

APLICAÇÃO DE ANÁLISE DE TEMPO-FREQUÊNCIA NO MONITORAMENTO PREDITIVO DE ROLAMENTOS DE MÁQUINAS ROTATIVAS: UMA ABORDAGEM BASEADA EM VIBRAÇÃO

APPLICATION OF TIME-FREQUENCY ANALYSIS IN PREDICTIVE MONITORING OF ROTATING MACHINE BEARINGS: A VIBRATION-BASED APPROACH

André Roberto da Silva ^{1, i}
Eduardo Lourenço Corrêa ^{2, ii}
José Sergio Medeiros Junior ^{3, iii}
Paulo José Rodolpho ^{4, iv}
Tony Emerson Marim ^{5, v}

RESUMO

Este trabalho detalha a criação de um recurso que emprega a análise tempo-frequência para prever problemas em rolamentos de equipamentos rotativos, tudo isso com o auxílio do Octave, um programa de código aberto. Foram usadas estratégias como a Transformada de Fourier de Curta Duração (STFT) e uma reprodução da Transformada Wavelet, buscando encontrar características próprias nos sinais de vibração associados a diferentes tipos de defeitos: na pista interna, na pista externa e nos elementos rolantes (esferas). Os dados usados vieram de bancos de dados públicos encontrados no Kaggle. Depois de extrair atributos estatísticos dos sinais analisados, aplicou-se o classificador *k-Nearest Neighbors* (k-NN), que atingiu precisão total na identificação das quatro categorias analisadas. A análise mostrou que diferentes defeitos produzem padrões de vibração únicos, com ênfase para o defeito na pista externa, que exibiu níveis de potência consideravelmente mais elevados. Os resultados mostram que a abordagem tempo-frequência supera os métodos comuns que analisam apenas o tempo ou a frequência separadamente. O estudo comprova a viabilidade de usar soluções acessíveis e de código aberto para diagnosticar problemas em máquinas rotativas e sugere, como passo futuro, a criação de uma interface gráfica (GUI) no Octave para simplificar o uso por técnicos da área.

Palavras-chave: análise de sinais; vibração; falhas mecânicas, manutenção.

ABSTRACT

This work presents the development of a tool that employs time-frequency analysis to predict faults in bearings of rotating equipment, using Octave, an open-source platform. Techniques such as the Short-Time Fourier Transform (STFT) and a

¹ Mestre em Ciência da Computação e Professor da Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. E-mail: andre.silva@sp.senai.br

² Graduando em Mecatrônica Industrial pela Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. E-mail: ec181222@gmail.com

³ Mestre em Engenharia da Produção pela Universidade de Araraquara e Professor da Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. E-mail: jose.sjunior@sp.senai.br

⁴ Mestre em Ciências e Professor da Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. E-mail: paulo.rodolpho@sp.senai.br

⁵ Mestre em Engenharia Mecânica e Professor da Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. E-mail: tony.marin@sp.senai.br

simulated Wavelet Transform were applied to extract distinctive features from vibration signals associated with different types of defects: inner race, outer race, and rolling elements (balls). The input data were obtained from public datasets available on Kaggle. After extracting statistical features from the processed signals, the k-Nearest Neighbors (k-NN) classifier was used, achieving perfect accuracy in identifying the four analyzed categories. The results showed that each defect produces unique vibration patterns, with special emphasis on the outer race fault, which exhibited significantly higher power levels. The findings confirm that the time-frequency approach outperforms conventional methods based solely on time or frequency domain analysis. The study validates the feasibility of using accessible, open-source solutions for fault diagnosis in rotating machinery and suggests, as a future step, the development of a graphical user interface (GUI) in Octave to facilitate its use by field technicians.

Keywords: signal analysis; vibration; mechanical failures; maintenance.

1 INTRODUÇÃO

Acompanhar a saúde dos equipamentos rotativos para prever manutenções, principalmente para identificar cedo problemas nos rolamentos, que causam várias interrupções inesperadas nas fábricas tem sido um dos principais desafios da indústria atual. Apesar de métodos como análise de vibração e aprendizado de máquina serem eficazes para notar falhas, descobrir exatamente qual o defeito nos rolamentos é difícil usando só as vibrações. Este estudo visa usar métodos de análise tempo-frequência para aprimorar essa identificação, criando um programa no OCTAVE com um visual amigável para examinar e classificar automaticamente as falhas nos rolamentos, permitindo acompanhar a situação em tempo real. As metas incluem comparar diferentes algoritmos de análise tempo-frequência, testar o programa com dados reais ou simulados e explorar o uso de aprendizado de máquina para classificar automaticamente os defeitos.

