

O USO DE REDES NEURAIIS NO PROCESSAMENTO DE DADOS DE INSPEÇÃO POR CORRENTES PARASITAS MAGNÉTICAS PARA DETECÇÃO DE CORROSÃO POR PITE: UMA PROPOSTA METODOLÓGICA

Rescala, João¹; Coelho, Rodrigo²

¹ Mestrando do Programa em Gestão e Tecnologia Industrial do SENAI CIMATEC (PPG GETEC/CIMATEC), Salvador, BA, joao.rescala@gmail.com;

² Professor Pesquisador do Programa em Gestão e Tecnologia Industrial do SENAI CIMATEC (PPG GETEC/CIMATEC), Salvador, BA, rodrigo.coelho@fieb.org.br;

RESUMO

O uso de processamento inteligente de dados de inspeção não destrutiva já é uma realidade. O volume de dados gerados por ferramentas de inspeção e a agilidade no processamento para tomadas de decisão justificam essa tendência. Neste trabalho, é apresentada uma proposta metodológica baseada em Redes Neurais Convolucionais (CNN) para identificar e automaticamente a corrosão por pites próxima às soldas em T de uma estrutura em aço ASTM A36. Para o estudo, foram consideradas amostras fabricadas simulando a corrosão por pites como furos cegos rotulados no lado oposto ao lado a ser inspecionado. A técnica de inspeção por correntes parasitas magnéticas foi escolhida por possuir maior penetração em relação às correntes parasitas tradicionais. O algoritmo usado para a classificação foi desenvolvido em Python através da biblioteca Keras e utiliza redes convolucionais 1D com 16 canais. O modelo proposto utiliza a validação cruzada KFold, juntamente com as métricas de acurácia, precisão, revocação, F1 score, curvas de precisão-revocação e a área sob sua curva (AUC). Os resultados preliminares aplicando o modelo proposto mostrou-se eficiente no processamento de dados, especialmente quando os quesitos tempo, recursos humanos e corpo de provas são fatores relevantes na jornada de inspeção.

PALAVRAS-CHAVE: Redes Neurais Convolucionais (CNN); Correntes Parasitas Magnéticas; Classificação de Séries Temporais; Corrosão por pite.

1. INTRODUÇÃO

A tecnologia de inspeção baseada em correntes parasitas magnéticas (MEC) é um ensaio não destrutivo (END) que utiliza bobinas de correntes combinada com uma magnetização em corrente contínua (CC). O objetivo da magnetização é garantir a detecções de defeitos mais profundos e não superficiais em materiais ferromagnéticos e realizar inspeções estruturais rápidas baseadas na técnica de correntes parasitas tradicionais (ECT), o que representa uma demanda das indústrias, principalmente a de óleo e gás.¹⁻³

Atualmente, diversas metodologias para processamento de dados de inspeção utilizam técnicas baseadas em inteligência artificial (IA) para garantir maior eficiência e confiabilidade de processamento.⁴ Dentre elas, pode-se destacar as arquiteturas de Redes Neurais Convolucionais (CNN), que é a aprendizagem computacional baseada em redes neurais biológicas. As CNNs são robustas e podem ser utilizadas tanto para dados simples como séries temporais, quanto para dados mais complexos como processamento de imagens. Elas possuem como vantagem a extração automática das características de engenharia apresentadas nos dados e que, muitas vezes, podem ser ainda desconhecidas. Isso as torna robustas quando comparadas a outras arquiteturas de redes neurais, como as Redes Perceptron Multicamadas (MLP), e outros classificadores tradicionais de aprendizagem computacional. As CNNs são adequadas para análise de sinais temporais, pois possuem sensibilidade espacial (invariância a mudanças) tornando-as menos suscetíveis a ruídos e a perda de generalização. Além disso, as CNNs compartilham de parâmetros, o que reduz o número de parâmetros livres e, portanto, reduzindo o custo computacional.⁵⁻⁷

Dentre as tecnologias de inspeção, alguns desses modelos são aplicados para as diferentes técnicas de correntes parasitas, como as tradicionais e as pulsadas.⁸⁻¹⁰ Entretanto, quando o assunto é MEC, pouco ou nenhuma informação está disponível na literatura. Isso se justifica pela especificidade da tecnologia e seu caráter inovador. O mesmo pode-se afirmar quando essas tecnologias são aplicadas à inspeção de estruturas mais complexas, o que gera conseqüentemente dados mais robustos - como a presença de defeitos próximos a soldas.

