

Sistema Embarcado de Apoio à Decisão para Avaliação Não Destrutiva por Correntes Parasitas Pulsadas usando Redes Neurais

Manoel M. Silva Jr., Eduardo F. Simas Filho, Paulo C. M. A. Farias, Maria C. S. Albuquerque, Ivan C. Silva e Claudia T. T. Farias

Resumo— Neste trabalho foi construído um sistema eletrônico para ensaios não destrutivos utilizando a técnica de PEC (*Pulsed Eddy Current*). Para detecção de corrosão em um tubo de aço carbono, bastante utilizado na indústria petroquímica. O protótipo contou com etapas de geração, aquisição e processamento dos sinais de inspeção. O sistema de classificação foi projetado através das topologias de redes neurais *Extreme Learning Machine* e *Perceptron Multi-Camadas*. Os resultados mostraram alta eficiência, com o melhor desempenho do classificador exibindo 99,0% de discriminação das classes e tempo de execução de 1,60 ms.

Palavras-Chave— *Pulsed Eddy Current*, Processamento de Sinais, *Extreme Learning Machine*, Electronic System.

Abstract— In this work, an electronic system for non-destructive testing was constructed using the Pulsed Eddy Current technique. For corrosion detection in a carbon steel tube, widely used in the petrochemical industry. The prototype had stages of generation, acquisition and processing of inspection signals. The classification system was designed using the topologies of *Extreme Learning Machine* and *Perceptron Multi-Layers* neural networks. The results showed high efficiency, with the best performance of the classifier exhibiting 99.0% of class discrimination and a running time of 1.60 ms.

Keywords— Electronic System, Signal Processing, Electronic System, Electronic System.

I. INTRODUÇÃO

Os ensaios não destrutivos (*Nondestructive Testing - NDT*) são utilizados para caracterização e detecção de defeitos e descontinuidades em materiais e equipamentos, sem a necessidade de removê-los ou causar alterações à amostra durante o processo de inspeção [1]. O teste por correntes parasitas é um dos métodos de inspeção eletromagnética mais utilizados na indústria, destacando-se na avaliação de estruturas sob ação da corrosão. Dois tipos principais de técnicas de correntes parasitas são bastante usados em testes não destrutivos, correntes parasitas convencional (*Eddy Current - EC*) e

correntes parasitas pulsadas (*Pulsed Eddy Current - PEC*). Enquanto o ensaio por EC utiliza excitação por um sinal senoidal de frequência única, os testes por PEC fazem uso de um pulso como sinal de entrada. Sendo assim, apresenta maior espalhamento espectral do sinal, oferecendo uma banda larga de frequência, cuja extensão varia inversamente com o comprimento do pulso [2].

A utilização de técnicas de pré-processamento de sinais e de sistemas automáticos de classificação vem sendo bastante empregadas para melhorar a avaliação das informações adquiridas durante os ensaios por PEC [3], [4]. Trabalhos anteriores mostraram que é possível apresentar uma solução automática para avaliações utilizando essa técnica de inspeção [5], [6]. Em [7], os autores apresentaram uma metodologia com base na taxa de decaimento da tensão na bobina de recepção dos sinais PEC para determinar a espessura da parede em materiais ferromagnéticos. Diferente destes trabalhos, que realizaram o processamento das informações em um computador pessoal, e utilizando abordagem distinta para tratamento dos sinais PEC, desenvolveu-se um protótipo de sistema eletrônico embarcado de processamento de sinais. O sistema implementado apresenta uma abordagem distinta dos equipamentos comerciais, pois incorpora uma análise completa, que envolve desde a geração do sinal de inspeção até o diagnóstico do material avaliado. Para tanto, utiliza uma combinação de técnicas para extração (*Discrete Fourier Transform - DFT* e *Discrete Wavelet Transform - DWT*) e seleção de atributos (*Principal Component Analysis - PCA*), além de um sistema de classificação automático embarcado (utilizando *Multi Layer Perceptron - MLP* e *Extreme Learning Machine - ELM*), capaz de identificar a posição da perda de espessura.

