

Capítulo II – Predição de falhas mecânicas em motores elétricos utilizando a análise dos sinais de vibração e redes neurais artificiais

Fabio Soares Sampaio ⁷

Renato Kazuo Miyamoto ⁸

Rodolfo Alexandre Hildebrandt ⁹

Daniel Almeida Colombo ¹⁰

Antonio Carlos Rodrigues ¹¹

RESUMO

Falhas mecânicas em motores elétricos exigem intervenções de manutenção e reparo, resultando em custos devido de inatividade para reparos. Para evitar essas consequências, a manutenção preditiva é crucial. O estudo de métodos preditivos, como a análise de sinais de vibração pode contribuir para prevenir falhas, aumentar a confiabilidade, reduzir gastos e prolongar a vida útil dos motores. Ao monitorar sinais de vibração durante a operação, é possível detectar defeitos, como desalinhamento, antecipadamente, evitando paralisações e interrupções indesejadas na produção. Esse trabalho apresenta um estudo realizado em um motor elétrico usando um sensor de vibração para coletar dados e identificar alterações nos padrões de vibração que afetam o funcionamento.

Palavras-chave: Vibração; Rede neural, Manutenção preditiva

ABSTRACT

Mechanical failures in electric motors require maintenance and repair interventions, resulting in costs due to downtime for repairs. To avoid these consequences, predictive maintenance is crucial. The study of predictive methods, such as the analysis of vibration signals, can help to prevent failures, increase reliability, reduce costs and extend the useful life of motors. By monitoring vibration signals during operation, it is possible to detect defects, such as misalignment, in advance, preventing unwanted stoppages and interruptions in production. This work presents a study carried out on an electric motor using a vibration sensor to collect data and identify changes in vibration patterns that affect the operation.

Key words: Vibration; Neural network; Predictive maintenance.

⁷ Aluno Engenharia Elétrica da UniSenai Londrina, fabiosoressampaio0@gmail.com

² Doutor em Engenharia Elétrica da UniSenai Londrina, renato.miyamoto@sistemafiep.org.br

³ Doutor em Engenharia Mecânica da UniSenai Londrina, rodolfo.hildebrandt@sistemafiep.org.br

⁴ Mestre em Engenharia Mecânica, daniel_colz@outlook.com

⁵ Especialista em Manutenção Industrial da UniSenai Londrina, antonio.rodrigues1@sistemafiep.org.br

1. INTRODUÇÃO

Segundo Petruzella (2013), estima-se que 70% de toda a eletricidade consumida no setor industrial brasileiro seja utilizada para operar os motores elétricos. Os motores industriais exercem um papel fundamental nas operações de diversas indústrias, esses motores são amplamente utilizados para converter energia elétrica em energia mecânica, fornecendo potência e impulsionando máquinas e equipamentos industriais.

São responsáveis por sustentar uma ampla variedade de máquinas e processos essenciais para a produção industrial, como bombas, ventiladores, compressores, transportadores, máquinas-ferramentas, entre outros, eles são encontrados em setores como manufatura, automobilístico, petroquímico, siderúrgico, alimentício, entre outros. A análise de vibração é utilizada como uma ferramenta para detectar e diagnosticar problemas de funcionamento em máquinas elétricas (DUTRA, 2019).

Com isso o uso de algoritmos de inteligência artificial (IA) e aprendizado de máquinas (AM) vem sendo aprimorados e otimizados, mostrando que possui um grande potencial para a criação de sistemas inteligentes de manutenção, que tenham a capacidade de induzir hipóteses de falha a partir da análise de dados coletados.

O objetivo deste trabalho consiste em utilizar um modelo de predição de falhas mecânicas por meio de IA, mais especificamente um rede neural artificial aplicada como ferramenta para a detecção e a previsão de falhas em motores elétricos, considerando diferentes condições de operação e ambientes de trabalho.

2. FUNDAMENTAÇÃO TEÓRICA

Os motores de indução desempenham um papel fundamental na indústria moderna, sendo amplamente utilizados em uma variedade de aplicações devido às suas características de confiabilidade, eficiência e versatilidade. Esses motores funcionam com base no princípio de indução eletromagnética, onde correntes elétricas são induzidas no rotor sem a necessidade de contato físico (PETRUZELLA, 2013).

