

16º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2025

Método para desenvolvimento de sistemas inteligentes de diagnóstico de falhas em máquinas rotativas baseado em ferramentas de deep learning

MARIANA F. MARCELINO¹, MAYARA G. DE ESTEFANI², ANDRE L. DIAS³

¹ Graduanda em Engenharia Elétrica, Bolsista IFSP, Campus Sertãozinho. mariana.ferraz@aluno.ifsp.edu.br

² Engenharia Eletricista Razek Equipamentos LTDA. mayaraestefani1@gmail.com

³ Professor e Diretor Adjunto de Pesquisa e Inovação do Campus Sertãozinho. andre.dias@ifsp.edu.br

Área de conhecimento (Tabela CNPq): 3.04.05.02-5 Automação Eletrônica de Processos Elétricos e Industriais

RESUMO: Máquinas rotativas acionadas por motores elétricos estão presentes nos mais diversos segmentos industriais. Garantir sua operação em condição saudável pode evitar falhas e paradas não programadas, possibilitando aumento de disponibilidade e produtividade no processo produtivo. Neste contexto, este projeto propõe um método para o desenvolvimento de sistemas inteligentes de diagnóstico de falhas em máquinas rotativas, como desbalanceamento e desalinhamento angular. O caráter inovador se dá uma vez que busca-se extrair informações fornecidas pelo servoacionamento, sem a necessidade de sensores dedicados como acelerômetros para análise de vibração. As variáveis investigadas foram rotação e torque, que normalmente já são disponibilizadas pelo servoacionamento via rede de comunicação industrial. O método investigou a utilização de redes neurais convolucionais, com pré-processamento dos sinais utilizando Wavelet scattering. O desempenho dos modelos preditivos foram avaliados e comparados literatura correlata, obtendo resultados satisfatórios.

PALAVRAS-CHAVE: máquinas rotativas, deep learning; aplicações industriais; condition monitoring

Method to develop Intelligent Fault Diagnosis Systems in Rotating Machinery Based on Deep Learning Techniques

ABSTRACT: Rotating machines driven by electric motors are present in a wide range of industrial sectors. Ensuring their operation under healthy conditions can prevent failures and unplanned downtime, thereby increasing availability and productivity in manufacturing processes. In this context, this project proposes a method for developing intelligent fault diagnosis systems for rotating machinery, addressing faults such as unbalance and angular misalignment. The innovative aspect lies in the extraction of information directly from the servo drive, eliminating the need for dedicated sensors such as accelerometers for vibration analysis. The investigated variables were rotational speed and torque, which are typically already available through the servo drive via the industrial communication network. The method explored the use of convolutional neural networks, with signal preprocessing performed through Wavelet Scattering. The predictive models' performance was evaluated and compared with related literature, yielding satisfactory results.

KEYWORDS: rotating machines, deep learning; industry applications; condition monitoring

INTRODUÇÃO

As tecnologias da Indústria 4.0 representam uma oportunidade para pequenas e médias empresas aprimorarem seus processos produtivos, melhorando a eficiência, reduzindo desperdícios e custos. Se considerarmos que estas empresas possuem recursos limitados para investimento em pesquisa e desenvolvimento, tecnologias como algoritmos de inteligência artificial, internet das coisas, e computação em nuvem podem promover vantagens por possuírem características de baixo custo (DIAS et al., 2021).

Neste contexto, o diagnóstico de falhas em máquinas de produção desempenha um papel importante para a confiabilidade e segurança de sistemas industriais modernos, uma vez que este tipo de equipamento é um dos mais importantes no setor produtivo de fábricas e com o rápido desenvolvimento tecnológico, se tornam cada vez mais complexo e funcional (Liu et al., 2018).

O diagnóstico de falha inteligente é uma maneira promissora de liberar o trabalho humano e automaticamente reconhecer o estado de saúde de máquinas e assim vem chamado muita atenção de pesquisas e empresas nas últimas duas ou três décadas (Lei et al., 2020).