II. METODOLOGIA PROPOSTA

O sistema proposto neste trabalho está ilustrado na Figura 1. Ele foi desenvolvido para realizar etapas de geração, aquisição e processamento dos sinais de inspeção por PEC (Figura 2). O sinal pulsado é aplicado em um tubo de aço carbono com revestimento de material compósito (Figura 3). O objetivo deste ensaio é identificar três regiões distintas, sendo um local sem defeito (SD) e dois outros com Defeito Interno (DI)

Manoel M. Silva Jr., Departamento de Engenharia Elétrica, Universidade Federal do Oeste da Bahia (UFOB), Bom Jesus da Lapa - BA, Brasil, e-mail: manoel.messias@ufob.edu.br. Eduardo F. Simas Filho e Paulo C. M. A. Farias, Departamento de Engenharia Elétrica, Universidade Federal da Bahia (UFBA), Salvador - BA, Brasil, Emails: eduardo.simas@ufba.br e paulo.farias@ufba.br. Maria C. S. Albuquerque, Ivan C. Silva e Claudia T. T. Farias, Departamento de Engenharia Mecânica, Instituto Federal de Educação, Ciência e Tecnologia da Bahia, Salvador - BA, Brasil, e-mails: cleaalbuquerque@ifba.edu.br, ivanslv@gmail.com e ct.farias@uol.com.br.

e Defeito Externo (DE), provocados por corrosão. Os sinais de resposta PEC são capturados através de dois sensores GMR (*Giant Magnetoresistance*), e, armazenados na memória do microcontrolador. Durante a coleta de informações utilizou-se a máxima resolução do ADC (12 bits), com frequência de amostragem de 200 kHz.

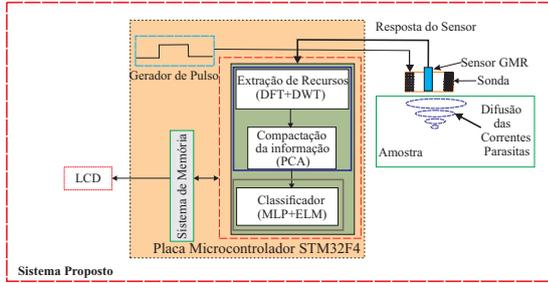


Fig. 1. Diagrama Geral do Sistema Proposto.

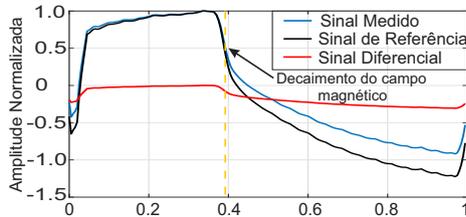


Fig. 2. Sinais típicos PEC.

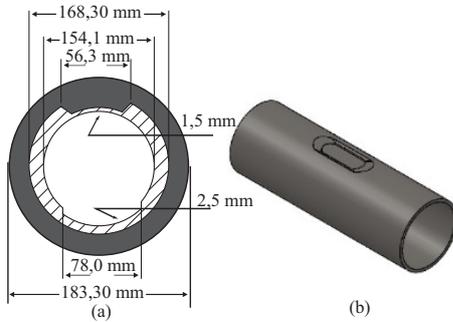


Fig. 3. Dimensões do corpo de prova: (a) seção transversal e (b) vista 3D sem o isolamento mostrando o defeito externo.

A. Extração de Características

Os sinais gerados no processo de inspeção por PEC, em alguns casos, são de difícil interpretação, razão pela qual, tem-se utilizado ferramentas computacionais para tornar as informações mais evidentes [8]. Em aplicações envolvendo sistemas de classificação embarcados, a fase de processamento das informações é importante para melhorar a eficiência de detecção das classes envolvidas, assim como ajudar a reduzir os custos computacionais da implementação [9].

A *Discrete Fourier Transform* (DFT) de um sinal $f[n]$ é definida de acordo com a Equação 1 [10]:

$$X[k] = \sum_{n=0}^{N-1} f[n] W_N^{nk}, k = 0, 1, \dots, N-1, \quad (1)$$

em que $W_N = e^{-j\frac{2\pi}{N}}$.

