

Detecção de Corrosão em Tubulações Industriais Utilizando Correntes Parasitas Pulsadas e Rede Neural Convolutacional 1D

Ademário José de Carvalho Neto
Programa de Pós Graduação em
Engenharias Elétrica e de Computação
Universidade Federal da Bahia (UFBA)
Salvador - BA, Brasil
ademario.neto@ufob.edu.br

Lucas Fialho Xavier
Laboratório de Máquinas Elétricas
Universidade F. do Oeste da Bahia
Bom Jesus da Lapa - BA, Brasil
lucas.x2091@ufob.edu.br

Manoel Messias Silva Júnior
Laboratório de Máquinas Elétricas
Universidade F. do Oeste da Bahia
Bom Jesus da Lapa - BA, Brasil
manoel.messias@ufob.edu.br

Eduardo F. Simas Filho
Programa de Pós Graduação em
Engenharias Elétrica e de Computação
Universidade Federal da Bahia (UFBA)
Salvador - BA, Brasil
eduardo.simas@ufba.br

Paulo C. M. A. Farias
Programa de Pós Graduação em
Engenharias Elétrica e de Computação
Universidade Federal da Bahia (UFBA)
Salvador - BA, Brasil
paulo.farias@ufba.br

Maria C. S. Albuquerque
Laboratório de Inspeção Não Destrutiva
Instituto Federal de Educação, Ciência e
Tecnologia da Bahia
Salvador - BA, Brasil
cleaalbuquerque@ifba.edu.br

Ivan C. Silva
Laboratório de Inspeção Não Destrutiva
Instituto Federal de Educação, Ciência e
Tecnologia da Bahia
Salvador - BA, Brasil
ivanslv@gmail.com

Claudia T. T. Farias
Laboratório de Inspeção Não Destrutiva
Instituto Federal de Educação, Ciência e
Tecnologia da Bahia
Salvador - BA, Brasil
ct.farias@uol.com.br

Resumo—Neste trabalho é apresentado um sistema para classificação de defeitos em tubulações industriais, motivado pela necessidade e pelo desafio de aprimorar a inspeção não destrutiva em tubos de aço carbono revestidos com material compósito. A inspeção dessas tubulações é particularmente desafiadora, pois o revestimento dificulta o acesso direto ao tubo metálico. O objetivo é identificar três condições distintas: Sem Defeito, Defeito Interno e Defeito Externo — utilizando sinais obtidos pelo método de *Pulsed Eddy Current* (PEC) processados por uma rede neural convolutacional unidimensional (1D-CNN). O estudo envolveu: (a) a preparação de um corpo de prova especialmente usinado para emular diferentes níveis de corrosão; (b) a aquisição de dados a partir de sondas com sensores GMR; e (c) o treinamento de modelos CNN com técnicas de pré e pós-processamento, incluindo normalização, balanceamento e filtragem gaussiana. Os resultados demonstraram uma acurácia média de 95% na classificação, com destaque para a identificação precisa das regiões sem defeito e com defeito interno. A abordagem proposta mostrou-se promissora, destacando seu potencial para aumentar a confiabilidade e a eficiência de inspeções em ambientes industriais.

Index Terms— *Pulsed Eddy Current*, Redes Neurais Convolutacionais, Ensaios Não Destrutivos, Estruturas Industriais.

I. INTRODUÇÃO

Sistemas industriais são frequentemente submetidos a avaliações estruturais não destrutivas com o objetivo de prevenir a deterioração de ferramentas e equipamentos, contribuindo para o controle de qualidade, redução de custos e de paradas na produção, além da mitigação de riscos de acidentes [1].

As técnicas de correntes parasitas destacam-se em avaliações de estruturas metálicas. O método convencional, conhecido como *Eddy Current* (EC), utiliza um sinal senoidal de frequência única para excitação da sonda de teste [2]. Essa característica impõe limitações na avaliação de diferentes camadas do material inspecionado, pois a profundidade de penetração na estrutura depende diretamente da frequência de excitação da bobina. Por outro lado, o ensaio por correntes parasitas pulsadas (*Pulsed Eddy Current* – PEC) emprega um sinal de onda quadrada ou pulso quadrado para excitação [3]. Esse método proporciona um maior espalhamento espectral do sinal, resultando em uma banda larga de frequências, cuja extensão varia inversamente com a duração do pulso [4].