Um sistema de diagnóstico deste tipo, trata-se de uma técnica para detecção e identificação da falha, que pode ser aplicado na informação sobre a condição de operação do equipamento (Jardine; Lin; Banjevic, 2006), normalmente provenientes de sinais de sensores dedicados instalados no equipamento. Devido à variabilidade e riqueza dos sinais de resposta, é quase impossível reconhecer padrões de falha diretamente, e normalmente um sistema de diagnóstico de falhas é aplicado, consistindo de duas etapas principais: processamento de dados (tratamento e extração de características dos sinais) e reconhecimento de falhas (normalmente com utilização de um sistema inteligente para a tarefa de reconhecimento de padrões) (Liu et al., 2018).

Este projeto tem por objetivo principal investigar, desenvolver e validar sistemas inteligentes de diagnóstico de falhas em máquinas rotativas, como desalinhamento angular e desbalanceamento, apenas com a utilização de dados fornecidos pelo servoacionamento, sem a necessidade de sensores dedicados como acelerômetros.

Na literatura correlata sobre sistemas que utilizam técnicas de *condition monitoring* empregadas no sistema de diagnóstico, verifica-se a utilização de medidas de algumas variáveis para sensoramento do corpo da máquina, motores e seu acionamento elétrico, como: potência, corrente e tensão elétricas, temperatura, vibrações mecânicas, torque, velocidade, posição, emissões acústicas entre outras. Adicionalmente, verifica-se emprego de diversas ferramentas de inteligência artificial para análise destes sinais, dentre elas as Redes Neurais Convolucionais (CNN).

Segundo Ige e Sibiya (2024), CNN são redes neurais artificiais de alimentação direta profundas, normalmente compostas por diversas camadas distintas com múltiplos neurônios e funções diferentes.

Para Kiranyaz et al. (2021) a popularidade dos algoritmos CNN é devido a suas vantagens quando comparado aos demais algoritmos, vantagens essas como:

- realizam a fusão da extração e classificação de características em um único algoritmo, podendo aprender e otimizar as características durante a fase de treinamento.
- conseguem processar mais informações com maior eficiência computacional quando comparado as redes Perceptron de multicamadas.
- podem se adaptar a diferentes tamanhos de sinal de entrada.

Para Ige e Sibiya (2024), as CNNs podem ser classificadas pela dimensão dos dados de entrada, sendo comumente dados de 1, 2 ou 3 dimensões, possuindo diversos campos de aplicação, desde aplicações médicas a engenharia. Modelos baseados em CNN ganharam maior destaque quanto a suas aplicações 2D e 3D em algoritmos de visão computacional, sendo utilizados em projetos para reconhecimento de objetos, reconhecimento facial, veículos autônomos etc.

Segundo Kiranyaz et al. (2021), as CNNs podem possuir várias camadas ocultas e milhares de parâmetros, podendo ser utilizadas para aprender objetos e padrões complexos, porém, são necessários bancos de dados massivos para realizar o treinamento de tais algoritmos.


Neste projeto de pesquisa, foi utilizado o software Matlab versão 2024 para programação do algoritmo responsável pelo diagnóstico de falha. Esta ferramenta possui integrada funções pré-programadas para produção de algoritmos CNN, onde se pode especificar as camadas a serem utilizadas pelo algoritmo e suas especificações.

MATERIAL E MÉTODOS

A bancada experimental composta por um servoacionamento sendo um *driver* e servomotor responsável pelo acionamento da máquina rotativa foi desenvolvida para coleta de dados. A referência de rotação é enviada via Controlador Lógico Programável (CLP) via rede de comunicação industrial, a uma taxa de 1000 amostras por segundo. Os dados brutos foram coletados pelo software gratuito

Wireshark, coletando os pacotes de dados no link de comunicação entre CLP e servoacionamento. Ademais, a bancada possui um simulador de carga, que gera diferentes torques resistentes. A figura 1 apresenta o esquemático da bancada experimental.

Figura 1. Esquemático da bancada experimental



Fonte: Autoria própria

Para garantir coleta de dados em diferentes parâmetros, foram utilizadas rotação de 500, 1000, 1500, 2000, 2500 e 3000 RPM, e diferentes valores de torque resistente, simulando cargas distintas. Os dados foram coletados com estes parâmetros na condição de operação saudável, com desbalanceamento e desalinhamento angular.