A porcentagem de utilização de motores de indução na indústria é significativamente alta, sendo uma das tecnologias de acionamento mais comuns em

diversas aplicações industriais. Esses motores são preferidos devido à sua simplicidade, confiabilidade e custo relativamente baixo. Embora não haja um número exato para a porcentagem de utilização, estima-se que a grande maioria das máquinas e equipamentos industriais seja impulsionada por motores de indução.

Eles são amplamente empregados em setores como manufatura, construção, energia, transporte e muito mais. No entanto, como qualquer sistema mecânico, os motores de indução estão sujeitos a uma variedade de falhas que podem impactar negativamente a produção e a eficiência da indústria (DUTRA, 2019).

2.1. FALHAS MECÂNICAS EM MOTORES DE INDUÇÃO

As falhas mecânicas em motores de indução podem ter uma série de impactos significativos. Essas falhas podem resultar em interrupções operacionais, aumento de custos de manutenção, perda de produtividade e, em casos extremos, danos mais severos que podem levar a paralisações prolongadas. Os principais impactos de falhas mecânicas em motores de indução são listados a seguir:

- **Interrupções na Produção:** Falhas mecânicas nos motores de indução podem levar a paralisações não planejadas na produção, causando atrasos na entrega de produtos ou serviços. Isso pode resultar em perda de receita e insatisfação dos clientes.
- **Custos de Manutenção:** A necessidade de reparos e manutenção não programados devido a falhas mecânicas pode aumentar significativamente os custos operacionais. Além disso, a compra de peças de reposição e o pagamento de técnicos de manutenção podem representar um ônus financeiro para a empresa.
- **Perda de Produtividade:** Quando um motor de indução falha, as máquinas e equipamentos conectados a ele ficam inoperantes. Isso resulta em uma diminuição da produtividade, uma vez que os trabalhadores não conseguem executar suas tarefas de forma eficiente.
- **Tempo de Inatividade Prolongado:** Em casos graves de falhas mecânicas, o tempo necessário para reparar ou substituir um motor de indução pode ser prolongado. Isso leva a um tempo de inatividade mais longo, o que pode afetar

significativamente a capacidade da empresa de atender a demanda do mercado.

- **Riscos de Segurança:** Dependendo da natureza da falha mecânica, podem surgir riscos de segurança para os trabalhadores e para o ambiente. Por exemplo, uma falha no sistema de resfriamento do motor pode levar ao superaquecimento, aumentando o risco de incêndio ou explosão.
- **Impacto Ambiental:** Em alguns casos, falhas mecânicas podem resultar em vazamentos de substâncias nocivas, como óleos lubrificantes ou fluidos refrigerantes, causando contaminação ambiental. Isso pode levar a multas, responsabilidade legal e danos à reputação da empresa.
- **Desgaste Prematuro de Equipamentos:** Falhas mecânicas frequentes ou não resolvidas podem levar ao desgaste prematuro de outros componentes e equipamentos conectados ao motor de indução. Isso pode criar um ciclo de manutenção constante e custos adicionais.
- **Incerteza na Programação:** A imprevisibilidade das falhas mecânicas dificulta a programação e o planejamento eficaz da manutenção. Isso pode resultar em equipes de manutenção sobrecarregadas, dificuldades na aquisição de peças de reposição e agendamento de serviços ineficiente.
- **Reputação da Empresa:** Falhas frequentes nos motores de indução podem afetar a reputação da empresa, pois clientes e parceiros podem perceber a empresa como pouco confiável ou incapaz de fornecer produtos e serviços consistentes.
- **Necessidade de Treinamento:** Em algumas situações, as equipes de manutenção podem precisar de treinamento adicional para lidar com as falhas mecânicas específicas do motor de indução, aumentando os requisitos de recursos e tempo.

Para mitigar esses impactos, é essencial implementar uma estratégia sólida de manutenção preventiva, monitoramento contínuo do estado dos motores, uso de tecnologias de diagnóstico avançadas e ações de melhoria no design e operação dos sistemas em que esses motores são empregados. A utilização de redes neurais artificiais pode auxiliar nesse processo.

2.2. REDES NEURAIS ARTIFICIAIS

A Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano. Elas são projetadas para aprender e realizar tarefas complexas, especialmente em áreas como reconhecimento de padrões, processamento de linguagem natural, visão computacional e tomada de decisões.