A avaliação da integridade dos materiais é realizada por meio de ferramentas de calibração baseadas em padrões de referência, que ajustam os parâmetros dos testes. Esse

procedimento é essencial, pois diferentes características e propriedades dos materiais podem influenciar sua permeabilidade magnética e condutividade elétrica [5]. Para estimar a espessura da parede de um material, os padrões de referência utilizados consistem em um conjunto de objetos com espessuras previamente conhecidas. A análise da resposta dos ensaios é feita por meio de parâmetros como amplitude e tempo do pico do sinal durante o ciclo de carga da bobina. Esse sinal de resposta é então comparado com um padrão de referência, determinado a partir de uma amostra com as mesmas características do material avaliado [6]. No entanto, a interpretação das medições ainda depende significativamente da experiência e habilidade técnica do operador, o que pode influenciar na precisão dos resultados.

Com a finalidade de auxiliar o operador na tomada de decisão, muitas pesquisas têm sugerido o uso de ferramentas de processamento de sinal e sistemas inteligentes [7], [8]. O processamento dos sinais de PEC tem se mostrado eficiente para extração de características relevantes de materiais condutores, como condições de corrosão, fissuras e outros atributos físicos [9]. Trabalhos recentes apresentam soluções envolvendo *Machine Learning* em dispositivos embarcados, auxiliando o inspetor em campo e disponibilizando uma ferramenta que contempla etapas de geração, aquisição e processamento dos sinais de inspeção por correntes parasitas [10]. Sistemas automáticos de detecção de rachaduras e corrosão usando redes neurais convolucionais 1D, também, são propostos na literatura [11]. O estudo realizado por [12] compara distintas configurações de técnicas de aprendizado de máquina voltadas à detecção de defeitos em chapas de aço inoxidável.

Diante do exposto, este trabalho tem como objetivo apresentar o desenvolvimento de um sistema automático de classificação capaz de identificar três condições distintas em tubos de aço carbono com revestimento compósito: Sem Defeito (SD), Defeito Externo (DE) e Defeito Interno (DI). Essas condições são representadas por defeitos usinados que emulam características típicas de corrosão. Para alcançar esse objetivo, foi empregado um modelo de rede neural convolucional unidimensional (1D-CNN), utilizado para extrair e analisar informações relevantes das assinaturas de sinal obtidas durante os ensaios com correntes parasitas pulsadas (PEC).

II. METODOLOGIA PROPOSTA

Neste trabalho, o controle da degradação de estruturas industriais é considerado essencial para a garantia da qualidade de serviços e equipamentos. Nesse contexto, a utilização de sistemas automáticos de classificação, capazes de fornecer respostas rápidas e eficientes durante inspeções por PEC, configura-se como uma ferramenta valiosa para essas aplicações [13]. Neste estudo, a técnica de correntes parasitas pulsadas foi utilizada para avaliar defeitos provocados por corrosão em tubos de aço carbono revestidos com material compósito. A Figura 1 apresenta uma visão geral da metodologia adotada neste trabalho. O processo envolve inicialmente a coleta de sinais gerados por excitação pulsada em uma sonda PEC, os quais foram digitalizados por um sistema de aquisição

de dados (DAQ) e posteriormente utilizados nas etapas de processamento. O módulo de processamento é composto por três blocos principais: (i) pré-processamento, com aplicação da Análise de Componentes Principais (PCA); (ii) classificação dos sinais utilizando uma Rede Neural Convolucional unidimensional (CNN 1D) e (iii) suavização das saídas da rede por meio de um filtro Gaussiano. Ao final desse fluxo, são geradas informações organizadas para apoio ao diagnóstico, indicando a condição do material inspecionado: sem defeito, com defeito externo ou com defeito interno.




Figura 1. Diagrama geral da metodologia adotada.

A seguir são descritas em detalhes as etapas representadas no diagrama, com ênfase na montagem experimental, no modelo de classificação e no tratamento das saídas.