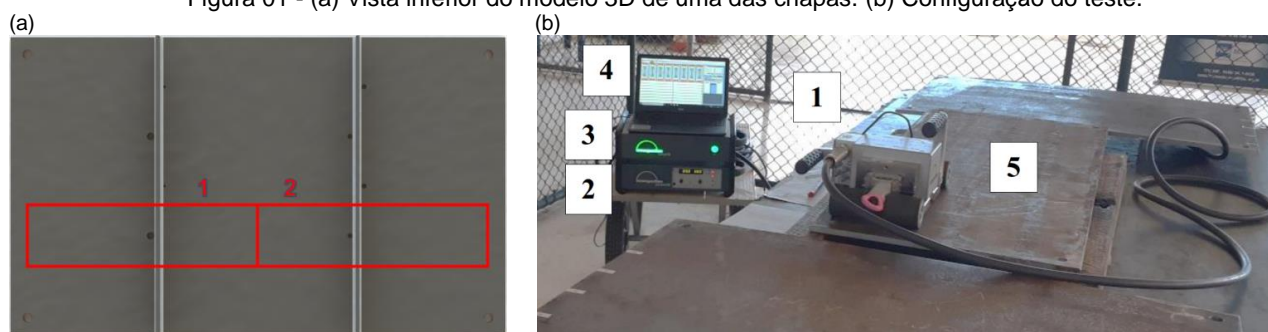
Este trabalho tem como objetivo descrever de forma preliminar os materiais e métodos utilizados na coleta dos dados e na classificação de corrosões por pite na inspeção de estruturas metálicas soldadas. A metodologia explora CNNs para classificar regiões com e sem defeito, entretanto, ao contrário de artigos correlatos,⁹ não serão utilizadas imagens e sim os dados brutos, devido ao menor custo computacional. Baseado na literatura,¹⁰ serão utilizados modelos unidimensionais, CNN1D, porém com o uso das componentes x e y de todos os canais disponíveis no dispositivo de inspeção.

2. METODOLOGIA

Os corpos-de-prova (CPs) utilizados nos testes laboratoriais foram fabricados com chapas de aço ASTM A36 com espessura de 1/2". A escolha do material foi devida suas características ferromagnéticas, a sua fácil disponibilidade e aplicabilidade na indústria. A espessura de 1/2" apresenta uma relação ideal para a análise de defeitos em chapas grossas. As chapas foram soldadas em T com 60x06 mm do mesmo material através do processo MAG, para simular chapas de reforço estrutural. A corrosão por pite foi simulada adicionando furos cegos fresados no mesmo lado das chapas de reforço e com distância constante de 09 mm do centro do cordão de solda para a borda mais próxima do furo. O experimento, conta com 38 furos usinados em 03 chapas. Um exemplo dessas chapas pode ser visto na Figura 01a.

O teste de inspeção conta com (1) o dispositivo de tecnologia MEC (P-19 da Innospection GmbH); (2) um controlador EddyIQ; (3) uma fonte de energia; (4) computador com a plataforma de controle e (5) a chapa de teste apoiada em uma bancada (Figura 02b).¹¹ Os testes foram realizados com distancia chapa-sensor (*lift-off*) de 5 mm, corrente de 15 A e ganho de 30 dB. As regiões de interesse, 38 com defeitos e 8 sem defeitos, foram inspecionadas nos dois sentidos transversais ao cordão de solda e com replicatas.


Figura 01 - (a) Vista inferior do modelo 3D de uma das chapas. (b) Configuração do teste.¹¹



3. RESULTADOS PRELIMINARES

A Figura 02 apresenta as características do sinal obtido pelo MEC. Os resultados podem ser visualizados através do plano de impedância (composto pela resistência e pela reatância) que varia de acordo com o deslocamento da ferramenta durante o ensaio.¹² Para facilitar a visualização do sinal, todo o rastro do sinal medido é mostrado em verde na Figura 02a. O sensor utilizado nos experimentos MEC é diferencial e, portanto, apenas detecta sinais na presença de não uniformidades, como soldas, defeitos e rebaixos. As 16 séries temporais, correspondentes às duas componentes de cada um dos 8 canais, variando com o *encoder* pode ser visualizada na Figura 02b, que mostra todo o percurso retilíneo de uma extremidade à outra durante a inspeção. A Figura 02c mostra o formato do sinal variando de acordo com o número de amostras.

Figura 02 - Sinal do MEC na presença de soldas com defeito: (a) plano de impedância; (b) duas soldas com defeitos variando com *encoder* e (c) uma solda com defeito variando com o número de amostras.



3.1 Pré-processamento e Classificação dos Dados

Os dados produzidos foram analisados através de algoritmo desenvolvido em linguagem Python, utilizando diversas de suas bibliotecas para visualizar, pré-processar e classificar os dados. Como demonstrado na Figura 01a, o percurso retilíneo de uma extremidade à outra da chapa, atravessa mais de um cordão de solda, mais de um sinal de interesse, como demonstrado na Figura 02b, e, portanto, o sinal deve ser separado.

Todos os dados devem possuir a mesma dimensionalidade. Portanto, a configuração de uma amostra ficou definida como sendo a janela de 500 pontos antes e 500 pontos depois do centroide do sinal de cada

solda. Foram utilizados todos os canais disponíveis no sistema, o que gerou uma amostragem de dimensão (1000,16). Essa amostragem foi inserida como entrada no classificador onde 30% do conjunto de dados foram separados para teste do modelo final. Esse conjunto de dados nunca vistos pelo modelo, serve para garantir a boa generalização do modelo. Os dados foram redimensionados para o intervalo de 0 a 1 para uma classificação mais rápida e mais estável da classificação.