Uma rede neural artificial é composta por um conjunto de unidades de processamento interconectadas, chamadas de neurônios artificiais ou nós. Esses neurônios são organizados em camadas, geralmente divididas em camada de entrada, camadas intermediárias (também conhecidas como camadas ocultas) e camada de saída. A informação flui através da rede, passando pelos neurônios e suas conexões, que são representadas por pesos.


Durante a fase de treinamento, uma RNA ajusta os pesos das conexões com base em um conjunto de exemplos de entrada e saída esperada. Esse processo é conhecido como algoritmo de aprendizado. Um dos algoritmos de aprendizado mais populares para RNAs é o chamado retropropagação do erro (backpropagation), que calcula o gradiente do erro em relação aos pesos e ajusta-os de forma a minimizá-lo.

Após o treinamento, a rede neural pode ser usada para fazer previsões ou classificar novos dados com base no conhecimento adquirido durante o treinamento. A capacidade das RNAs de lidar com dados complexos e realizar tarefas de aprendizado tornou-as muito úteis em uma ampla variedade de aplicações, incluindo reconhecimento de imagens, reconhecimento de fala, sistemas de recomendação, análise de dados e muitos outros campos.

2.3. Rede Neural TDNN (Time Delay Neural Network)

A rede TDNN é um tipo específico de rede neural projetada para processar dados sequenciais ou temporais, como sinais de áudio, séries temporais ou sequências de texto. A arquitetura TDNN introduz atrasos temporais nos dados de entrada para capturar informações contextuais e relacionamentos sequenciais conforme ilustra a Figura 1.

Figura 1 – Rede TDNN



Fonte: SILVA; SPATI; FLAUZINO (2010)

Uma TDNN geralmente é composta por camadas convolucionais e camadas totalmente conectadas. As camadas convolucionais aplicam filtros ou operações de convolução aos dados de entrada, permitindo que a rede capture padrões ao longo do tempo. Os pesos dos filtros são compartilhados entre diferentes posições temporais, o que ajuda a reduzir a dimensionalidade dos dados e torna a rede mais eficiente.

Após as camadas convolucionais, a saída é passada para camadas totalmente conectadas, onde os neurônios estão conectados a todos os neurônios da camada anterior. Essas camadas processam as informações extraídas pelas camadas convolucionais e podem gerar as previsões ou classificações finais.

3 METODOLOGIA

3.1 SISTEMA PARA PREDIÇÃO DE FALHAS

Para realizar o trabalho e fazer a análise de vibração foi utilizado um motor trifásico da marca Weg modelo W22 Plus de 3 cv. Esse motor está sendo utilizado como ventilador em uma estufa de secagem em uma fábrica metalúrgica localizada na cidade de Londrina/PR. A Figura 2 traz os dados técnicos da placa do motor e a sua localização atual de trabalho.

Figura 2 – Motor para ventilação



Fonte: Do autor (2023)

Para realizar a coleta de dados das vibrações foi utilizado o sensor WEG Motor Scan que foi instalado na carcaça do motor seguindo as orientações do fabricante. Após a instalação os dados podem ser coletados via Bluetooth pelo aplicativo no smartphone, essas informações do motor são enviadas e armazenadas na nuvem e podem ser analisadas com mais profundidade no site WEG Motion Fleet Management. A Figura 3 mostra o modelo de sensor utilizado para a coleta de dados.

Figura 3 – Sensor de vibração Motor Scan




Fonte: Grupo WEG

Para o desenvolvimento do projeto foi utilizado um modelo de rede neural TDNN (Time delay neural network). Para seu treinamento e validação é aplicado um atraso nas entradas, e a previsão dos valores futuros referente ao processo é contado

em função das entradas anteriores, como mostrado na expressão: $x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p))$ e ilustrado na Figura 4.

Figura 4 – Arquitetura PMC com entradas atrasadas no tempo.



Fonte: SILVA; SPATI; FLAUZINO (2010)

O desalinhamento de um motor elétrico se resulta em duas forças, axial e radial, e por consequência, em aumento de vibração nas direções axial e radial. Das 4.053 medições feitas pelo sensor, para realizar o treinamento foram utilizadas 200 amostras de vibração axial e transferidas para uma tabela no Excel, a Figura 5 mostra um dos dados de vibração feito pelo sensor.