Os defeitos avaliados (DI e DE) foram produzidos por meio de usinagem (fresamento), assegurando o controle preciso da espessura de parede desejada. Na preparação do corpo de prova, diferentes espessuras foram obtidas de modo a representar variados estágios do processo corrosivo.

Para o modelo de CNN 1D desenvolvido neste trabalho, foram aplicadas técnicas de refinamento, incluindo etapas de pré e pós-processamento, seguidas da análise dos resultados que alcançaram maior precisão. Com base na matriz de confusão e nas métricas de avaliação, foram gerados três conjuntos principais de resultados. Esses, refletem variações em parâmetros da rede neural, como o número de épocas e o tamanho do lote. Além da matriz de confusão, foram calculadas métricas complementares de desempenho, como acurácia, precisão e F1-Score, para avaliar a qualidade da classificação.

A. Montagem Experimental

O ensaio por correntes parasitas pulsadas foi realizado aplicando-se um sinal de onda quadrada, com amplitude de 4 V, frequência de 1 kHz e *duty cycle* de 40%, o que corresponde a 40 ms de sinal de alto nível em cada período. Foram utilizados dois sensores Magnetoresistivo Gigante (*Giant Magnetoresistive* – GMR) para detecção das respostas dos sinais de PEC. Um sensor de referência e outro de medição, sendo que esse último fica localizado mais próximo da superfície de inspeção. Essa configuração é tradicionalmente utilizada, pois é comum fazer uso do sinal diferencial para análise dos materiais. Para aplicação nesse trabalho foi considerado os sinais capturados pelo sensor de medição.

A Figura 2 mostra a seção transversal do tubo com suas dimensões e as características dos defeitos. Para a realização do teste de PEC foi utilizada uma sonda com diâmetro externo de 20 mm, diâmetro interno de 10 mm, altura de 15 mm, diâmetro do fio de 0,27 mm e 500 voltas. Os dados foram adquiridos utilizando resolução de 12 bits, taxa de amostragem

Tabela I
INFORMAÇÕES SOBRE AQUISIÇÃO DOS SINAIS PEC.

Resolução do ADC	12 bits
Intervalo de amostragem	5×10^{-6} s
Frequência de Amostragem	200 kHz
Amostras no tempo	200
Exemplos da Classe SD	100
Exemplos da Classe DI	100
Exemplos da Classe DE	100

de 200 kHz e um conjunto de 100 registros por classe, conforme ilustrado na Tabela I.




Figura 2. Ilustração com as dimensões do corpo de prova utilizado: (a) Seção transversal, onde a área hachurada indica a parte metálica do tubo e a região escura ilustra o revestimento compósito (b) Vista 3D sem o isolamento mostrando o defeito externo [5].

Durante a aquisição de dados, a sonda é deslocada manualmente ao longo da região de interesse. As amostras são digitalizadas a uma taxa de 200 kS/s e armazenadas em um *buffer* circular duplo. Um controlador de Acesso Direto à Memória (*Direct memory access* - DMA) realiza a transferência dos sinais digitalizados pelo ADC diretamente para a memória, minimizando a intervenção do processador. A Figura 3 representa a montagem experimental realizada para aquisição dos dados.

B. Sistema de Classificação

A rede neural convolucional é amplamente utilizada em aplicações que envolvem dados bidimensionais e tridimensionais, entretanto, também é aplicável à análise de dados unidimensionais. No contexto deste trabalho, voltado para a análise de dados temporais, a convolução bidimensional é substituída por uma convolução unidimensional, que opera com vetores em vez de matrizes. Dessa forma, a *Convolutional Neural Networks* (CNN) 1D foi empregada para extrair informações dos sinais temporais por meio dos filtros aplicados em suas camadas convolucionais [14].

A Figura 4 apresenta as principais etapas de processamento das informações avaliadas durante o ensaio PEC. Inicialmente, técnicas de normalização, balanceamento e *Principal Component Analysis* (PCA) foram usadas para melhorar a




Figura 3. Ilustração da montagem experimental realizada.

representação dos dados. O método *Synthetic Minority Over-sampling Technique* foi usado para balanceamento das classes, minimizando a desproporção entre as amostras. Os rótulos das classes foram preparados por meio da codificação *One-Hot Encoding*, assegurando que o modelo interpretasse corretamente as categorias durante o treinamento.