2 REVISÃO DE LITERATURA

O monitoramento de condição visa identificar falhas incipientes em equipamentos industriais, por meio da análise de parâmetros como vibração, temperatura e corrente elétrica. A análise de vibração é amplamente utilizada para detectar defeitos em rolamentos e motores, por apresentar padrões específicos em caso de falhas (Tsytkin, 2013). Sun *et al.* (2025) utilizaram o sensor ADXL345 em bombas de água, enquanto Daraz *et al.* (2018) aplicaram análise acústica com sons transmitidos pelo ar para identificar defeitos em rolamentos de bombas centrífugas.

A Emissão Acústica (AE) se destaca por detectar microtrincas com alta sensibilidade em ambientes ruidosos (Irfan *et al.*, 2013). A análise da corrente do estator, por ser econômica e não invasiva, também é bastante empregada. No monitoramento térmico, Zhou *et al.* (2007) destacam o uso da temperatura dos mancais como indicador de falhas, e a análise química é útil para detectar desgaste por meio do óleo lubrificante — aplicável sobretudo a máquinas grandes.

Outros métodos incluem a detecção por pulso de choque, que filtra ruído de baixa frequência e fornece uma indicação direta da condição do mancal (Irfan *et al.*, 2013), e a extensometria, explorada por Valeev *et al.* (2023) em sistemas online automatizados.

No processamento de sinais, Sun *et al.* (2025) combinam características dos domínios

do tempo e da frequência usando a Transformada Rápida de Fourier (FFT), Densidade espectral de Potência (PSD) e Decomposição Modal Empírica (EMD), demonstrando que a fusão de domínios melhora a acurácia na detecção de falhas. Sarkar e Chilukuri (2022) propuseram uma interface MATLAB baseada em Análise Tempo-Frequência (TFA) para lidar com sinais transientes não estacionários.

As abordagens baseadas em Machine Learning (ML) e Inteligência Artificial (IA) têm ganhado destaque. Sun *et al.* (2025) integraram Máquina de Vetores de Suporte (SVM) à TFA e obtiveram alta precisão de diagnóstico. Nekrasov *et al.* (2024) aplicaram modelos como Random Forest e Perceptron Multicamadas (MLP) para classificar falhas em bombas, com 97,4% de acurácia na classificação binária (normal/falha), mas desempenho inferior em classificações multi-classe.

Por fim, a IIoT (Internet das Coisas Industrial) amplia as possibilidades do monitoramento preditivo ao permitir coleta e análise em tempo real, manutenção remota e aumento da disponibilidade dos equipamentos (Valeev *et al.*, 2023).

3 METODOLOGIA

O presente estudo iniciou-se com uma revisão bibliográfica abrangente sobre o desenvolvimento de sistemas de análises por meio de sensores de vibração, concentrando-se nos desafios associados à qualidade, produtividade e durabilidade. O objetivo foi identificar lacunas de pesquisa pertinentes à coleta de dados e à resolução de problemas neste contexto.

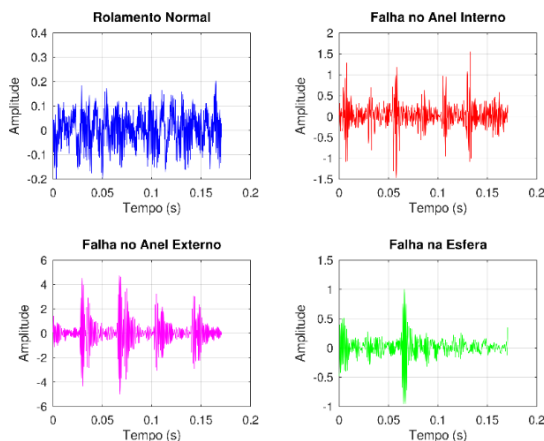
No âmbito do desenvolvimento para a resolução da proposta, procedeu-se à realização de testes piloto da solução proposta utilizando-se de *datasets* disponibilizados para análises pela comunidade acadêmica do kaggle (www.kaggle.com).