Figura 5 – Medições realizadas



Fonte: Do autor (2023)

Para realizar a comparação dos limites de vibração, foi consultado o catálogo técnico do fabricante para saber os limites recomendados de vibração para os motores elétrico do modelo W22. Segundo o fabricante os motores W22 são balanceados dinamicamente com meia chaveta e, em sua configuração padrão, atendem aos níveis de vibração descritos na norma IEC 60034-14, com limites de velocidade de vibração RMS em mm/s, o motor que esta sendo utilizado para o estudo possui uma rotação nominal de 1.760 RPM como pode ser visto na placa de dados técnicos na Figura 2, e esta instalado em uma altura de 1 metro. Com essas informações de acordo com a Figura 6, o limite de vibração do motor é de 1,6 mm/s.

Figura 6 – Limites de velocidade e vibração

Rotação nominal (RPM)	Limites de vibração total de acordo com a altura do motor			
	Até 131mm	Acima de 131mm até 254mm	Acima de 254mm até 399mm	Acima de 399mm
$\geq 500 \leq 1500$	1 mm/s	1,6 mm/s	2,5 mm/s	2,5 mm/s
$> 1500 \leq 3000$	1,6 mm/s	2,5 mm/s	2,5 mm/s	2,5 mm/s

Tabela 8 - Níveis de velocidade de vibração

Fonte: Grupo Weg


Com base nas amostras de dados coletadas e conhecendo os limites de vibração do motor, essas informações foram implantadas para realizar o treinamento usando uma rede neural TDNN. O primeiro passo para fazer o treinamento é a leitura dos dados de treinamento e validação a partir dos arquivos do Excel, fazer a normalização dos dados de treinamento e validação e fazer a definição de parâmetros iniciais, como taxa de aprendizagem (η), precisão (ϵ), número de treinamentos (tr) e valor de momentum.

Em seguida foi feita a execução de três treinamentos para a topologia TDNN 1, com inicialização de variáveis auxiliares para cada treinamento até a convergência do erro mínimo absoluto entre duas épocas consecutivas.

E realizado o armazenamento dos pesos finais ($wf1$ e $wf2$), número de épocas e erro quadrático médio (E_{qm}) de cada treinamento. Após a validação foi feita a plotagem do erro de treinamento (E_{qm}) em relação ao número de épocas para o

treinamento selecionado e a plotagem das saídas de validação desejadas e obtidas para o treinamento selecionado como mostra a Figura 7.