Figura 4. Diagrama básico da estrutura CNN que foi implementada nesse trabalho.

A arquitetura da rede neural convolucional foi projetada para extrair padrões relevantes das amostras processadas. Após o tratamento dos dados, o modelo aplica duas camadas convolucionais unidimensionais (Conv1D) com 64 e 32 filtros, respectivamente, ambas ativadas pela função de ativação ReLU. Essas camadas são responsáveis por capturar as características espaciais dos sinais de entrada [16]. Em seguida, os dados são achatados (*Flatten*) e inseridos em uma camada densa com 256 neurônios e regularização L2, visando reduzir o sobreajuste. Para aprimorar a generalização, uma camada de *Dropout* foi configurada com uma taxa de 55%. O modelo prossegue com uma camada densa de 64 neurônios antes de fornecer a saída, que utiliza a função softmax para classificação multiclasse. A otimização do modelo foi realizada com o algoritmo Adam, empregando uma taxa de aprendizado de 0,001 e a função de perda *Huber*, garantindo maior estabilidade no treinamento.

A escolha por uma arquitetura baseada em camadas convolucionais unidimensionais justifica-se por sua eficiência na extração de padrões locais relevantes em sequências de dados, como séries temporais ou sinais unidimensionais [17]. Para definir os parâmetros do modelo, avaliou-se seu desempenho

com base na acurácia e na função de perda, monitorando-se o comportamento de convergência durante o treinamento e a validação. Esse procedimento foi repetido com diversas configurações da rede neural, permitindo identificar os parâmetros mais adequados para o sistema implementado [18].

Como etapa final do sistema de classificação, foi aplicado um filtro Gaussiano unidimensional com o objetivo de atenuar flutuações abruptas nas probabilidades geradas pela CNN. Essa técnica de pós-processamento reduz ruídos residuais e contribui para a estabilidade dos resultados antes da decisão final de classificação. Após a filtragem, a classe predita foi determinada por meio da função *argmax*, assegurando que o processo de suavização não comprometesse a coerência das previsões [19]. Essa abordagem aumentou a robustez do modelo, minimizando erros causados por pequenas oscilações nas saídas da rede.

III. RESULTADOS

Nesta seção são apresentados os resultados obtidos a partir da avaliação dos sinais medidos durante os ensaios com PEC, cujo objetivo foi identificar defeitos em um tubo de aço carbono amplamente utilizado no setor industrial. As avaliações envolveram a aplicação de técnicas de refinamento, englobando etapas de pré e pós-processamento e os testes realizados referem-se à implementação do algoritmo de rede neural convolucional unidimensional (1D-CNN). O conjunto de dados coletado foi dividido em 70% para treinamento e 30% para teste do classificador. Após a etapa de treinamento, foi realizada a fase de teste para avaliar o desempenho real da rede, fornecendo uma estimativa mais precisa da capacidade de generalização do modelo. As métricas de desempenho foram calculadas com base na matriz de confusão, permitindo uma análise detalhada da eficácia do classificador em cada categoria. Foram utilizadas métricas como acurácia, precisão, *recall* e *F1-score* para avaliar o desempenho global do modelo, além de estimar os erros de classificação.

A seguir, são detalhados os resultados obtidos em conjunto com as técnicas de refinamento adotadas, evidenciando a relevância dessas abordagens para aprimorar o desempenho do modelo de classificação.

A. Testes do Modelo Desenvolvido

O primeiro experimento foi realizado com 50 épocas e tamanho de lote (*batch size*) igual a 16. Ao analisar o gráfico da Figura 5, observa-se a evolução da acurácia, durante o processo de treinamento e validação, em função do número de épocas. Nota-se um aumento significativo da acurácia nas primeiras iterações, com o modelo atingindo valores superiores a 90% tanto no treinamento quanto na validação. No entanto, à medida que o número de épocas aumenta, observa-se um distanciamento entre as curvas de treinamento (em azul) e validação (em vermelho), indicando sinais de *overfitting*, ou seja, um possível sobreajuste do modelo aos dados de treinamento.