A transformada *wavelet* fornece um paradigma diferente para análise do sinal, pois permite que os domínios tempo e frequência sejam explorados simultaneamente [11]. A implementação da transformada discreta *wavelet* pode ser realizada utilizando um banco de filtros de decomposição hierárquica. Nesta técnica, o sinal é decomposto em coeficientes de aproximação $c[n]$ (passa-baixa) e de detalhe $d[n]$ (passa-alta), mantendo o número original de amostras através de um processo chamado subamostragem, por um fator de 2 ($\downarrow 2$). Considerando dois filtros digitais espelhados em quadratura com sequências de resposta de impulso finita, o sinal de interesse $s[m]$ é então decomposto em:

$$F_{low}[n] = \sum_{m=-\infty}^{\infty} s[m]c[2n-m] \quad (2)$$

$$F_{high}[n] = \sum_{m=-\infty}^{\infty} s[m]d[2n-m] \quad (3)$$

em que $F_{low}[n]$ e $F_{high}[n]$ representam os coeficientes *wavelet* associados ao filtro passa-baixas (*Low-pass Filter* - LPF) e filtro passa-altas (*High-pass Filter* - HPF), respectivamente.

B. Seleção de atributos

A técnica conhecida como Análise de Componentes Principais é aplicada neste trabalho com a finalidade de selecionar características do sinal PEC [12]. O módulo compactação projetado compreende uma multiplicação de matrizes que projeta os parâmetros estimados $\mathbf{y}_i = [y_1, \dots, y_n]^T$ (obtido através do módulo de extração de características) em um conjunto compacto e representante de atributos $\mathbf{z}_i = [z_1, \dots, z_n]^T$:

$$\mathbf{z}_i = B_{K \times N} \times \mathbf{y}_i \quad (4)$$

em que B ($K \times N$, com $N > K$) é a compactação PCA da matriz.

C. Sistema de Classificação

O sistema de classificação utilizado neste trabalho contou com duas topologias de redes neurais diferentes, um baseado na arquitetura *Multilayer Perceptron* (MLP) e outro na configuração *Extreme Learning Machine* (ELM). Estes classificadores foram testados com a finalidade de encontrar a melhor solução para o problema envolvido nesta pesquisa. 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:

$$v_q = \sum_{j=1}^N w_j x_j + b_j, \quad y_q = \varphi(v_q) \quad (5)$$

onde 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.

Os classificadores baseados na Máquina de Aprendizado Extremo são fundamentados, principalmente, em uma teoria de aprendizado para redes neurais *feed-forward* de camada única oculta (*Single Hidden Layer Feedforward Neural Networks - SLFNs*) [13]. Diferente das abordagens tradicionais de aprendizagem, em que todos os parâmetros são ajustados, exigindo um alto custo computacional, o ELM contém apenas uma camada oculta, na qual o conjunto de parâmetros ocultos é gerado aleatoriamente, independentemente das amostras de aplicação e treinamento [14], [15]. Assim, considerando o treinamento de um ELM com N nós na camada de entrada, k neurônios ocultos e q neurônios de saída, vamos supor que existam n pares de entrada-saída disponíveis dados por $\mathfrak{N} = \{(x_i, t_i) | x_i \in \mathbb{R}^N, t_i \in \mathbb{R}^q, i = 1, \dots, n\}$. Assim, a ELM é uma rede neural com pesos sinápticos aleatórios w_j associados ao bias b_j , $j = 1, 2, 3, \dots, k$, que determina os neurônios da camada oculta, e $\beta_o \in \mathbb{R}^k$, $y = 1, 2, \dots, q$ pesos definindo os neurônios na camada de saída. Assim, a rede treinada é obtida usando a seguinte equação:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (6)$$

onde \mathbf{H} é uma matriz correspondente às respostas de saída de neurônios ocultos, g é uma função de ativação (tangente hiperbólica), $\mathbf{T} = [t_1, t_2, \dots, t_n]$ é a matriz com os resultados desejados e $\boldsymbol{\beta}$ é a matriz que contém os pesos β_o que conectam os neurônios da camada oculta à de saída.

III. RESULTADOS EXPERIMENTAIS

Os resultados experimentais foram apresentados em duas etapas. Inicialmente, o sistema de medição proposto foi avaliado mediante desempenho do módulo de classificação. Neste caso, considerou-se o sinal de decaimento da assinatura PEC como entrada do sistema de processamento dos sinais. O fluxo de processamento aplicado aos sinais de inspeção está ilustrado na Figura 4. Em seguida, analisou-se os principais aspectos relacionados ao desempenho da plataforma de *hardware* utilizada.