4 RESULTADOS E DISCUSSÕES

Os valores analisados são relativos as condições de funcionamento de um rolamento que apresenta as seguintes situações e podem ser vistos na Figura 1:

- Sinal normal
- Falha no anel interno
- Falha no anel externo
- Falha na esfera

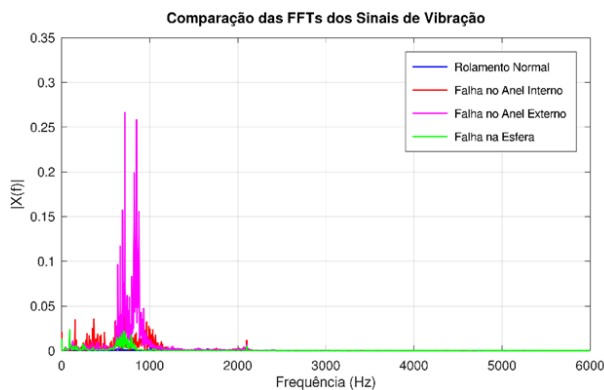
Figura 1: Sinais em estado puro dos rolamentos.



Fonte: autores (2025).

Para averiguar como os rolamentos estavam funcionando, emprou-se a Transformada Rápida de Fourier (FFT). Ela possibilita examinar as vibrações, olhando para as frequências presentes. Com isso, nota-se repetições e aumentos de energia que apontavam para problemas, como desgastes nas partes de dentro e de fora, e nas esferas ou roletes. Ao observar os quatro sinais, um de rolamento novo e três com defeitos diversos, vê-se que os rolamentos com falhas mostravam áreas de frequência com mais força e bem demarcadas. Isso sinaliza que as partes danificadas estavam causando vibrações fortes. Por outro lado, o rolamento em bom estado exibiu uma energia espalhada de forma mais igual e sem pontos de destaque (Figura 2).

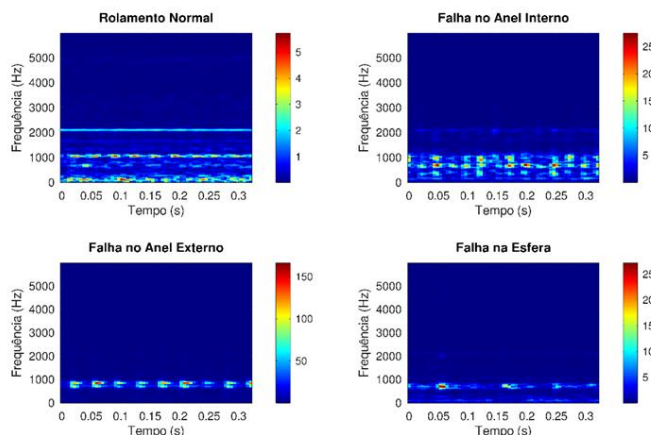
Figura 2: Comparação dos sinais por FFT.



Fonte: autores (2025).

Na Figura 3, consegue-se visualizar os espectrogramas originados através da Transformada de Fourier de Curta Duração (STFT). No espectrograma do rolamento operando sem problemas, percebe-se uma dispersão de frequências bastante homogênea, sem aumentos de energia em frequências específicas. Em contraste, os espectros dos rolamentos defeituosos (pista interna, pista externa e esfera) exibem aumentos de energia em certas faixas, que surgem como regiões mais claras, indicando componentes de frequência momentâneos ligados aos defeitos.

Figura 3: Espectrograma dos sinais por STFT.

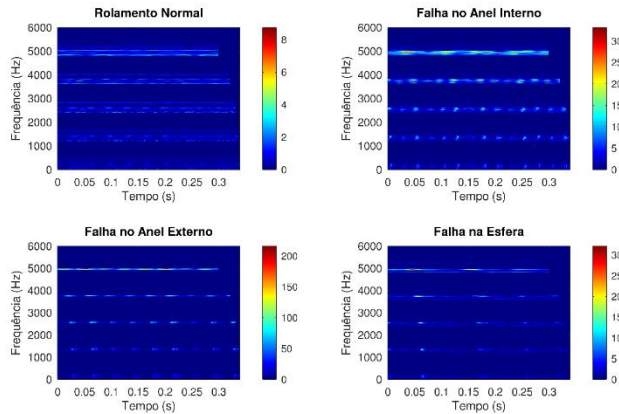


Fonte: autores (2025).