As perdas apresentadas na Figura 6 se distribuíram ao longo das épocas, aproximando-se de zero já por volta da




Figura 5. Gráfico de Acurácia para a configuração da rede com 50 épocas e tamanho de lote (*batch size*) igual a 16.

quinta época. Esse comportamento indica que o modelo atingiu rapidamente um ponto de estabilização no processo de treinamento, com a função de perda convergindo de forma eficiente.




Figura 6. Gráfico de Perdas para a configuração da rede com 50 épocas e tamanho de lote (*batch size*) igual a 16.

A matriz de confusão apresentada na Tabela II mostra o desempenho do modelo em relação às três classes analisadas no estudo (Sem Defeito, Defeito Interno e Defeito Externo). As predições corretas encontram-se na diagonal principal, sendo que o melhor desempenho foi observado para a classe SD, que apresentou 100% de discriminação. Conforme a Tabela III, a acurácia total alcançou 95%, e, de forma geral, os acertos superaram 90% em todas as classes, demonstrando um balanceamento adequado na discriminação, com destaque para a classificação perfeita na região SD.

Após a primeira configuração e a análise dos resultados, foi definida uma nova configuração com 100 épocas e tamanho

Tabela II

MATRIZ CONFUSÃO PARA A CONFIGURAÇÃO DE REDE COM 50 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 16.

Classe Verdadeira	Classe Prevista		
	Sem Defeito	Defeito Interno	Defeito Externo
Sem Defeito	100	0	0
Defeito Interno	4	92	4
Defeito Externo	1	7	92

Tabela III

TABELA DE MÉTRICAS DA CONFIGURAÇÃO DE REDE COM 50 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 16.

	Precisão	Recall	F1-Score
Sem Defeito	0.95	1.00	0.98
Defeito Interno	0.93	0.92	0.92
Defeito Externo	0.96	0.92	0.94
Acurácia - 0.95			

de lote (*batch size*) igual a 32. A acurácia apresentou uma média de 95%, indicando boa eficiência inicial no treinamento e validação. À medida que o número de épocas aumentou (acima de 30), conforme pode ser observado na Figura 7, ficou perceptível uma variação crescente entre as curvas de validação e treinamento, sugerindo que o *overfitting* pode ter afetado significativamente esse resultado.




Figura 7. Gráfico de Acurácia para configuração de rede com 100 épocas e tamanho de lote (*batch size*) igual a 32.

As perdas estão representadas na Figura 8, mostrando uma redução progressiva ao longo das épocas. Esse comportamento evidencia um bom desempenho durante a fase de treinamento das classes, sendo possível observar a estabilização por volta da décima época, com valores próximos de zero, indicando um ajuste adequado do modelo.

A matriz de confusão apresentada na Tabela IV mostra uma boa discriminação das três classes (Sem Defeito, Defeito In-




Figura 8. Gráfico de Perdas para configuração de rede com 100 épocas e tamanho de lote (*batch size*) igual a 32.

terno e Defeito Externo), destacando-se a classe Sem Defeito, que alcançou a maior taxa de *recall*, com 100%. Ao verificar a tabela de métricas correspondente (Tabela V), observa-se que o modelo apresentou bom desempenho geral, considerando que o menor valor de precisão foi 87% para a classe DI, enquanto as classes Sem Defeito e Defeito Externo atingiram 99% e 96%, respectivamente. Ademais, para essa configuração, com acurácia de 95%, foram observados pequenos sinais de *overfitting*, que, no entanto, não comprometeram significativamente o desempenho geral.

Tabela IV

MATRIZ CONFUSÃO PARA CONFIGURAÇÃO DE REDE COM 100 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 32.

Classe Verdadeira	Classe Prevista		
	Sem Defeito	Defeito Interno	Defeito Externo
Sem Defeito	100	0	0
Defeito Interno	0	98	2
Defeito Externo	1	12	87

Tabela V

TABELA DE MÉTRICAS PARA CONFIGURAÇÃO DE REDE COM 100 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 32.