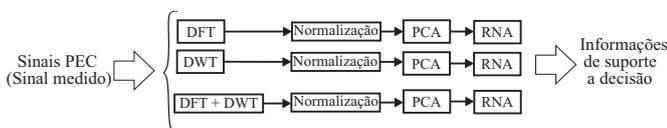


Fig. 4. Diagrama do fluxo de processamento dos sinais PEC.

A. Testes de Desempenho do Sistema de Classificação

O conjunto de dados usado neste experimento consistiu em 300 assinaturas medidas (100 para cada classe de interesse). A partir dessas informações, 70% foram usados para treinamento, 20% para testes e 10% para validação da rede neural. O procedimento de treinamento foi repetido várias vezes, a fim de tentar evitar a ocorrência de resultados tendenciosos devido à escolha inicial dos pesos aleatórios. Para isso, os sinais que compõem os conjuntos de treinamento, teste e validação foram escolhidos de forma aleatória, antes da inicialização de cada procedimento de projeto do classificador. Testes de desempenho foram realizados utilizando o módulo de compactação PCA. A Figura 5(a) ilustra os resultados encontrados para o pré-processamento das informações usando a transformada de Fourier. O melhor desempenho apresentado foi obtido utilizando 18 componentes principais e 11 neurônios ocultos (Figura 6). Conforme mostrado na Figura 5(b), o melhor resultado foi encontrado com a combinação W+PCA+ELM, que apresentou Produto das eficiências, PE(%) = 99,0 ± 0,4 com 12 componentes principais retidos e 100 neurônios na camada oculta (Figura 6).

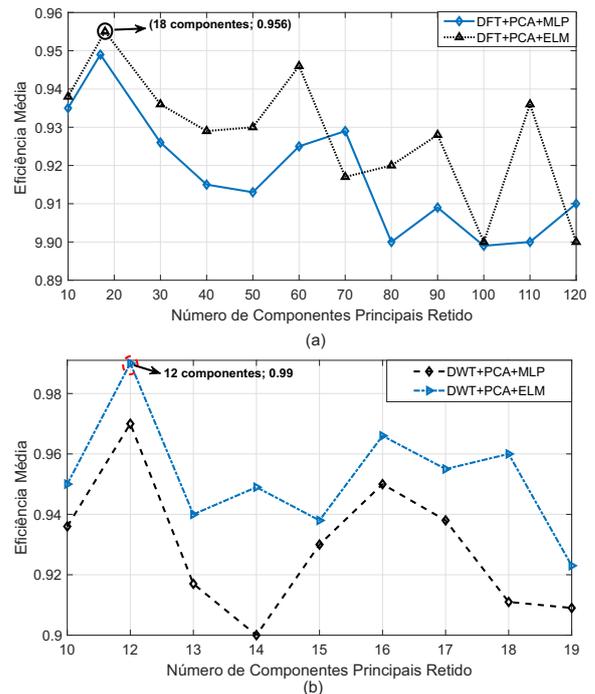


Fig. 5. Produto da eficiência média em função do número de componentes principais retidos (a) após aplicação da transformada de Fourier e (b) após aplicação da transformada *wavelet*.

Na Tabela I destacam-se as discriminações realizadas para as topologias MLP e ELM. O uso da transformada *wavelet* como técnica de extração de atributos apresentou melhores taxas de discriminação das regiões inspecionadas, tanto utilizando a arquitetura MLP (97,3% de eficiência média) quanto a ELM (99,0% de eficiência média). Nestas configurações também não houve taxa

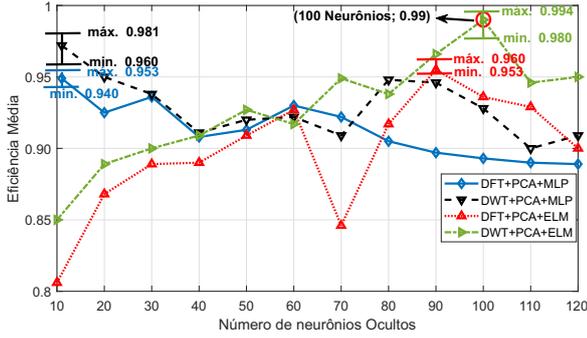


Fig. 6. Produto médio da eficiência em função do número de neurônios ocultos para aplicação do módulo de compactação, e valores máximos e mínimos registrados após diversas inicializações dos classificadores durante o processo de treinamento.

de falso positivo para a classe sem defeito (quando uma região defeituosa é identificada como sem defeito).

