

Sistema de Apoio à Decisão para Avaliação de Estruturas Industriais Utilizando a Técnica de Correntes Parasitas Pulsadas e Redes Neurais

Hugo Leonardo Santana Barbosa
Colegiado de Engenharia Elétrica
Universidade F. do Oeste da Bahia
Bom Jesus da Lapa, Brasil
hugo.barbosa@ufob.edu.br

Manoel Messias Silva Júnior
Colegiado de Engenharia Elétrica
Universidade F. do Oeste da Bahia
Bom Jesus da Lapa, Brasil
manoel.messias@ufob.edu.br

Eduardo F. Simas Filho
Dept. de Engenharia Elétrica e Computação
Universidade Federal da Bahia (UFBA)
Salvador - BA, Brasil
eduardo.simas@ufba.br

Paulo C. M. A. Farias
Dept. de Engenharia Elétrica e 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

Abstract—Inspeções utilizando correntes parasitas pulsadas vem sendo aplicadas no monitoramento de integridade estrutural em equipamentos industriais. Destacando-se na capacidade de detecção de corrosão sob isolamento térmico, uma vez que, não precisa entrar em contato com a superfície do material avaliado, não havendo a necessidade de remoção do isolamento para realização do ensaio. Diante disso, para este trabalho foi desenvolvido um sistema de classificação automático para identificação de defeitos provocados por corrosão em um tubo de aço carbono, usualmente aplicado na indústria petroquímica. Este sistema foi projetado através das topologias Perceptron Multi-Camadas (*Multi Layer Perceptron - MLP*) e Redes Neurais Recorrentes (*Recurrent Neural Networks - RNN*). Neste caso, utilizou-se o sinal no domínio do tempo do ensaio por correntes parasitas pulsadas como entrada das redes neurais projetadas. Observou-se que os melhores resultados foram alcançados quando utilizado a rede neural recorrente como sistema inteligente.

Index Terms—Corrosão, Monitoramento, Correntes Parasitas Pulsadas, Multi Layer Perceptron, Recurrent Neural Networks

I. INTRODUÇÃO

No setor industrial, o monitoramento periódico de estruturas metálicas que estão sujeitas a ação corrosiva, mostra-se importante para garantir que materiais e

equipamentos possam ser operados com segurança [1]. Essa prática permite redução de custos na produção e maior tempo de funcionamento dos equipamentos, diminuindo as paradas e os riscos de acidentes. A corrosão pode ser identificada por meio de diversos métodos, cada um com suas particularidades. No caso das técnicas intrusivas, um sensor é posicionado no fluxo do produto, permitindo o controle de corrosão. Essas sondas caracterizam-se por apresentarem respostas rápidas as mudanças na taxa de corrosão. Por outro lado, em algumas situações, não é possível a utilização destes métodos, assim, faz-se uso de técnicas de monitoramento da espessura da parede do material [2]. Os métodos de ensaios não destrutivos utilizando correntes parasitas vem mostrando alta eficiência no monitoramento de corrosão. Dois tipos principais destas técnicas são bastante usados, corrente parasita convencional (*Eddy Current - EC*) e corrente parasita pulsada (*Pulsed Eddy Current - PEC*). Os testes por PEC fazem uso de um pulso como sinal de entrada, enquanto o ensaio por EC utiliza excitação por um sinal senoidal de frequência única [3]. Neste caso, o ensaio por correntes parasitas pulsadas apresenta maior espalhamento espectral do sinal, oferecendo uma banda larga de frequência, cuja

Identify applicable funding agency here. If none, delete this.

extensão varia inversamente com o comprimento do pulso. Assim, com um único pulso, pode-se realizar inspeções em diferentes profundidades do material.

No contexto atual, equipamentos voltados para inspeções por correntes parasitas se baseiam na análise da amplitude ou ângulo de fase dos sinais em um gráfico do plano de impedância (que representa graficamente a resistência da bobina no eixo x versus a reatância indutiva no eixo y). Em outros casos, a detecção de defeitos é avaliada através de parâmetros como: amplitude e tempo do pico, durante o ciclo de carga da bobina [4]. Nesta avaliação, normalmente, o operador observa o comportamento do sinal de resposta de inspeção e o compara com um padrão de referência (determinado através de uma amostra com as mesmas características do material a ser avaliado). Entretanto, a interpretação das medidas fica bastante dependente da experiência e habilidade técnica do operador.