	Precisão	Recall	F1-Score
Sem Defeito	0.99	1.00	1.00
Defeito Interno	0.89	0.98	0.93
Defeito Externo	0.98	0.87	0.92
Acurácia - 0.95			

Para uma nova avaliação dos resultados, foi considerada a configuração com 150 épocas e tamanho de lote igual a 64. A Tabela VI apresenta a eficiência geral da CNN 1D, mostrando que o desempenho das três classes, por meio da

matriz de confusão, revelou boa discriminação das regiões avaliadas. A diagonal principal indica as predições corretas, com valores de 100%, 97% e 85% para as classes SD, DE e DI, respectivamente. Os elementos fora da diagonal correspondem aos erros de classificação, que neste caso apresentaram valores reduzidos, resultando em uma boa precisão geral. Destaca-se, contudo, a menor eficiência na identificação da classe DE, que foi confundida com a região DI em 14% dos casos e com SD em 1%. Esses erros, entretanto, não comprometem o principal objetivo desta pesquisa, que é garantir a distinção entre regiões defeituosas e sem defeito.

O gráfico da Figura 9 apresenta a acurácia durante o processo de treinamento e validação em função do número de épocas. Nota-se um aumento progressivo da acurácia nas primeiras épocas e, ao se aproximar da 50ª época, a curva de treinamento (em azul) converge para valores próximos de 1, enquanto a curva de validação decai para cerca de 80%, indicando que o modelo apresenta melhor desempenho com um número menor de épocas, quando o processo é mais estável e o *overfitting* não afeta significativamente os resultados.




Figura 9. Gráfico de Acurácia para configuração de rede com 150 épocas e tamanho de lote (*batch size*) igual a 64.

No gráfico de análise de perdas apresentado na Figura 10, observa-se uma redução significativa da perda no início do treinamento, à medida que o modelo vai se ajustando aos dados. A perda estabiliza próxima de zero, indicando que, ao longo as épocas são incrementadas, não há expectativa de melhora significativa nos resultados.

Os dados das métricas referentes ao treinamento da terceira configuração estão apresentados na Tabela VII, destacando uma acurácia de 94%, com bons valores de precisão, recall e F1-score. Foi o único treinamento de modelo que ficou abaixo dos 95% de acurácia, indicando que com o aumento do número de épocas o modelo tende a apresentar uma leve redução na taxa de acerto, mas, de forma geral, manteve uma boa performance.

Outras metodologias foram propostas utilizando o mesmo experimento (corpo de prova e técnica de ensaios não des-




Figura 10. Gráfico de Perdas para configuração de rede com 150 épocas e tamanho de lote (*batch size*) igual a 64.

Tabela VI
MATRIZ CONFUSÃO PARA CONFIGURAÇÃO DE REDE COM 150 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 64.

Classe Verdadeira	Classe Prevista		
	Sem Defeito	Defeito Interno	Defeito Externo
Sem Defeito	100	0	0
Defeito Interno	1	97	2
Defeito Externo	1	14	85

Tabela VII
TABELA DE MÉTRICAS PARA CONFIGURAÇÃO DE REDE COM 150 ÉPOCAS E TAMANHO DE LOTE (*batch size*) IGUAL A 64.

	Precisão	Recall	F1-Score
Sem Defeito	0.98	1.00	0.99
Defeito Interno	0.87	0.97	0.92
Defeito Externo	0.98	0.85	0.91
Acurácia - 0.94			

trutivos). A pesquisa de [20] apresentou uma combinação entre a técnica de extração de características por meio da *Discrete Fourier Transform* (DFT), a rede neural perceptron multicamadas (*MultiLayer Perceptron* – MLP) e a otimização por enxame de partículas (*Particle Swarm Optimisation* – PSO) para ajustar os parâmetros do classificador projetado. Essa metodologia foi aplicada aos sinais de ensaios por PEC em um tubo de aço carbono com revestimento compósito. Os melhores resultados foram alcançados com os dados pré-processados pela técnica DFT, atingindo 91,2% de eficiência total das classes, sendo a região com maior índice de acerto a SD.

A pesquisa publicada por [21] apresentou resultados promissores, com o melhor desempenho chegando a 96,8% de discriminação total das classes, destacando-se as detecções das

classes DI e DE (97% e 100%, respectivamente). A classe sem defeito foi identificada com 94%.