TABELA I

MATRIZ DE CONFUSÃO (EM %) PARA AS CLASSES SEM DEFEITO (SD), COM DEFEITO INTERNO (DI) E DEFEITO EXTERNO (DE), CONSIDERANDO CLASSIFICADOR MLP E ELM ALIMENTADO APÓS A APLICAÇÃO DAS TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS E SELEÇÃO DE ATRIBUTOS.

		Classe Real		
		SD	DI	DE
F+PCA+MLP → PE(%) = 94,9 ± 0,3				
Classe detectada pelo classificador	SD	91	0	0
	DI	9	94	0
	DE	0	6	100
W+PCA+MLP → PE(%) = 97,3 ± 0,5				
Classe detectada pelo classificador	SD	92	0	0
	DI	8	96	0
	DE	0	4	100
F+PCA+ELM → PE(%) = 95,6 ± 0,2				
Classe detectada pelo classificador	SD	94	0	0
	DI	6	95	2
	DE	0	5	98
W+PCA+ELM → PE(%) = 99,0 ± 0,4				
Classe detectada pelo classificador	SD	100	0	0
	DI	0	98	0
	DE	0	2	100

Visando melhorar o aproveitamento das informações discriminantes disponíveis, as técnicas de extração de características foram combinadas em um único conjunto de informações. Para uma eficiente combinação dessas informações em diferentes domínios foi aplicado o módulo de compactação através da PCA. A Figura 7 apresenta as eficiências médias dos classificadores em função do número de componentes principais retidos. A configuração F+W+PCA+ELM apontou discriminação total de 98,3%, para 16 componentes principais e 100 neurônios ocultos, utilizando o sinal medido. Conforme Figura 8, o sistema de classificação que mostrou maior desempenho foi a arquitetura ELM, levando em consideração a combinação das técnicas de Fourier e *wavelet*, e o módulo de compactação PCA. A Tabela II ilustra os resultados referentes ao processamento das informações

após combinação das técnicas. Conforme observado, o discriminador que apresentou melhor resultado foi o ELM, contudo, obteve-se desempenho de 0,7% a menos que o classificador W+PCA+ELM, avaliado anteriormente. Neste caso, a classe defeito externo foi identificada sem erros, as regiões sem defeito e com defeito interno apresentaram erros de 3 e 2 pontos percentuais, respectivamente. Nenhuma região defeituosa foi identificada como sem defeito, entretanto, uma parcela dos sinais correspondentes a classe sem defeito foi classificada incorretamente como defeito interno. Um aspecto que pode ter contribuído para redução da eficiência dos classificadores após a combinação das transformadas é a aplicação da transformada de Fourier, visto que, ao considerar o pré-processamento com esta técnica, observou-se que os discriminadores apresentaram menores taxas de acertos.

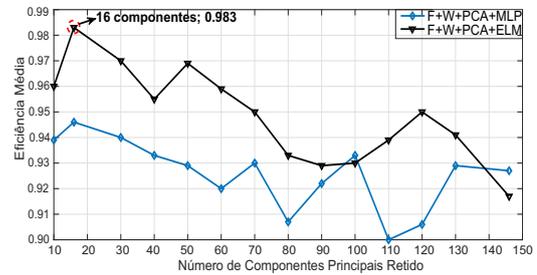


Fig. 7. Produto da eficiência média em função do número de componentes principais retidos.

