PEC e 365 componentes para o conjunto DFT. Os resultados mostram uma confiabilidade de 95,00% e 94,84%, e uma redução de 91,20% e 70,78% do tamanho das amostras, respectivamente. No final, obteve-se um total de 6 conjuntos de dados. O diagrama do processo é mostrado na Figura 3.

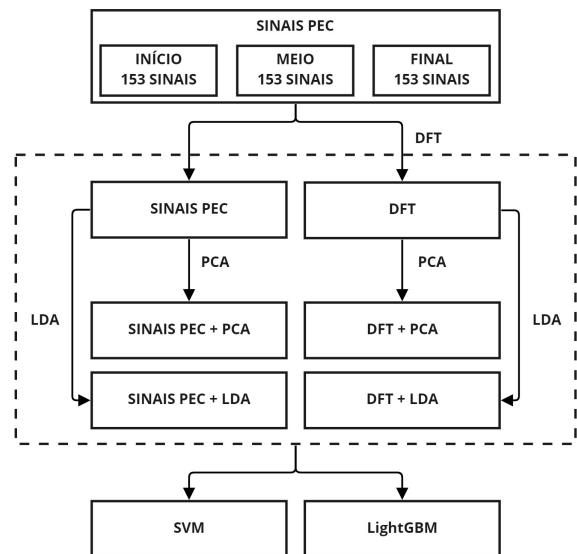


Fig. 3. Diagrama da geração dos conjuntos de dados de entradas dos algoritmos.

Os classificadores SVM e *LightGBMClassifier* foram utilizados no estudo devido a sua robustez em serem treinados com número restrito de exemplos de cada classe. Deste modo, as assinaturas foram divididas em uma relação de 80%, destinados ao treino e 20%, destinados ao teste. Não foi considerado um conjunto para validação devido ao número reduzido de dados. Para o SVM, foram realizadas 200 reinicializações da rede para cada configuração, variando o *Kernel* entre base radial, linear, polinomial e sigmoide e o parâmetro C, para os valores de  $10^{-4}$ ,  $10^{-3}$ ,  $10^{-2}$ ,  $10^{-1}$ , 1, 10,  $10^2$ ,  $10^3$ ,  $10^4$ ,  $10^5$ .

O classificador *LightGBMClassifier* foi desenvolvido com a mesma relação de treino/teste definida para o classificador SVM. Foi realizado um procedimento de busca aleatória por otimização Bayesiana de hiperparâmetros, variando-se: *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, com 200 reinicializações. Nesse sentido, os grupos foram comparados nos termos da média da acurácia e do F1-score das 200 inicializações para os dois classificadores.

#### IV. RESULTADOS E DISCUSSÃO

Em relação às diferentes inicializações de treinamento utilizando a SVM, a Tabela I apresenta a melhor configuração de máquina para cada cadeia de pre-processamento, considerando os conjuntos de teste.

TABELA I

MÉDIA DAS ACURÁCIAS E F1-SCORE PARA SVM.

Entrada	Acurácia (%)	F1-score (%)	Parâmetros
PEC	63,83 ± 0,30	63,80 ± 0,31	Base Radial, C=10 <sup>2</sup> , $\gamma=1$
DFT	69,72 ± 0,27	69,75 ± 0,27	Linear, C=10
PEC + PCA	52,49 ± 0,32	52,33 ± 0,32	Linear, C=10 <sup>-3</sup>
DFT + PCA	67,67 ± 0,32	67,35 ± 0,33	Sigmoide, C=1, $\gamma = 1$
PEC + LDA	81,13 ± 0,23	81,11 ± 0,23	Linear, C=10 <sup>-2</sup>
DFT + LDA	86,10 ± 0,25	86,08 ± 0,25	Linear, C=10 <sup>5</sup>