Diante disso, a utilização de sistemas automáticos de classificação para avaliação das informações adquiridas durante os ensaios PEC, tem sido cada vez mais frequente na literatura. Na pesquisa apresentada em [5], os autores desenvolveram um modelo utilizando *Machine Learning* para monitoramento de corrosão em oleodutos e gasodutos. O método *Gauss-pulse-modulation eddy current* (GPMEC) foi proposto para melhorar a sensibilidade da sonda de inspeção na detecção de falhas provocadas por corrosão [6]. O trabalho desenvolvido por [7], utilizou o método de PEC combinado com técnicas de aprendizado de máquinas para classificar amostras de aço IF a partir da posição onde elas foram extraídas de uma bobina de armazenamento. Na pesquisa desenvolvida por [8] foi aplicado dois métodos de extração de atributos, usados para produzir informações de entrada para um sistema de classificação. Neste caso, os coeficientes da transformada de Fourier e os parâmetros de uma curva exponencial ajustada aos coeficientes da DFT foram considerados. Os resultados encontrados indicam que a metodologia proposta reconheceu a perda de espessura na parede do tubo e sua localização com eficiência de detecção de 97,4 e 97,0 %, respectivamente. Neste contexto, o presente trabalho, apresenta um sistema de classificação automático com a finalidade de identificar, através da técnica de PEC, defeitos provocados por corrosão. Duas topologias de redes neurais (*MultiLayer Perceptron* – MLP e *Recurrent Neural Networks* – RNN) foram testadas com a finalidade de encontrar a melhor solução para o problema envolvido nesta pesquisa.

II. METODOLOGIA PROPOSTA

Neste trabalho foram investigados defeitos provocados por corrosão em um tubo de aço carbono revestido por material compósito. Tanto os defeitos internos quanto os externos foram produzidos por fresamento para garantir a espessura de parede desejada. Durante o

processo de preparação do corpo de provas, diferentes espessuras foram emuladas para simular diversas intensidades do processo corrosivo. Assim, a técnica PEC foi aplicada com a intenção de identificar 3 classes distintas, sem defeito (SD), defeito interno (DI) e defeito externo (DE). A Figura 1 ilustra a seção transversal do tubo com suas dimensões e a Tabela I resume as características dos defeitos.




Fig. 1. Dimensões do corpo de prova: (a) seção transversal e (b) vista 3D sem o isolamento mostrando o defeito externo.

TABLE I
DIMENSÕES DOS DEFEITOS EM MM (ONDE DI E DE REPRESENTAM DEFEITO INTERNO E DEFEITO EXTERNO, RESPECTIVAMENTE).

Defeito	Comprimento (mm)	Largura (mm)	Espessura (mm)
DI	96,0	78,0	2,5
DE	86,8	56,2	1,5

A configuração experimental é ilustrada na Figura 2. Um circuito analógico foi utilizado para amplificação dos sinais de excitação. Outro circuito foi utilizado para recepção dos sinais e acoplado a sonda de testes. Os dados coletados foram armazenados na memória do microcontrolador. Um sistema de classificação automática baseado em redes neurais artificiais foi projetado para identificação das classes envolvidas no experimento.




Fig. 2. Ilustração da montagem experimental realizada para coleta dos dados de inspeção.

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. Na Figura 3 estão ilustrados os dois sensores GMR (*Giant Magnetoresistance*) usados, um para sinais de referência e outro para sinais de medição, e na Tabela II é apresentado os principais parâmetros da sonda utilizada. A distância entre a peça e a bobina é de $\sim 7,5$ mm, correspondendo à espessura do revestimento do material compósito. A Figura 4 ilustra sinais típicos PEC obtidos por meio de uma sonda baseada em sensores GMR.




Fig. 3. Ilustração da sonda projetada com os sensores GMR de medição e referência.

TABLE II
PARÂMETROS UTILIZADOS PARA O PROJETO DA SONDA DE INSPEÇÃO.

Diâmetro externo (mm)	Diâmetro interno (mm)	Altura (mm)	Diâmetro do fio (mm)	Resistência (Ohm)
20	10	15	0,27	11




Fig. 4. Sinais típicos PEC.