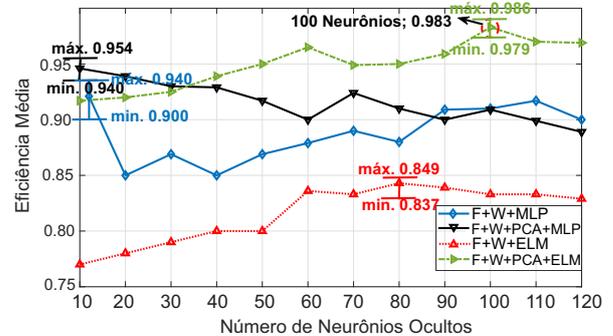


Fig. 8. Produto médio da eficiência em função do número de neurônios ocultos para combinação das técnicas, e valores máximos e mínimos registrados após diversas inicializações dos classificadores durante o processo de treinamento.

B. Desempenho da Plataforma de Hardware

Para realização dos testes foram considerados os discriminadores que apresentaram melhores eficiências na detecção das regiões inspecionadas. O tempo médio de processamento do conjunto de dados foi estimado considerando a média de 300 sinais carregados no sistema eletrônico proposto. Diante disso, a cadeia de processamento foi executada e os tempos calculados. O tempo de execução t_{ex} foi estimado calculando o número de ciclos

TABELA II

MATRIZ DE CONFUSÃO (EM %) PARA AS CLASSES SEM DEFEITO (SD), COM DEFEITO INTERNO (DI) E DEFEITO EXTERNO (DE), CONSIDERANDO CLASSIFICADOR MLP E ELM ALIMENTADO APÓS A COMBINAÇÃO DAS TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS E SELEÇÃO DE ATRIBUTOS.

		Classe Real		
		SD	DI	DE
F+W+MLP → PE(%) = 92,1±1,1				
Classe detectada pelo classificador	SD	85	0	0
	DI	10	95	0
	DE	5	5	100
		Classe Real		
		SD	DI	DE
F+W+PCA+MLP → PE(%) = 94,6±0,4				
Classe detectada pelo classificador	SD	93	0	0
	DI	7	91	0
	DE	0	9	100
		Classe Real		
		SD	DI	DE
F+W+ELM → PE(%) = 84,3±0,3				
Classe detectada pelo classificador	SD	83	0	0
	DI	17	84	14
	DE	0	16	86
		Classe Real		
		SD	DI	DE
F+W+PCA+ELM → PE(%) = 98,3±0,2				
Classe detectada pelo classificador	SD	97	0	0
	DI	3	98	0
	DE	0	2	100

de CPU (NC) e assumindo 1 ciclo de CPU $\sim \frac{1}{F_{op}}$ s, em que F_{op} é a frequência da CPU do microcontrolador (180 MHz). Nesse caso: $t_{ex} = \frac{NC}{F_{op}}$

Destaca-se a combinação entre os coeficientes *wavelet* com o classificador ELM, que apresentou discriminação total das classes de 99,0% com 12 características de entrada, 100 neurônios ocultos e tempo de execução de 1,6 ms, correspondente ao processamento de uma assinatura medida (Tabela III). Neste caso, o sistema combinou alta eficiência na discriminação das classes envolvidas no experimento e baixo custo computacional.

TABELA III

RESUMO DOS RESULTADOS APRESENTADOS PELA METODOLOGIA UTILIZADA.

Processamento do Sinal	NC	NNO	PE(%)	FP_{SD}	FN_{SD}	Tempo (ms)
W+PCA+MLP	12	11	97,3	0	8	1,3
W+PCA+ELM	12	100	99,0	0	3	1,6

IV. CONCLUSÕES

Neste trabalho, a técnica de PEC foi empregada para detectar e localizar a perda de espessura em um tubo revestido com material compósito. Dessa forma, a implementação de um sistema para geração, aquisição e processamento dos sinais de PEC, que incorpora inteligência e proporciona o diagnóstico do material no momento do ensaio foi projetado. O melhor resultado de classificação foi alcançado quando a cadeia de processamento utilizou a combinação W+PCA+ELM, apresentando a menor taxa de falsos negativos, com reduzidas características de entrada e erro máximo do discriminador de 3%. Assim, considerando-se os objetivos desta aplicação, o método proposto mostrou eficiência na discriminação das classes

envolvidas no experimento, com baixos custos computacionais associados. Trabalhos anteriores mostraram potencial para embarcar máquinas de aprendizado extremo em microcontroladores. Diante disso, para dar continuidade neste trabalho, será projetado um sistema embarcado que compreenda também o treinamento da rede neural no *hardware* utilizado.