Utilizando diretamente os sinais PEC, a melhor acurácia foi de 63,83% com o *Kernel* de base radial, apresentando um F1-score de 63,80%. Após a redução da dimensionalidade do conjunto de entrada com o PCA, a melhor configuração do conjunto PEC + PCA apresentou uma redução da acurácia para 52,49% e do F1-score para 52,33% com o *Kernel* Linear. Em contrapartida, com a utilização do LDA, os valores da acurácia e do F1-score aumentaram, atingindo resultados de 81,13% e 81,11%, respectivamente, com um *Kernel* Linear. O conjunto de dados de entrada dos sinais PEC após a DFT apresenta um comportamento semelhante. Para o conjunto de entrada DFT, a melhor configuração apresentou uma acurácia de 69,72% e F1-score de 69,75%, utilizando um *Kernel* Linear. Após a redução de dimensionalidade do conjunto de entrada com o PCA, as métricas do conjunto PEC + PCA novamente reduziram, atingindo resultados de 67,67% para a acurácia, e 67,35% para o F1-score, com o *Kernel* Sigmoide. Em contrapartida, com a utilização do LDA no conjunto de entrada, os valores de acurácia e F1-score aumentaram, atingindo o melhor resultado

da SVM, com 86,10% e 86,08% respectivamente, com um *Kernel* Linear.

TABELA II

MÉDIAS DAS ACURÁCIAS E F1-SCORE PARA LIGHTGBM.

Entrada	Acurácia (%)	F1-score(%)	Parâmetros
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

A Tabela II apresenta os melhores arranjos de hiperparâmetros para cada conjunto de teste, no que se refere ao *LightGBMClassifier*. O conjunto de entrada dos sinais PEC, sem processamento, apresentou acurácia de 30,85% e F1-score de 17,98%. Após a aplicação da PCA no conjunto de sinais PEC, as métricas apresentaram um aumento, atingindo 40,29% de acurácia média e 35,87% de F1-score médio. A aplicação da LDA a esse mesmo conjunto de dados iniciais possibilitou, novamente, um aumento da acurácia e do F1-score, atingindo os valores de 72,10% e 69,95% respectivamente. Para o grupo de sinais de entrada PEC com a aplicação da DFT, a acurácia atingida foi de 73,42% e o F1-score de 70,28%. Em divergência ao conjunto de dados PEC após a aplicação da PCA, no conjunto DFT + PCA houve uma redução nos valores da acurácia e do F1-score, o que fez tais médias lograrem os valores de 67,96% e 63,89%, na devida ordem. Em contrapartida, ao se empregar a LDA no grupo de sinais de entrada DFT, as métricas obtiveram um aumento, alcançando então os resultados de maior acurácia média e F1-score para o *LightGBM*, de 85,28% e 84,91%, nesta ordem.

O classificador SVM teve acurácia média e F1-score médio superiores ao *LightGBMClassifier* para os conjuntos de entrada PEC, PEC + PCA, PEC + LDA e DFT + LDA. O classificador *LightGBM*, por sua vez, mostrou-se superior em termos de acurácia e F1-score médios para o grupo de entrada que utiliza o pré-processamento DFT. Para o conjunto DFT + PCA, ambas as redes apresentaram resultados semelhantes, tendo a SVM apresentado uma acurácia superior e o classificador

*LightGBM* apresentou um F1-score superior. Estes resultados apontam uma melhora na máquina classificadora ao se utilizar o pré-processamento DFT. De forma semelhante, podemos perceber um aumento relevante no desempenho dos algoritmos ao utilizarmos a LDA no conjunto de dados de entrada. Comparando os dois classificadores para os melhores casos, observa-se que com SVM foi possível atingir  $86,10 \pm 0,25\%$  de acurácia e  $86,08 \pm 0,25\%$  de F1-score em comparação a  $85,28 \pm 0,32\%$  de acurácia e  $84,91 \pm 0,34$  de F1-score da *LightGBM*.

		SVM					LightGBM		
		CLASSE PREDITA					CLASSE PREDITA		
CLASSE REAL		INÍCIO	MEIO	FINAL	CLASSE REAL		INÍCIO	MEIO	FINAL
	INÍCIO	0,93	0,07	0,00		INÍCIO	0,92	0,03	0,05
	MEIO	0,03	0,94	0,03		MEIO	0,03	0,84	0,13
	FINAL	0,00	0,03	0,97		FINAL	0,08	0,00	0,92

Fig. 4. Matriz de confusão da melhor inicialização de cada classificador.