A. Sistema de Classificação

O sistema de classificação utilizado neste trabalho contou com a implementação de duas arquiteturas diferentes: *Multilayer Perceptron* (MLP) e outra na configuração (*Recurrent Neural Networks* – RNN). Estes classificadores foram testados com a finalidade de encontrar a melhor opção para o sistema projetado. As redes neurais do tipo MLP vem sendo aplicadas com sucesso na classificação de falhas [9], [10]. Já a rede neural recorrente mostra-se uma importante ferramenta em aplicações que envolvem dados no domínio do tempo [11], [12].

As redes MLP são caracterizadas por possuírem uma ou mais camadas de nós intermediários ou ocultos (neurônios artificiais). Matematicamente, um neurônio artificial pode ser descrito pelas seguintes equações:

$$v_q = \sum_{j=1}^N w_j x_j + b_j, \quad y_q = \varphi(v_q) \quad (1)$$

em que x_1, x_2, \dots, x_N são as entradas, w_1, w_2, \dots, w_N são os pesos sinápticos, b_N é o viés, $\varphi(\cdot)$ é função de ativação e y_q é o sinal de saída do neurônio.

Para avaliação do sistema de classificação, também foi considerado a utilização da rede neural recorrente com combinações de camadas convolucionais. A rede neural convolucional destaca-se em aplicações que envolvem, principalmente, dados em 2 e 3 dimensões, embora seja aplicada em análise de dados unidimensionais. No caso da aplicação neste trabalho, na análise de séries temporais, a camada de convolução bidimensional é substituída por uma convolução unidimensional, operando com vetores ao invés de matrizes (Figura 5). Dessa forma, a rede neural convolucional 1D foi utilizada para extrair informações da série temporal por meio dos filtros utilizados em cada etapa da CNN (*Convolutional Neural Networks*). As características extraídas foram utilizadas como entrada de uma rede neural recorrente.

As redes neurais recorrentes são caracterizadas como uma classe que recebe entrada de duas fontes distintas: uma do presente, e outra de um ponto passado (realimentação). Essas informações são utilizadas como parâmetros para decidir como se comportar diante de uma nova entrada, neste caso, a saída de cada instante representa a entrada para o instante seguinte. Diante disso, essa topologia de rede é caracterizada como possuidora de memória, possibilitando o reconhecimento de um contexto através da memória. A Figura 6 apresenta um esquema de uma RNR de quatro camadas de neurônios, em que duas delas são ocultas. Nelas, um ou mais neurônios da segunda camada oculta abastece de forma recorrente ao menos um dos neurônios da primeira camada.

Fig. 5. Esquema de uma camada convolucional unidimensional.

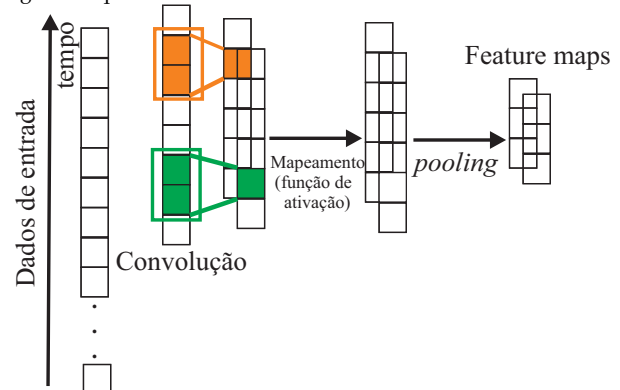
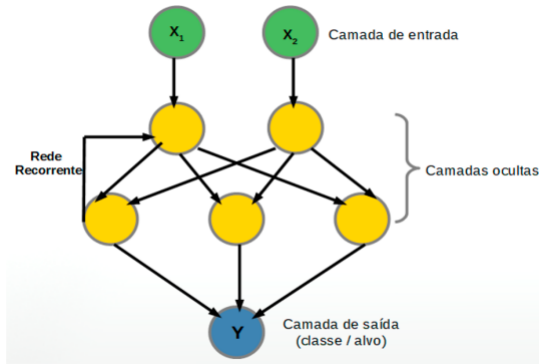


Fig. 6. Esquema de uma rede neural recorrente [14].



Na tabela III está apresentado os principais parâmetros utilizados no projeto dos classificadores.

TABLE III

PARÂMETROS UTILIZADOS PARA O PROJETO DOS MELHORES CLASSIFICADORES.

RNA	Otimizador	Taxa de Aprendizado	Épocas	Função de Ativação
RNN	Stochastic Gradient Descent (SGD)	0,01	500	ReLU
MLP	Stochastic Gradient Descent (SGD)	0,01	500	ReLU

B. Ferramentas computacionais e Hardware

A estrutura desenvolvida nesta pesquisa consiste em um módulo que contempla a etapa do projeto da rede neural em uma plataforma Python (utilizando Keras/TensorFlow) [15], para treinamento e testes dos dados de inspeção por PEC.