AGRADECIMENTOS

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

REFERÊNCIAS

- [1] Bowler, Nicola, *Eddy-current nondestructive evaluation*, Springer, 2019.
- [2] Wang, Haowen and Huang, Jiangbo and Liu, Longhuan and Qin, Shanqiang and Fu, Zhihong, *A Novel Pulsed Eddy Current Criterion for Non-Ferromagnetic Metal Thickness Quantifications under Large Liftoff*, Multidisciplinary Digital Publishing Institute, Sensors, v. 22, pp. 614, 2022.
- [3] Xie, Shejuan and Zhang, Lei and Zhao, Ying and Wang, Xiaogang and Kong, Yuying and Ma, Qiang and Chen, Zhenmao and Uchimoto, Tetsuya and Takagi, Toshiyuki, *Features extraction and discussion in a novel frequency-band-selecting pulsed eddy current testing method for the detection of a certain depth range of defects*, NDT & E International, Elsevier, v. 111, 2020.
- [4] Ulapane, Nalika and Nguyen, Linh, *Review of Pulsed-Eddy-Current Signal Feature-Extraction Methods for Conductive Ferromagnetic Material-Thickness Quantification*, Multidisciplinary Digital Publishing Institute, Electronics, v. 8, p. 470, 2019.
- [5] Silva, Manoel M.; Simas Filho, Eduardo F.; Farias, Paulo C.M.A.; Albuquerque, Maria C.S.; Silva, Ivan C.; Farias, Claudia T.T. *Intelligent embedded system for decision support in pulsed eddy current corrosion detection using Extreme Learning Machine*, MEASUREMENT, v. 185, p. 110069, 2021.
- [6] Ge, Jiuhao and Hu, Baowang and Yang, Chenkai, *Bobbin pulsed eddy current array probe for detection and classification of defects in nonferromagnetic tubes*, Sensors and Actuators A: Physical, p. 112450, 2021.
- [7] Ulapane, Nalika and Thiyagarajan, Karthick and Hunt, David and Miro, Jaime Valls, *Quantifying the relative thickness of conductive ferromagnetic materials using detector coil-based pulsed eddy current sensors*, JoVE (Journal of Visualized Experiments), p. e59618, 2020.
- [8] GDing, Tianyu and Yang, Zhaohe and Huang, Hua and Huang, Pingjie and Hou, Dibo and Zhang, Guangxin, *A method for characterizing defects in multi-layer conductive structures by combining pulsed eddy current signals with PCA components*, AIP Conference Proceedings, AIP Publishing LLC, v.2102, p. 080003, 2019.
- [9] Xie, Fengqin and Wu, Xinhai and Zhang, Huayu and Zhang, Xin, *Research on pulsed eddy current automatic detection technology for weld defects of pressure vessel cylinder*, Measurement, v.176, p. 109081, 2021.
- [10] Grando, Flavio L and Denardin, Gustavo W and Moreto, Miguel and Lazzaretti, André E and Neto, Hugo Vieira, *A method for synchronized harmonic phasor measurement based on hardware-enhanced Fast Fourier Transform*, International Transactions on Electrical Energy Systems, Wiley Online Library, v.30, p. e12405, 2020.
- [11] Zhang, Dengsheng, *Fundamentals of Image Data Mining: Wavelet transform*, Springer, p. 35–44, 2019.
- [12] Vidal, René and Ma, Yi and Sastry, S Shankar, *Generalized principal component analysis: Principal component analysis*, Springer, p. 25–62, 2016.
- [13] Huang, Guang-Bin and Zhu, Qin-Yu and Siew, Chee-Kheong, *Extreme learning machine: theory and applications*, Neurocomputing, Elsevier, v. 70, p. 489–501, 2006.
- [14] Cheng, Jiatang and Xiong, Yan, *Application of Extreme Learning Machine Combination Model for Dam Displacement Prediction*, Procedia Computer Science, Elsevier, v. 107, p. 373–378, 2017.
- [15] Finker, Raúl and del Campo, Inés and Echanobe, Javier and Martínez, Victoria, *Intelligent Embedded Systems (IES)*, 2014 IEEE Symposium on: An intelligent embedded system for real-time adaptive extreme learning machine, IEEE, p. 61–69, 2014.