A partir dos dados brutos, sugere-se o seguinte método para desenvolvimento do sistema inteligente de diagnóstico de falhas.

Tratamento dos dados

Os sinais disponibilizados pelo servoacionamento serão pré-processados utilizando transformada Wavelet Scattering, se captura informações de diferentes escalas e frequências, sendo gerado uma figura, ou seja dados em duas dimensões. Os dados brutos pré-processados são utilizados como variáveis de entrada no classificador para reconhecimento de padrões.

Classificador para reconhecimento de padrões

Os sistemas de inferência objetivam classificar o status de operação da máquina rotativas como normal (sendo operação saudável) ou anormal (sendo possível máquina com desbalanceamento ou desalinhamento angular).

Trata-se de um problema de reconhecimento de padrões, onde planeja-se a investigação dos classificadores *deep learning*, sendo redes neurais convolucionais de duas dimensões.

Adicionalmente, busca-se investigação de ambos sinais rotação e torque, ou somente um destes dois sinais. Trata-se de uma análise relevante, uma vez que pode significar coleta de menos dados e redução do esforço computacional para treinamento e execução dos modelos preditivos.

Avaliação de Desempenho

Para a avaliação dos resultados do sistema diagnóstico gerado a partir desta metodologia alguns indicadores de desempenho são empregados, são eles: acurácia, razão de falso positivo (RFP) e razão de falso negativo (RFN).

Para a validação dos resultados e verificação da capacidade de generalização do sistema foi utilizada a estratégia conhecida como validação cruzada para k-partições, que consiste na divisão dos dados em um número de k partições diferentes, utilizando-se k – 1 partições para treinar o algoritmo e uma única partição para testar. O processo é feito de forma sistemática, e cada partição é composta por amostras selecionadas aleatoriamente. Realiza-se essa repetição por k vezes e os resultados das k avaliações dos indicadores são ponderados utilizado seus valores como métrica de desempenho.

RESULTADOS E DISCUSSÃO

A partir da metodologia, utilizada para classificar o status de operação de máquinas rotativas, foram obtidos alguns resultados relevantes. Foram realizadas modificações em parâmetros, como o tamanho do filtro e a quantidade de convoluções, com o objetivo de avaliar possíveis melhorias no desempenho do modelo. Os valores de acurácia estão apresentados no quadro 1.

Quadro 1. Acurácia rede neural convolucional de duas dimensões

Tam. filtro	Nº Convoluções	Acurácia (%) Erro da velocidade	Acurácia (%) Torque	Acurácia (%) Erro da vel. + Torque
3	3	99.5	98.4	100.0
	2	100.0	96.7	99.7
	1	94.9	85.1	94.4
5	3	100.0	98.7	99.8
	2	99.7	97.2	99.70
	1	96	88.8	98.363
7	3	99.5	99.1	100.0
	2	100.0	97.02	99.8
	1	97.3	89.6	99.1

Fonte: Autoria própria

Observa-se que o tamanho do filtro influenciou diretamente nos resultados: filtros maiores (5 e 7) proporcionaram desempenho mais consistente e acurácia superior em comparação ao filtro 3. De forma parecida, o número de convoluções também impactou positivamente o modelo, sendo que três convoluções resultaram nos melhores índices de acurácia. Com relação aos parâmetros analisados, os sinais de Erro da velocidade e Erro da velocidade + Torque apresentaram desempenho superior, chegando em valores iguais e bem próximos de 1 em várias configurações. Em contrapartida, o parâmetro Torque foi o que mostrou pior resultado de acurácia.

A acurácia foi utilizada para descobrir os parâmetros que apresentaram melhor desempenho, e assim elaborar o quadro 2 com mais informações de erros e acertos na classificação.

Como, 3 convoluções apresentaram, na maioria dos casos, melhor resultado de acurácia, elaborou-se o quadro 2.