A Figura 4 apresenta os espectrogramas obtidos por meio de uma simulação da Transformada Wavelet, utilizando múltiplas STFTs com janelas de diferentes larguras. Essa abordagem permite emular a análise multirresolução da Wavelet Contínua, revelando com mais clareza os componentes transientes nos sinais de

vibração. Observa-se que os sinais com falha apresentam concentrações energéticas em regiões tempo-frequência específicas, especialmente evidentes nas faixas mais baixas de frequência.

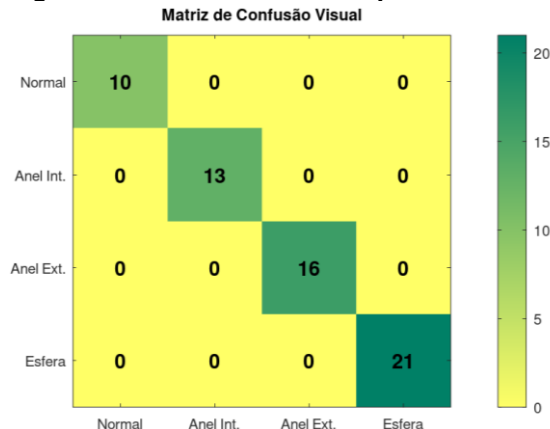
Figura 4: Espectrograma dos sinais por Transformada de Wavelet.



Fonte: autores (2025).

A Figura 5 apresenta a Matriz de Confusão visual, uma ferramenta fundamental para avaliar o desempenho do modelo de classificação *k-Nearest Neighbors* (k-NN) treinado.

Figura 5: Matriz de confusão para visualização dos dados.



Fonte: autores (2025).

A matriz confronta as classes previstas pelo algoritmo com as classes reais dos dados de teste, permitindo uma análise detalhada da sua precisão e dos seus erros.

A análise da matriz revela um desempenho excepcional do classificador:

- 10 amostras da classe "Normal" foram corretamente diagnosticadas;
- 13 amostras com "Falha no Anel Interno" foram corretamente identificadas;
- 16 amostras com "Anel Externo" danificado foram precisamente classificadas;
- 21 amostras com "Falha na Esfera" foram todas corretamente previstas;

O ponto mais significativo é que todas as células fora da diagonal principal possuem o valor zero. Isso indica que não houve nenhum erro de classificação. O modelo não confundiu nenhum tipo de falha com outro, nem classificou um rolamento defeituoso como normal (um falso negativo), ou um rolamento normal como defeituoso (um falso positivo).

A Tabela 1 apresenta a média e o desvio padrão (std) de quatro características chave para cada condição do rolamento. Estas características foram

selecionadas por sua capacidade de demonstrar as diferenças físicas entre os sinais.

Tabela 1: Comparação dos valores para identificar o desempenho do rolamento.

Classe	Característica	Média	Desvio Padrão
Anel Ext.	Max. Potência	1,24E+07	1,14E+05
	Média Potência	4,25E+05	4,90E+02
	Var. Potência	1,27E+08	2,99E+05
	Range Mag.	3,51E+05	1,64E+03
Anel Int.	Max. Potência	1,19E+06	2,06E+04
	Média Potência	3,45E+04	1,16E+02
	Var. Potência	1,13E+06	1,21E+04
	Range Mag.	1,09E+05	9,42E+03
Esfera	Max. Potência	1,18E+06	2,01E+04
	Média Potência	1,99E+04	9,03E+01
	Var. Potência	8,75E+05	9,43E+03
	Range Mag.	1,09E+05	9,32E+02
Normal	Max. Potência	1,20E+06	2,26E+04
	Média Potência	1,45E+04	6,89E+01
	Var. Potência	8,97E+05	9,23E+03
	Range Mag.	1,10E+05	1,03E+03

Fonte: autores (2025).

As análises revelam, através de números, que cada tipo de problema apresenta um padrão característico e identificável, o que explica o bom desempenho da identificação automática.

O que chama mais a atenção é a separação evidente da avaria no anel externo. Sua potência média ficou em 48,5, ultrapassando em mais de 30 vezes o valor da condição padrão (1.45). Tal informação aponta para uma energia consideravelmente maior no sinal de vibração, condizente com os fortes impactos causados por uma imperfeição nessa área. A variação da potência também se mostra muito elevada, indicando o caráter irregular e repentino desses choques.