Os resultados encontrados nesta pesquisa, quando comparados aos anteriores, destacam-se pelo alto desempenho na identificação das classes SD e DI. Contudo, o classificador projetado apresentou dificuldades na detecção da região de defeito externo, o que reduziu a eficiência total das classes, resultando em uma acurácia de 95%. Isso se deve ao fato de que, em diversas situações, o classificador identificou a região de defeito interno no lugar da classe defeito externo.

Ao confrontar os erros de classificação entre regiões com e sem defeito, observou-se que o melhor resultado desse trabalho apresentou apenas 1% de erro nesse aspecto crítico. Esse tipo de equívoco — em que uma região defeituosa é interpretada como saudável — é especialmente relevante do ponto de vista prático, pois representa o cenário mais arriscado em aplicações reais de inspeção. Uma falha como essa pode gerar riscos significativos à integridade física dos trabalhadores e à integridade patrimonial de um complexo industrial, podendo ocasionar desde a ruptura de tubulações sob pressão até, em casos extremos, a paralisação total do processo produtivo. Assim, mesmo com desafios na distinção entre tipos de defeitos, a baixa taxa de erro entre regiões com e sem defeito reforça a confiabilidade do modelo para aplicações industriais sensíveis à segurança e à continuidade operacional.

IV. CONCLUSÕES

Este trabalho apresentou o desenvolvimento de um sistema automático baseado em CNN 1D para a classificação de defeitos em tubos de aço carbono, utilizando sinais obtidos em ensaios por correntes parasitas pulsadas. Os resultados demonstraram alta eficiência geral, alcançando até 95% de discriminação total das classes avaliadas. Destaca-se que as classes Sem Defeito e Defeito Interno foram identificadas com alta precisão, enquanto a classe Defeito Externo apresentou maior dificuldade de classificação, refletida em taxas elevadas de falsos positivos e falsos negativos.

A principal contribuição deste trabalho reside na aplicação de redes neurais convolucionais unidimensionais para um contexto desafiador de inspeção não destrutiva em materiais revestidos, preenchendo lacunas metodológicas na detecção automática de defeitos por corrosão. Os resultados obtidos são promissores e reforçam o potencial da abordagem como ferramenta eficiente para aplicações industriais sensíveis à segurança e à continuidade operacional.

Apesar dos avanços, reconhece-se como limitação a sensibilidade reduzida na identificação de defeitos externos, apontando para a necessidade de investigações complementares. Entre os caminhos futuros destacam-se o estudo de arquiteturas híbridas, técnicas avançadas de balanceamento de classes e, de forma igualmente relevante, o aprimoramento dos aspectos de instrumentação e acionamento eletrônico. Esse aprimoramento abrange desde o controle dos parâmetros elétricos aplicados à bobina da sonda, passando pelo condicionamento e digitalização dos sinais adquiridos, até a utilização de conversores de alta resolução, visando uma aquisição de dados

mais íntegros que potencializem o desempenho dos algoritmos de classificação.

AGRADECIMENTOS

Os autores agradecem ao CNPQ pelo apoio financeiro.