Para a construção da rede foram utilizadas camadas de convolução, Conv1D, com funções de ativação do tipo ReLU, camadas de pooling, MaxPooling1D, sendo conectadas a uma camada densa com ativação sigmoide para a classificação binária dos dados. Foi utilizada entropia cruzada binária para classificar os melhores modelos calculando as perdas e como métricas a acurácia e o F1 score. Este último, calculado através da precisão e da revocação. O otimizador utilizado neste estudo foi o Adam. A validação cruzada KFold em 5 partes foi utilizada para avaliar os resultados com diferentes combinações de dados de treino e validação. Esse tipo de procedimento é altamente recomendado devido ao reduzido conjunto de dados, evitando que uma distribuição de dados favorável leve a resultados falsos.

3.2 Métricas e Critérios de Avaliação (próximos passos)

Os modelos ainda estão sendo desenvolvidos e a avaliação final melhor do modelo deve ser baseada em critérios de avaliação e métricas utilizando a precisão e a revocação para construir a curva precisão-revocação (PRC) e calcular a área sob a curva (AUC). A escolha dessas métricas é necessária devido ao desbalanceamento do conjunto de dados. Novamente, o KFold com 5 divisões será utilizado para o cálculo de todas as métricas, obtendo assim 5 resultados para cada uma das métricas e através das quais devem ser calculados os respectivos valores de média e desvio padrão amostrais, os quais serão os valores finais do modelo.

4. CONSIDERAÇÕES PRELIMINARES

A parte metodológica é fundamental para garantir a repetibilidade e reprodutibilidade do experimento, bem como a transparência dos resultados obtidos. Este trabalho se propôs a detalhar esta etapa e precede as futuras etapas, nas quais serão realizadas as análises dos resultados e discussões.

É esperado que os classificadores com CNN para o conjunto de dados em questão obtenha bons resultados, entretanto, o conjunto de dados limitados e desbalanceados são fatores críticos e podem limitar possíveis extrapolações para casos que estejam fora do escopo aqui estudado. É importante frisar, no entanto, que as métricas e métodos de avaliação dos resultados aqui descritos objetivam grande rigor e conservadorismo dos resultados, o que não foi encontrado em literaturas correlatas ao tema.

5. REFERÊNCIAS

- ¹ ASHER SL, BOENISCH A, REBER K. Development of a magnetic eddy current in-line inspection tool. In: *2016 11th International Pipeline Conference*. ; 2016.
- ² ANTIPOV AG, MARKOV AA. 3D simulation and experiment on high speed rail MFL inspection. *NDT E Int*. 2018;98(April):177-185. doi:10.1016/j.ndteint.2018.04.011
- ³ TERPSTRA S, HOEVE F, MCCANN Z, STONE M. TOF-FS: a technique for detection and monitoring of wall loss defects in large areas of vessels and pipework. *Insight - Non-Destructive Test Cond Monit*. 2008;50(9):476-479. doi:10.1784/insi.2008.50.9.476
- ⁴ VISHAL V, RAMYA R, SRINIVAS PV, SAMSINGH RV. ScienceDirect A review of implementation of Artificial Intelligence systems for weld defect classification . *Mater Today Proc*. 2019;16:579-583. doi:10.1016/j.matpr.2019.05.131
- ⁵ LECUN Y, BENGIO Y. Convolutional Networks for Images , Speech , and Time-Series Yann LeCun. In: *The Handbook of Brain Theory and Neural Networks*. MIT Press, Cambridge, MA; 1998:255-258.
- ⁶ HAYKIN S. *Neural Networks and Learning Machines*. Prentice Hall; 2009.
- ⁷ PYAKILLYA B, KAZACHENKO N, MIKHAILOVSKY N. Deep learning for ECG classification. In: *Journal of Physics: Conference Series*. Vol 913. ; 2017:12004.
- ⁸ YIN L, YE B, ZHANG Z, TAO Y, XU H, SALAS JR. NDT and E International A novel feature extraction method of eddy current testing for defect detection based on machine learning. 2019;107(March). doi:10.1016/j.ndteint.2019.04.005
- ⁹ ZHU P, CHENG Y, BANERJEE P, TAMBURRINO A, DENG Y. A novel machine learning model for eddy current testing with uncertainty. *NDT E Int*. 2019;101(October):104-112. doi:10.1016/j.ndteint.2018.09.010
- ¹⁰ FU X, LIU Z, ZHANG C, PENG X, JIAN L. Towards end-to-end pulsed eddy current classification and regression with CNN. In: *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. Auckland, New Zealand; 2019:1-5. doi:10.1109/I2MTC.2019.8826858
- ¹¹ RESCALA JPS, NEVES EC, LUNA WHD, et al. On the influence of operational parameters in pitting detection using magnetic eddy currents system: A preliminary review. In: *Da Conferência Sobre Tecnologia de Equipamentos*. ; 2019.
- ¹² BERNIERI A, FERRIGNO L, LARACCA M, MOLINARA M. Crack Shape Reconstruction in Eddy Current Testing Using Machine Learning Systems for Regression. 2008;57(9):1958-1968.