Quadro 2. Desempenho da rede neural convolucional de duas dimensões (FPR e FNR)

Tam. filtro	Nº Convoluções	Métrica	Erro da velocidade	Torque	Erro da vel. + Torque
3	3	FPR(%)	0.22	1.52	0
		FNR(%)	0.95	1.90	0
5	3	FPR(%)	0	0.65	0.22
		FNR(%)	0	2.86	0
7	3	FPR(%)	0.43	0.87	0
		FNR(%)	0.48	0.95	0

Fonte: Autoria própria

O quadro 2 mostra as métricas de FNR e FPR. A FNR (*False Negative Rate*) mede a proporção de verdadeiros positivos que foram classificados incorretamente como negativo, enquanto o FPR (*False Positive Rate*) mede a proporção de verdadeiros negativos que foram classificados incorretamente como positivos. O cálculo é realizado usando equações I e II:

$$FPR = \frac{FP}{TN+FP} \quad (I)$$

$$FNR = \frac{FN}{TP+FN} \quad (II)$$

TP - *True positive*, quando o modelo prediz positivo e a classe real também é positiva. Neste caso, o status de operação da máquina normal;

TN - *True negative*, quando o modelo prediz negativo e a classe real também é negativa. Neste caso, o status de operação da máquina anormal;

FP - *False positive*, quando o modelo prediz positivo e a classe real é negativa;

FN - *False negative*, quando o modelo prediz negativo e a classe real é positiva.

A partir do quadro é possível notar que, quando o modelo utiliza os sinais de Erro da velocidade + Torque, a porcentagem de predições errôneas, são menores. Para qualquer tamanho de filtro, o resultado para a combinação de Erro da velocidade + Torque são superiores.

CONCLUSÕES

A partir da pesquisa realizada, foi possível identificar que o sinal de Erro da velocidade apresentou melhor desempenho que o Torque para detecção de falhas em máquinas rotativas. Contudo, a combinação de ambos apresentaram os melhores índices de classificação. Identificou-se também que quantidade de convoluções e o tamanho de cada filtro influenciaram nos resultados. Desta forma, foi possível identificar a importância da escolha adequada dos sinais usados, assim como os parâmetros da rede neural convolucional de duas dimensões.

CONTRIBUIÇÕES DOS AUTORES

M.F.M.: Concepção, Análise formal, Metodologia, Software e Redação – rascunho original. M.G.E.: Curadoria de dados e Investigação. A.L.D.: Concepção, Obtenção de financiamento e Redação – revisão e edição.

AGRADECIMENTOS

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo que está financiando os recursos deste projeto por meio do Edital Nº 329/2021 - "Edital de Fomento para Criação de Centros de Pesquisa e Inovação no IFSP".

REFERÊNCIAS

Dias, A. L.; Turcato, Afonso Celso; Sestito, Guilherme Serpa; Brandao, Dennis; Nicoletti, Rodrigo. A cloud-based condition monitoring system for fault detection in rotating machines using PROFINET process data. *Computers in Industry*, vol. 126, 2021, p. 103394. ISSN 0166-3615. Disponível em: <<https://doi.org/10.1016/j.compind.2021.103394>>. DOI: 10.1016/j.compind.2021.103394. Acesso em: 19/09/2024.

Ige, A. O. e Sibiya, M. State-of-the-art in 1D Convolutional Neural Networks: A Survey. In: *IEEE Access*, [S.l.], 2024, DOI: 10.1109/ACCESS.2024.3433513. Disponível em: <https://ieeexplore-ieee-org.ez338.periodicos.capes.gov.br/document/10609371>. Acesso em: 19/09/2024.

Jardine, A.K.S., Lin, D. and Banjevic, D. A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance. *Mechanical Systems and Signal Processing*, 20, 1483-1510, 2006. <https://doi.org/10.1016/j.ymssp.2005.09.012> Acesso em: 19/09/2024.

Kiranyaz, S.; Avci, O.; Abdeljaber, O.; Ince, T.; Gabbouj, M.; Inman, D. J. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, [S.l.], Volume 151, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0888327020307846>. Acesso em: 19/09/2024.

Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., e Nandi, A. K. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587, 2020. Disponível em: <http://dx.doi.org/10.1016/j.ymssp.2019.106587> Acesso em: 19/09/2024.

Liu, R. et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, vol. 108, 2018, pp. 33-47. Acesso em: 19/09/2024.