



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:
Limitações e possibilidades**



Manutenção Preditiva de Motores Elétricos com Inteligência Artificial

SIMPEP - simpep.feb@unesp.br

UNIVERSIDADE ESTADUAL PAULISTA - UNESP - BAURU-FEB

COMISSÃO ORGANIZADORA DO SIMPEP - simpep.feb.unesp@gmail.com

UNIVERSIDADE ESTADUAL PAULISTA - UNESP - BAURU-FEB

DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO - dep.feb@unesp.br

UNIVERSIDADE ESTADUAL PAULISTA - UNESP - BAURU-FEB

1º AUTOR - estevaosilva@alunos.utfpr.edu.com

UNIVERSIDADE - UTFPR

2º AUTOR - Juliano.Pimentel@akersolutions.com

UNIVERSIDADE – UTFPR

3º AUTOR - ruiyoshino@utfpr.edu.br

UNIVERSIDADE – UTFPR

4º AUTOR - nauber@alunos.utfpr.edu.br

UNIVERSIDADE – UTFPR

5º AUTOR - foronda@utfpr.edu.br

UNIVERSIDADE - UTFPR

ÁREA: 3. PESQUISA OPERACIONAL

SUBÁREA: 3.1 – MODELAGEM, SIMULAÇÃO E OTIMIZAÇÃO

PALAVRAS-CHAVES: MOTORES ELÉTRICOS; MACHINE LEARNING;
MICROCONTROLADOR.

1. INTRODUÇÃO


O desenvolvimento de projetos inovadores, como a manutenção preditiva de motores elétricos com inteligência artificial, exige um profundo entendimento do estado da arte. Um estudo significativo nesta área é o artigo "Estimating Electric Motor Temperatures With Deep Residual Machine Learning – IEEE July 2021", que utiliza redes neurais artificiais (RNAs) para prever temperaturas de componentes de motores. Este trabalho reproduziu e otimizou os métodos utilizados, incorporando a análise de Shapley para entender a importância de cada variável de entrada no modelo de machine learning.

2. METODOLOGIA

O projeto foi dividido em duas principais frentes sendo elas a modelagem matemática e a implementação prática.

Na modelagem matemática desenvolveu-se uma equação matemática para estimar a perda de vida útil de um motor elétrico com base na temperatura de operação. Cada extrapolação de 10°C fora da faixa ideal reduz aproximadamente metade da vida útil restante do motor. Focou-se nas temperaturas dos enrolamentos do motor, por serem as mais altas e críticas para a análise. Dessa forma, um tempo de vida útil é definido no início do processo, o decréscimo natural é estimado e, quando ocorrem falhas, o modelo matemático estima qual o tempo de vida perdido (excedente). Como pode ser visto de maneira resumida na imagem a seguir.

FIGURA 1- Temperatura do motor.




Fonte : Os autores

Na implementação prática utilizou-se microcontroladores e um Raspberry Pi para coletar e enviar dados para a nuvem, onde um modelo de machine learning treinado previamente faz a previsão das temperaturas.

A segunda figura mostra os resultados da rede neural de previsão de temperatura. À esquerda, temos as curvas de treinamento e avaliação para duas métricas de erro, ou seja, o erro médio absoluto e o erro quadrático médio, com as métricas finais exibidas no canto superior direito.

FIGURA 2- Resultados da rede neural



Fonte : Os autores

Este sistema oferece diversas vantagens, como capacidade de processamento e armazenamento ilimitados, manutenção simplificada e escalabilidade. Contudo, enfrenta desafios como dependência de conexão à internet, latência e custo.

3. RESULTADOS E DISCUSSÃO

Os resultados da rede neural na previsão de temperaturas mostraram-se satisfatórios, com baixos erros médios absoluto (MAE) e quadrático (MSE), e uma eficiência de 98,5%. A análise de Shapley foi crucial para reduzir as variáveis de entrada de 135 para 10, sem impactar significativamente o desempenho do modelo. O impacto da temperatura na vida útil do motor foi evidente, com uma redução de 50.000 para cerca de 45.000 horas após 180 horas de operação fora da faixa ideal.

4. CONSIDERAÇÕES FINAIS

Os avanços neste projeto são promissores, mas há um longo caminho até alcançar um modelo robusto para prever falhas. Os próximos passos incluem testes práticos, avaliação de processamento, aperfeiçoamento de RNAs e melhorias na modelagem matemática. Os testes práticos podem ser melhorados com a implementação de um modelo físico com os sensores adequados. A avaliação de processamento pode evoluir através da comparação de diferentes ferramentas para processamento de dados. O aperfeiçoamento de RNAs com o estudo de outras arquiteturas como LSTM Bidirecional e Computação de Reservatório, além de ajustes do RNA atual. Além disso, melhorias na modelagem matemática podem ocorrer por meio de considerações de variáveis além da temperatura e melhorias nas regras de definição de falhas.

Com essas melhorias, será possível prever com maior precisão a vida útil restante dos motores, permitindo a geração de alertas e o agendamento de manutenções de forma mais eficaz.

REFERÊNCIAS

WILHELM KIRCHGASSNER; WALLSCHEID, O.; BOCKER, J. Estimating Electric Motor Temperatures With Deep Residual Machine Learning. v. 36, n. 7, p. 7480–7488, 1 Jul. 2021.

PIMENTEL, J.; MCEWAN, A. A.; HONG QING YU. Towards a Real-Time Smart Prognostics and Health Management (PHM) of Safety Critical Embedded Systems. **2022 25th Euromicro Conference on Digital System Design (DSD)**, 1 ago. 2022.

PIMENTEL, J.; ARIF, J. Communication Network Optimization for Subsea Processing Fields Development. 1 maio 2019.

KIM, S.; CHOI, J.-H.; KIM, N. H. Challenges and Opportunities of System-Level Prognostics. **Sensors**, v. 21, n. 22, p. 7655, 18 nov. 2021.