A Figura 7 apresenta o fluxo de projeto da rede neural. Para implementação do sistema de classificação, os dados adquiridos foram rotulados antes de serem utilizados para treinamento da RNA.

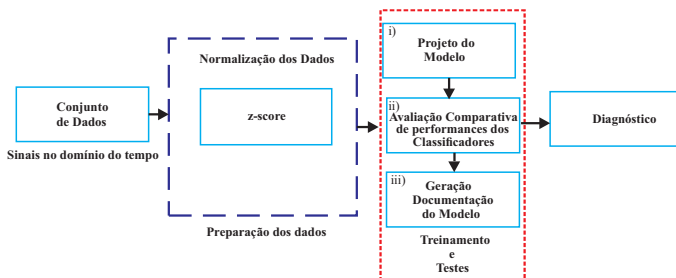


Fig. 7. Projeto do sistema de classificação.

O *hardware* utilizado é um computador pessoal com suas especificações descritas na Tabela IV.

TABLE IV
ESPECIFICAÇÕES DO HARDWARE UTILIZADO

Processador	Intel® Core™ i7-7500U – 7ª Geração
Memória RAM	8 GB DDR4
Armazenamento	HD de 1 TB
Sistema Operacional	Windows 10 de 64 bits

C. Metodologia de avaliação dos resultados

Duas arquiteturas diferentes de redes neurais artificiais são usadas para classificação automática. A escolha dos parâmetros utilizados durante o processo de treinamento das redes foi orientada pelos testes realizados durante a fase de projeto dos discriminadores neurais. Nestas avaliações observou-se, principalmente, dois aspectos: convergência e generalização e eficiência de discriminação (através do produto das eficiências – PE) das classes presentes no experimento.

Para medir o desempenho da RNA, foram utilizadas métricas calculadas a partir da matriz de confusão, ferramenta muito utilizada para avaliações de modelos de classificadores. A matriz de confusão mostra as probabilidades de detecção de cada classe na diagonal principal e a probabilidade de classificação incorreta representada pelos elementos fora da diagonal principal. O elemento c_{ij} da matriz de confusão C representa a probabilidade de classificar uma amostra da classe i como pertencente à classe j . Assim, para c_{ij} , $i = j$ representa a eficiência de discriminação da classe i e $i \neq j$ representa erros de classificação. Nessa análise é possível identificar as probabilidades de detecção de cada classe na diagonal principal, onde, os demais elementos representam erros de classificação.

Outro parâmetro considerado foi o produto da média geométrica das eficiências (Produto das Eficiências - PE) de cada classe, que pode ser calculado através da Equação 2.

$$PE = (E_{f1} \times E_{f2} \times \dots \times E_{fq})^{\frac{1}{q}} \quad (2)$$

em que E_{fi} consiste na eficiência encontrada na diagonal principal da matriz e q representa o número total de classes envolvidas.

III. RESULTADOS EXPERIMENTAIS

Os resultados experimentais são avaliados mediante desempenho do módulo de classificação. Neste caso, o conjunto de dados usado neste experimento consistiu em 300 assinaturas medidas através da aplicação de correntes parasitas pulsadas (100 para cada classe de interesse). Sinais típicos de PEC são apresentados na Figura 8. A partir dessas informações, 70% foram usados para treinamento e 30% para testes da rede neural projetada. Os treinamentos, testes e projetos dos classificadores implementados foram executados em um ambiente Python Windows de 64 bits, rodando em um

computador pessoal cuja as especificações são: processador *Intel(R) core(TM) i7-7500U*, CPU de 3,50 GHz, e RAM instalada de 8,00 GB.




Fig. 8. Assinaturas típicas medidas no domínio do tempo (a) Região sem defeito - SD, (b) Região com defeito interno - DI, (c) Região com defeito externo - DE e (d) Sinal diferencial para as classes de interesse.

A. Desempenho do Sistema de Classificação

Os classificadores projetados foram alimentados através dos sinais no domínio do tempo. Foram utilizados 128 neurônios na camada oculta, 100 épocas e função de ativação *Softmax* para ambas topologias de rede. A matriz de confusão ilustrada na Tabela V apresenta os resultados encontrados. Observou-se que os classificadores apresentaram reduzidas taxas de acertos das classes envolvidas. Sendo que, o melhor discriminador apresentou 77,5% de eficiência total.