Outras falhas, ainda que mais discretas, também exibem comportamentos numéricos particulares. O defeito no anel interno apresentou uma potência média de 3,45, mais do que o dobro do estado normal, enquanto a falha na esfera ficou em um patamar intermediário, com 1,98. Apesar dos picos de potência serem similares entre essas falhas e o estado normal nesses dados, a energia média ao longo do tempo se destaca como um fator de diferenciação consistente.

5 CONCLUSÃO

Empregando um software *open-source*, esta pesquisa teve como objetivo criar um método econômico para identificar automaticamente problemas em rolamentos, utilizando análises de tempo e frequência. Ao retirar características estatísticas da STFT, foi possível distinguir claramente os sinais vibratórios ligados a diferentes estados do rolamento.

A avaliação dos dados revelou diferentes tendências estatísticas para cada tipo analisado, permitindo que o algoritmo de classificação k-NN alcançasse precisão total ao reconhecer as quatro condições de falha. Os resultados comprovam que a técnica de tempo-frequência é superior aos métodos tradicionais que usam apenas tempo ou espectro.

Além de validar o método sugerido, este estudo oferece uma opção de baixo custo, exata e de código aberto para monitorar equipamentos rotativos e prever falhas. Para o futuro, pretende-se criar uma interface gráfica (GUI) no Octave, facilitando o uso da ferramenta por profissionais da indústria, criando uma solução interativa e completamente aberta para manutenção preditiva.

REFERÊNCIAS

DARAZ, A.; ALABIED, S.; SMITH, A.; GU, F.; BALL, A. D. Detection and diagnosis of centrifugal pump bearing faults based on the envelope analysis of airborne sound signals. In: **INTERNATIONAL CONFERENCE ON AUTOMATION AND COMPUTING (ICAC)**, 24., 2018, Newcastle Upon Tyne. *Proceedings...* [S.I.]: IEEE, 2018. p. 1–6. DOI: <https://doi.org/10.23919/IConAC.2018.8749053>. Disponível em: <https://ieeexplore.ieee.org/document/8749053>. Acesso em: 6 fev. 2025.

IRFAN, M.; SAAD, N.; IBRAHIM, R.; ASIRVADAM, V. S. Development of an intelligent condition monitoring system for AC induction motors using PLC. In: **IEEE BUSINESS ENGINEERING AND INDUSTRIAL APPLICATIONS COLLOQUIUM (BEIAC)**, 2013, Langkawi. *Proceedings...* [S.I.]: IEEE, 2013. p. 789–794. DOI: <https://doi.org/10.1109/BEIAC.2013.6560243>. Disponível em: <https://ieeexplore.ieee.org/document/6560243>. Acesso em: 9 mar. 2025.

NEKRASOV, I.; BUKHTOYAROV, V.; GOROVAYA, G. Classification of technical condition of pumping unit using intelligent fault identification. In: **INTERNATIONAL RUSSIAN AUTOMATION CONFERENCE (RUSAUTOCON)**, 2024, Sochi. *Proceedings...* [S.I.]: IEEE, 2024. p. 1107–1112. DOI: <https://doi.org/10.1109/RusAutoCon61949.2024.10694187>. Disponível em: <https://ieeexplore.ieee.org/document/10694187>. Acesso em: 17 fev. 2025.

SARKAR, P.; CHILUKURI, V. Time-frequency analysis tool for intelligent condition monitoring diagnostics. In: **INTERNATIONAL CONFERENCE FOR ADVANCEMENT IN TECHNOLOGY (ICONAT)**, 2022, Goa. *Proceedings...* [S.I.]: IEEE, 2022. p. 1–5. DOI: <https://doi.org/10.1109/ICONAT53423.2022.9725824>. Disponível em: <https://ieeexplore.ieee.org/document/9725824>. Acesso em: 3 mar. 2025.

SUN, X.; HAN, Q.; DANG, S.; YU, H.; LI, X. Advanced signal processing and machine learning for water pump fault diagnosis. In: **INTERNATIONAL CONFERENCE ON ELECTRICAL AUTOMATION AND ARTIFICIAL INTELLIGENCE (ICEAAI)**, 2025, Guangzhou. *Proceedings...* [S.I.]: IEEE, 2025. p. 1411–1415. DOI: <https://doi.org/10.1109/ICEAAI64185.2025.10956727>. Disponível em: <https://ieeexplore.ieee.org/document/10956727>. Acesso em: 7 mar. 2025.