A Figura 4 apresenta as matrizes de confusão com as melhores inicializações do SVM e do LightGBM para a entrada DFT + LDA, tendo em vista o conjunto de melhor desempenho em acurácia e F1-score. A rede do SVM possui uma taxa total de acerto de 94,67%, ao passo que a rede do LightGBM obteve um percentual total de assertividade de 89,33%. Analisando as duas matrizes, verifica-se que as classes “Início” e “Final” são mais distintas entre si, visto que foram retiradas de dois extremos da bobina, enquanto a classe “meio” apresenta uma situação intermediária entre as classes.

## V. CONCLUSÕES

A utilização de Máquinas de Vetores de Suporte e *LightGBM* foram avaliados e comparados para apoio à decisão no diagnóstico PEC em chapas de aço IF. Os classificadores apresentaram um desempenho superior quando alimentadas pelos conjuntos de dados provenientes da DFT. Com a adição de métodos de redução de dimensionalidade, o SVM apresentou uma redução de desempenho com o PCA enquanto o desempenho do *LightGBM* irá depender do conjunto de dados base submetido a PCA. Adicionalmente, os dois algoritmos apresentaram um aumento do desempenho com a utilização do LDA. A cadeia de processamento DFT + LDA apresentou os melhores resultados para os dois modelos, tendo a SVM apresentado uma acurácia e F1-score médios superiores. Em trabalhos futuros, pretende-se investigar a utilização de outros classificadores e a implementação do sistema de classificação em um dispositivo portátil, para realização da inspeção em campo.

## AGRADECIMENTOS

Os autores deste artigo agradecem ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico por financiar parcialmente 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] 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.
- [7] 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.
- [8] Z. Chen, C. Jomdecha e S. Xie. “Eddy Current Testing”. Handbook of Advanced Nondestructive Evaluation, Springer International Publishing, pp. 645-728, 2019.
- [9] 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.
- [10] 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.
- [11] M. Fan et al. “Frequency optimization for enhancement of surface defect classification using the eddy current technique”. Sensors, vol. 649, 2016.
- [12] R. F. F. Nascimento et al. “O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2”. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009.
- [13] J. K. Min, J. H. Hong e S. B. Cho. “Ensemble approaches of support vector machines for multiclass classification”. Ghosh A., De R.K., Pal S.K. (eds) Pattern Recognition and Machine Intelligence. PRMI 2007. Lecture Notes in Computer Science, 2007.
- [14] J. Nalepa e M. Kawulok. “The Smaller, the Better: Selecting Refined SVM Training Sets Using Adaptive Memetic Algorithm”. Proceedings of the 2016 on Genetic and Evolutionary Computation Conference Companion - GECCO '16 Companion, 2016.
- [15] D. Kancherla, J. D. Bodapati e N. Veeranjeyulu. “Effect of Different Kernels on the Performance of an SVM Based Classification”. International Journal of Recent Technology and Engineering, vol. 7, 2019.
- [16] H. Taheri, M. G. Bocanegra e M. Taheri. “Artificial Intelligence, Machine Learning and Smart Technologies for Nondestructive Evaluation”. Sensors, vol. 22(11):4055, 2022.
- [17] R. V. Patil e Y. P. Reddy. “An Autonomous Technique for Multi Class Weld Imperfections Detection and Classification by Support Vector Machine. Journal of Nondestructive Evaluation, vol. 40, n. 76, 2021.
- [18] H. Jin et al. “Defect Recognition and Classification Techniques for Multi-layer Tubular Structures in Oil and Gas Wells by Using Pulsed Eddy Current Testing”. Gelman, L., Martin, N., Malcolm, A.A., (Edmund) Liew, C.K. (eds) Advances in Condition Monitoring and Structural Health Monitoring. Lecture Notes in Mechanical Engineering. Springer, Singapore, pp. 499-508, 2021.
- [19] 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.
- [20] 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.
- [21] G. Ke et al. “A Highly Efficient Gradient Boosting Decision Tree.”. AI Communications, Advances in Neural Information Processing Systems 30, pp. 3149-3157, 2017.
- [22] LightGBM Documentation: <https://lightgbm.readthedocs.io/en/latest/Features.html#references>
- [23] A. Tharwat et al. “Linear discriminant analysis: A detailed tutorial”. AI Communications, vol. 30, pp. 169–190, 2017.
- [24] 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.