TABLE V
MATRIZ DE CONFUSÃO (EM %) PARA AS CLASSES SEM DEFEITO (SD), COM DEFEITO INTERNO (DI) E DEFEITO EXTERNO (DE), LEVANDO EM CONSIDERAÇÃO O CLASSIFICADOR MLP E RNN ALIMENTADO PELOS SINAIS NO DOMÍNIO DO TEMPO UTILIZANDO A FASE 1 (SINAL MEDIDO).

MLP → PE(%) = 72,51±2,51		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	66	14	11
	DI	23	69	5
	DE	11	17	84
RNN → PE(%) = 77,50±1,30		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	84	8	0
	DI	16	68	18
	DE	0	24	82

Após análise inicial optou-se por treinar os classificadores com outros parâmetros, neste caso, considerou-se para ambos 256 neurônios na camada oculta e 500 épocas, utilizando, primeiramente, a função de ativação *softmax* e depois *ReLU*. Observou-se que a eficiência de discriminação total das classes aumentou quando utilizado o classificador baseado na rede neural recorrente, que chegou a alcançar 94,3% com a função de

ativação *softmax*, e, 96,8% com a função de ativação *ReLU*. As tabelas VI e VII apresentam esses resultados. Importante observar que para a configuração usando a rede RNN (Tabela VII) não houve taxa de falso positivo para a classe sem defeito (quando uma região defeituosa é identificada como sem defeito). Considerando uma aplicação prática, quando uma classe defeituosa é identificada como sem defeito, pode ocorrer interrupção da produção, gerando prejuízos e impactando nos custos do processo, além de gerar riscos de acidentes.

TABLE VI
MATRIZ DE CONFUSÃO (EM %) PARA AS CLASSES SEM DEFEITO (SD), COM DEFEITO INTERNO (DI) E DEFEITO EXTERNO (DE), LEVANDO EM CONSIDERAÇÃO O CLASSIFICADOR MLP E RNN ALIMENTADO PELOS SINAIS NO DOMÍNIO DO TEMPO UTILIZANDO A FASE 1 (SINAL MEDIDO).

MLP → PE(%) = 72,50±3,50		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	68	10	11
	DI	22	70	9
	DE	10	20	80
RNN → PE(%) = 94,3±0,30		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	100	5	0
	DI	0	87	3
	DE	0	8	97

TABLE VII
MATRIZ DE CONFUSÃO (EM %) PARA AS CLASSES SEM DEFEITO (SD), COM DEFEITO INTERNO (DI) E DEFEITO EXTERNO (DE), LEVANDO EM CONSIDERAÇÃO O CLASSIFICADOR MLP E RNN ALIMENTADO PELOS SINAIS NO DOMÍNIO DO TEMPO UTILIZANDO A FASE 1 (SINAL MEDIDO).

MLP → PE(%) = 74,55±2,11		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	70	15	10
	DI	23	65	5
	DE	7	20	85
RNN → PE(%) = 96,80±0,20		Classe Real		
		SD	DI	DE
Classe localizada pelo classificador	SD	94	0	0
	DI	6	97	0
	DE	0	3	100

A Tabela VIII apresenta o resumo dos principais resultados encontrados. O melhor resultado foi utilizando 256 neurônios na camada oculta, PE igual a 96,8%, função de ativação *ReLU* e taxa de falso positivo igual a zero, para a rede neural recorrente. Para aplicação prática deste trabalho um resultado muito importante é o valor da taxa de falso positivo da classe SD. Quando utilizado a arquitetura MLP, esse valor apresentou-se elevado, inviabilizando sua aplicação.

IV. CONCLUSÕES

Nesta pesquisa a técnica de correntes parasitas pulsadas foi aplicada em um tubo de aço carbono com revestimento compósito, com objetivo de detectar defeitos provocados por corrosão. A metodologia proposta utilizou as redes neurais recorrentes e perceptron multicamadas para realizar a classificação das regiões in-

TABLE VIII

RESUMO DOS RESULTADOS APRESENTADOS PELA METODOLOGIA UTILIZADA, EM QUE NNO É O NÚMERO DE NEURÔNIOS OCULTOS, PE É O PRODUTO DAS EFICIÊNCIAS, FP_{SD} É A TAXA DE FALSO POSITIVOS DA CLASSE SD E FA A FUNÇÃO DE ATIVAÇÃO UTILIZADA.