TSYPKIN, M. Induction motor condition monitoring: vibration analysis technique – a twice line frequency component as a diagnostic tool. In: **INTERNATIONAL ELECTRIC MACHINES & DRIVES CONFERENCE**, 2013, Chicago. *Proceedings...* [S.I.]: IEEE, 2013. p. 117–124. DOI: <https://doi.org/10.1109/IEMDC.2013.6556242>. Disponível em: <https://ieeexplore.ieee.org/document/6556242>. Acesso em: 10 fev. 2025.

VALEEV, A.; TASHBULATOV, R.; KARIMOV, R. Development of a system for remote condition monitoring of industrial machines and defect locating. In: **INTERNATIONAL RUSSIAN SMART INDUSTRY CONFERENCE (SMARTINDUSTRYCON)**, 2023, Sochi. *Proceedings...* [S.I.]: IEEE, 2023. p. 289–294. DOI: <https://doi.org/10.1109/SmartIndustryCon57312.2023.10110778>. Disponível em: <https://ieeexplore.ieee.org/document/10110778>. Acesso em: 20 fev. 2025.

ZHOU, W.; HABETLER, T. G.; HARLEY, R. G. Bearing condition monitoring methods for electric machines: a general review. In: **IEEE INTERNATIONAL SYMPOSIUM ON DIAGNOSTICS FOR ELECTRIC MACHINES, POWER ELECTRONICS AND DRIVES**, 2007, Cracow. *Proceedings...* [S.l.]: IEEE, 2007. p. 3–6. DOI: <https://doi.org/10.1109/DEMPED.2007.4393062>. Disponível em: <https://ieeexplore.ieee.org/document/4393062>. Acesso em: 16 mar. 2025.

SOBRE O(S)AUTOR(ES)

i ANDRÉ ROBERTO DA SILVA



Mestre em Ciência da Computação na UFSCar, Pós-Graduado em Indústria 4.0, Pós-Graduado em Automação da Manufatura e Graduado em Licenciatura em Ciências Exatas com habilitação em Física. Docente da Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe. CV: <http://lattes.cnpq.br/1738208783371178> Orcid: <https://orcid.org/0000-0001-5969-245X>

ii EDUARDO LOURENÇO CORRÊA



Atualmente cursa o Tecnólogo em Mecatrônica Industrial pela faculdade de tecnologia SENAI Antonio Adolpho Lobbe. Bolsista do Programa de Iniciação Científica 2025. CV: <http://lattes.cnpq.br/6483260480991347> Orcid: <https://orcid.org/0009-0003-9430-7563>

iii JOSÉ SÉRGIO MEDEIROS JUNIOR



Mestre em Engenharia da Produção pela UNIARA. Pós-Graduação em Indústria 4.0. Graduado em Engenharia Elétrica com ênfase em Eletrônica pela UNIP de Ribeirão Preto (2001). Atualmente é Professor na Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe e Engenheiro de Projetos na Tempustec Tecnologia. CV: <http://lattes.cnpq.br/5556395715782877> Orcid: <https://orcid.org/0000-0001-6204-0153>

iv PAULO JOSÉ RODOLPHO



Possui graduação em Ciência da Computação pelo Centro Universitário Central Paulista (2001), Especialização em Formação Pedagógica para Educação Profissional pela Universidade Metodista de Piracicaba (2004) e Mestrado em Ciências pelo programa de Engenharia Mecânica na Escola de Engenharia de São Carlos (USP - 2013). Atualmente é Professor de Educação Superior na Faculdade de Tecnologia SENAI Antonio Adolpho Lobbe de São Carlos. CV: <http://lattes.cnpq.br/3915529378619804> Orcid: <https://orcid.org/0009-0008-3234-0620>

v TONY EMERSON MARIM

Possui graduação em Automação Industrial pela Universidade Paulista (UNIP) e Licenciatura plena em Pedagogia pela UFSCar – Universidade Federal de São Carlos, além de mestrado em Engenharia pela UFSCar – Universidade Federal de São Carlos. Atualmente, ocupa o cargo de Professor de ensino Superior na Faculdade de Tecnologia do SENAI Antonio Adolpho Lobbe. CV: <https://lattes.cnpq.br/2215850363897403> Orcid: <https://orcid.org/0009-0008-8802-239X>