REFERÊNCIAS

- [1] WAAKO, Stephen et al. *Corrosion Detection Techniques for Asset Integrity and Maintenance in the Oil and Gas Industry: A Review*. Metallurgical and Materials Engineering, v. 31, n. 4, p. 638-654, 2025.
- [2] UCHANIN, Valentin. *Eddy current techniques for detecting hidden subsurface defects in multilayer aircraft structures*. Transactions on aerospace research, n. 2 (267), p. 69-79, 2022.
- [3] SOPHIAN, A.; TIAN, G.; FAN, M. *Pulsed eddy current non-destructive testing and evaluation: A review*. Chinese Journal of Mechanical Engineering, Springer, v. 30, p.500-514, 2017.
- [4] BARBOSA, H. et al. *Sistema de apoio à decisão para avaliação de estruturas industriais utilizando a técnica de correntes parasitas pulsadas e redes neurais*. In: XVI Brazilian Conference on Computational Intelligence, Salvador, October 8th to 11th, 2023. p. 1-6.
- [5] LAROCCA, Camilla B et al. *Wall Thinning Characterization of Composite Reinforced Steel Tube Using Frequency-Domain PEC Technique and Neural Networks*. Journal of Nondestructive Evaluation, Springer, v. 37, n. 3, p. 44, 2018.
- [6] XIE, F. et al. *Research on pulsed eddy current automatic detection technology for weld defects of pressure vessel cylinder*. Measurement, Elsevier, v. 176, p. 109081, 2021.
- [7] SILVA, M. M. et al. *Intelligent embedded system for decision support in pulsed eddy current corrosion detection using extreme learning machine*. Measurement, Elsevier, v. 185, p. 110069, 2021.
- [8] KASAI, Naoya et al. *Predicting actual crack size through crack signal obtained by advanced Flexible Eddy Current Sensor using ResNet integrated with CBAM and Huber loss function*. NDT & E International, v. 149, p. 103249, 2025.
- [9] SHE, Saibo et al. *Thickness Measurement and Surface-defect Detection for Metal Plate Using Pulsed Eddy Current Testing and Optimized Res2Net Network*. IEEE Transactions on Instrumentation and Measurement, 2024.
- [10] DENG, W. et al. *Classification and quantitative evaluation of eddy current based on kernel-pca and elm for defects in metal component*. Metals, MDPI, v. 9, n. 2, p. 155, 2019.
- [11] FU, Xin et al. *Towards end-to-end pulsed eddy current classification and regression with CNN*. In: 2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). IEEE, 2019. p. 1-5.
- [12] SHE, Saibo et al. *Inspection of defects depth for stainless-steel sheets using four-coil excitation sensor and deep learning*. IEEE Transactions on Instrumentation and Measurement, v. 72, p. 1-10, 2023.
- [13] LE, Minhuy et al. *Enhancing corrosion detection in pulsed eddy current testing systems through autoencoder-based unsupervised learning*. NDT & E International, v. 146, p. 103175, 2024.
- [14] TU, FengMiao; YANG, SuiXian. *Application of a one-dimensional convolutional neural network in defect size inversion of oil and gas pipelines*. Insight-Non-Destructive Testing and Condition Monitoring, v. 67, n. 1, p. 20-26, 2025.
- [15] MENG, Tian et al. *Real-time tunnel-magnetoresistive-based pulsed eddy current testing with deep learning*. IEEE Sensors Journal, 2024.
- [16] NOGAY, Hidir Selcuk; AKINCI, Tahir Cetin; YILMAZ, Musa. *Detection of invisible cracks in ceramic materials using by pre-trained deep convolutional neural network*. Neural Computing and Applications, v. 34, n. 2, p. 1423-1432, 2022.
- [17] SHE, Saibo et al. *Evaluation of defects depth for metal sheets using four-coil excitation array eddy current sensor and improved ResNet18 network*. IEEE Sensors Journal, v. 24, n. 12, p. 18955-18967, 2024.
- [18] SHE, Saibo et al. *Inspection of Defects Depth for Stainless-Steel Sheets Using 4-coil Excitation Sensor with 1D CNN*. In: 2023 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). IEEE, 2023. p. 01-06.
- [19] KUSRINI, Kusrini; YUDIANTO, Muhammad Resa Arif; AL FATTA, Hanif. *The effect of Gaussian filter and data preprocessing on the classification of Punakawan puppet images with the convolutional neural network algorithm*. International Journal of Electrical and Computer Engineering, v. 12, n. 4, p. 3752, 2022.

- [20] SILVA, Gilvan Farias Da et al. *Constrained neural classifier training method for flaw detection in industrial pipes using particle swarm optimisation*. International Journal of Innovative Computing and Applications, v. 13, n. 3, p. 150-160, 2022.
- [21] BARBOSA, Hugo Leonardo Santana et al. *Sistema de Apoio a Decisao para Avaliacao de Estruturas Industriais Utilizando a Tecnica de Correntes Parasitas Pulsadas e Redes Neurais*. XVI Brazilian Conference on Computational Intelligence (CBIC 2023), Salvador, October 8th to 11th.