Topologia da Rede	Amostras no tempo	NNO	PE(%)	FP_{SD}	FA
MLP	200	128	72,51	25	softmax
RNN	200	128	77,50	8	softmax
MLP	200	256	72,50	21	softmax
RNN	200	256	94,3	5	softmax
MLP	200	256	74,55	25	ReLU
RNN	200	256	96,80	0	ReLU

specionadas durante o experimento. Os melhores resultados foram alcançados quando se utilizou a rede neural recorrente, que apresentou eficiência de discriminação de 96,8%. Essa configuração de rede mostra-se bastante eficiente no processamento de dados em que as entradas anteriores devem ser consideradas, como dados da série temporal. Assim, considerando-se os objetivos desta aplicação, o método proposto mostrou eficiência na discriminação das classes envolvidas no experimento e pode fornecer informações relevantes para auxiliar o inspetor durante a realização dos ensaios por PEC. Outro aspecto importante é que neste trabalho não foram utilizadas técnicas de pré-processamento de sinais. Diante disso, métodos de extração de características e remoção de ruídos serão estudados, a fim de melhorar a eficiência do sistema projetado.

AGRADECIMENTOS

Os autores agradecem a FAPESB, CNPQ, CAPES e a UFOB pelo apoio financeiro.

REFERENCES

- [1] JIA, Zhitong et al. Intelligent identification of metal corrosion based on Corrosion-YOLOv5s. *Displays*, p. 102367, 2023.
- [2] WINNIK, Stefan. *Corrosion under insulation (CUI) guidelines*. [S.l.]: Elsevier, 2014.
- [3] WANG, Zhenwei; YU, Yating. Traditional Eddy Current-Pulsed Eddy Current Fusion Diagnostic Technique for Multiple Micro-Cracks in Metals. *Sensors, Multidisciplinary Digital Publishing Institute*, v. 18, n. 9, p. 2909, 2018.
- [4] SOPHIAN, Ali; TIAN, Guiyun; FAN, Mengbao. Pulsed Eddy Current Non-destructive Testing and Evaluation: A Review. *Chinese Journal of Mechanical Engineering, Springer*, v. 30, n. 3, p. 500-514, 2017.
- [5] XU, Lei et al. The Research progress and prospect of data mining methods on corrosion prediction of oil and gas pipelines. *Engineering Failure Analysis*, p. 106951, 2022.
- [6] HUANG, Pu et al. A sensitivity enhancement PEC method for bottom flaws and corrossions detection. *Measurement*, v. 202, p. 111910, 2022.
- [7] LAROCCA, Camilla B. et al. Classificação de tensões em chapas de Aço IF utilizando aprendizado de máquina aplicado a sinais de correntes parasitas pulsadas.
- [8] 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.

- [9] SILVA JR, Manoel M. et al. Sistema Embarcado de Apoio à Decisão para Avaliação Não Destrutiva por Correntes Parasitas Pulsadas usando Redes Neurais.
- [10] LIU, Yihao et al. Pulsed eddy current data analysis for the characterization of the second-layer discontinuities. *Journal of nondestructive Evaluation*, v. 38, p. 1-8, 2019.
- [11] DE BRUIN, Tim; VERBERT, Kim; BABUŠKA, Robert. Railway track circuit fault diagnosis using recurrent neural networks. *IEEE transactions on neural networks and learning systems*, v. 28, n. 3, p. 523-533, 2016.
- [12] XU, Qinhuo et al. Rail defect detection method based on recurrent neural network. In: 2020 39th Chinese Control Conference (CCC). IEEE, 2020. p. 6486-6490.
- [13] TURCANICK, M. Using recurrent neural network for hash function generation. In: *Proceedings of the International Conference on Applied Electronics (AE)*, (Pilsen, Czech Republic), p. 1-4, 201.
- [14] VILELA, G. B.; FILENI, C. H. P.; PASSOS, R. P. Redes Neurais Recorrentes: Aplicabilidade na Análise do Movimento Humano e na Saúde. *Revista CPAQV - Centro de Pesquisas Avançadas em Qualidade de Vida*, v. 12, n. 1, p. 1-7, 2020.
- [15] RASCHKA, Sebastian; MIRJALILI, Vahid. *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. [S.l.]: Packt Publishing Ltd, 2019.