Figura 7 – Treinamento TDNN

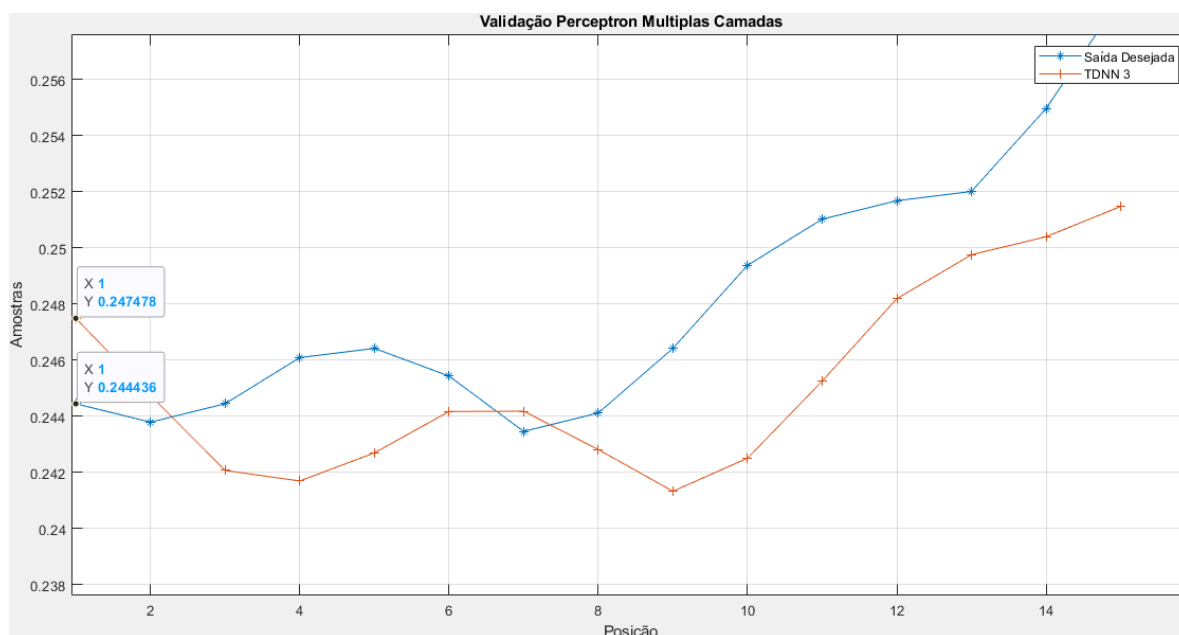


Fonte: Do autor (2023)

Esse treinamento utiliza a função de ativação sigmoide e o treinamento supervisionado backpropagation com momentum para atualização dos pesos. A topologia da rede utilizada é uma TDNN com uma camada escondida de 4 neurônios e uma camada de saída com 1 neurônio.

Em seguida foi realizada uma previsão com base nos dados de teste, carregando os dados de treinamento da rede TDNN e feito a plotagem da previsão de acordo com o treinamento ilustrado na Figura 7.

Figura 7 – Validação TDNN



Fonte: Do autor (2023)

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Com a aplicação de redes neurais TDNN (Time-Delay Neural Networks) nos processos de manufatura, percebe-se que essa ferramenta de monitoramento é eficaz na previsão de condições do funcional e indentificação de falhas. O estudo aplicado da análise de falhas mecânicas direcionados aos motores, pode-se antecipar possíveis problemas potenciais e interrupções significativas ou danos graves, que geram possíveis paradas em produções. Essa técnica apresenta uma combinação e poder de capturar padrões complexos em séries temporais com a capacidade de detectar sensíveis mudanças nos sinais de operação dos motores, permitindo assim, uma melhor análise dos dados obtidos e a identificação precoce de falhas mecânicas, possibilitando posteriormente tomadas de ações assertivas.

5 CONSIDERAÇÕES FINAIS

A análise de vibração em motores elétricos utilizando Redes Neurais Artificiais apresenta um potencial significativo na área de manutenção preditiva. Algumas

dessas vantagens é melhorar a confiabilidade do processo, reduzir custos necessários e agregar valor à organização.

Outras vantagens estão relacionadas à i) aquisição de dados: coletar dados relevantes do motor, como vibração, temperatura, corrente elétrica, pressão, entre outros. Esses dados são normalmente adquiridos de sensores instalados no motor ou em sistemas próximos a ele; ii) pré-processamento de dados: os dados brutos precisam ser pré-processados para remover ruídos, eliminar valores discrepantes e normalizar os dados, garantindo que a rede neural possa aprender com informações significativas; iii) alertas e manutenção preventiva: com base nas previsões da rede neural, os operadores podem receber alertas sobre possíveis falhas iminentes. Isso permite que medidas de manutenção preventiva sejam tomadas antes que a falha ocorra, reduzindo o tempo de inatividade não planejado.

O modelo proposto é aplicável em situações reais de um ambiente industrial e a utilização de Redes Neurais Artificiais na análise de vibração em motores elétricos é uma abordagem promissora para a manutenção. Pode-se concluir que o sucesso do sistema de predição depende da qualidade dos dados e das capacidades dos algoritmos utilizados.

REFERÊNCIAS

PETRUZELLA, Frank. **Motores Elétricos e Acionamentos: Série Tekne**. Bookman Editora, 2013.

DUTRA, Jhonata Teles. **Planejamento e Controle de Manutenção Descomplicado**. 1. ed. Brasília: Engeteles, 2019.

Grupo Weg. Disponível em: <<https://www.weg.net/wegmotorscan/pt>>

Grupo Weg. Disponível em: <<https://static2.weg.net/medias/downloadcenter/hbf/h54/WEG-w22-motor-eletrico-trifasico-de-inducao-tecnico-mercado-africano-50058213-brochure-portuguese-web.pdf>>

SILVA, I. N; SPATTI, D. H; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**: curso prático. 1.ed. São Paulo: Artliber, 2010.