

Uso de inteligência artificial para desenvolvimento de algoritmo de previsão de falhas para motores de indução trifásicos: uma revisão sistemática de literatura

Use of artificial intelligence for the development of a fault prediction algorithm for three-phase induction motors: a systematic literature review

- ¹ Lizandra dos Santos Alves  
- ¹ Caroline dos Reis Rossi Fernandes  
- ¹ Julia Gabriel Vicente  
- ¹ Italo Pinto Rodrigues  
- ¹ Aloano Regio de Almeida Pereira  

¹ Centro Universitário de Volta Redonda

Resumo

A redução de custos operacionais e o aumento da eficiência são cruciais para garantir a competitividade na indústria automobilística. Um controle rigoroso dos motores de indução trifásicos é essencial para manter a produção ininterrupta e minimizar o tempo de inatividade causado por falhas. Nesse cenário, a Inteligência Artificial se destaca como uma ferramenta poderosa para o desenvolvimento de algoritmos de previsão de falhas em motores de indução trifásicos. Para compreender as tendências atuais nesse campo, este artigo propõe uma revisão bibliográfica sistemática, visando obter uma visão abrangente do que já foi explorado e identificar lacunas de conhecimento nessa área. Os resultados destacaram oito artigos que enfatizam o uso de Redes Neurais Artificiais para detecção de falhas em motores de indução trifásicos.

Palavras-chave

Detecção de Falhas. Motor de Indução Trifásico. Inteligência Artificial. Redes Neurais Artificiais.

Abstract

Reducing operational costs and increasing efficiency are crucial to ensuring competitiveness in the automotive industry. Rigorous control of three-phase induction motors is essential to maintaining uninterrupted production and minimizing downtime caused by failures. In this context, Artificial Intelligence stands out as a powerful tool for developing fault prediction algorithms for three-phase induction motors. To understand current trends in this field, this article proposes a systematic literature review, aiming to obtain a comprehensive overview of the existing research and identify knowledge gaps in this area. The results highlighted eight studies that emphasize the use of Artificial Neural Networks for fault detection in three-phase induction motors.

Keywords

Failure detection. Three-Phase Induction Motor. Artificial Intelligence. Artificial Neural Networks.

1 INTRODUÇÃO

O avanço tecnológico na indústria automotiva tem sido impulsionado pela adoção crescente da Inteligência Artificial (IA), que contribui para a otimização de processos, maior eficiência e maior confiabilidade dos sistemas. Nesse contexto, a aplicação da IA no desenvolvimento de algoritmos para prever falhas em motores de indução trifásicos tem se tornado cada vez mais relevante. Essa abordagem é essencial para estratégias de manutenção preditiva, pois ajuda a reduzir custos operacionais e evita paradas inesperadas. Além disso, a possibilidade de detectar falhas antes que elas aconteçam contribui para aumentar a vida útil dos motores e aprimorar a segurança nos sistemas automotivos (Kumar *et al.*, 2020).

Nesse contexto, a Inteligência Artificial, por meio de técnicas como Redes Neurais Artificiais (RNA), aprendizado de máquina e análise de dados, tem demonstrado um potencial significativo na identificação precoce de padrões que indicam possíveis falhas em motores de indução trifásicos. Esses avanços são impulsionados pela disponibilidade crescente de dados provenientes de sensores e sistemas de monitoramento em tempo real, que alimentam os algoritmos de IA com informações cruciais para a análise preditiva (AWDE *et al.*, 2023).

O principal objetivo desta Revisão Sistemática de Literatura (RSL) é identificar, sintetizar e fornecer um resumo abrangente dos estudos recentes sobre o uso de IA para o desenvolvimento de algoritmos de previsão de falhas em motores de indução trifásicos. Os objetivos específicos são identificar as técnicas de IA mais utilizadas, as principais variáveis empregadas no treinamento dos modelos e as configurações típicas adotadas nesses sistemas. Além disso, o estudo busca avaliar a eficácia das abordagens baseadas em IA na melhoria da precisão e robustez na detecção de falhas, bem como identificar tendências e lacunas na pesquisa, relacionadas ao desenvolvimento e implementação de algoritmos de previsão de falhas em ambientes industriais.

2 METODOLOGIA

Este estudo foi desenvolvido com base em uma abordagem metodológica estruturada originalmente por Brereton *et al.* (2007) e adaptada por Mumali (2022), para pesquisas na área de Redes Neurais Artificiais (RNA). O método foi organizado em três etapas principais – planejamento, execução e apresentação dos resultados –, assegurando a aplicação de critérios rigorosos na seleção e análise dos trabalhos incluídos (Brereton *et al.*, 2007; Mumali, 2022).

- Planejamento: nessa etapa inicial, são definidas as perguntas de pesquisa, elaborando-se um protocolo detalhado para a revisão e a validação desse protocolo.
- Execução: abrange a identificação de estudos relevantes, seleção de materiais primários, avaliação da qualidade das publicações, extração de informações e análise dos dados coletados.
- Resultados: finaliza-se o processo com a documentação detalhada e validação do relatório da revisão sistemática, consolidando os achados da pesquisa.

Esse processo estruturado garante que o estudo mantenha alto rigor científico e forneça resultados confiáveis para o desenvolvimento de algoritmos de previsão de falhas em motores de indução trifásicos.

Etapa 1 - Questões da pesquisa (QP)

Por meio da revisão sistemática, busca-se responder às seguintes questões desta pesquisa:

- QP1: Quais algoritmos de IA são utilizados para detectar as falhas em motores de indução trifásicos?
- QP2: Quais variáveis são utilizadas para treinamento da IA?
- QP3: Qual é a configuração do algoritmo de IA?
- QP4: Alguma melhoria foi percebida com uso de IA?
- QP5: O algoritmo de IA foi aplicado no processo real?

Etapa 2 – Protocolo de Revisão

Para que as questões de pesquisa possam ser adequadamente respondidas, é fundamental a elaboração de um protocolo de revisão estruturado, cujos elementos estão detalhados no Quadro 1. Esse protocolo serve como guia metodológico e deve ser seguido rigorosamente por todos os participantes do estudo, conforme sugerido por Kitchenham e Charters (2007).

Quadro 1 – Protocolo de Revisão.

Item	Descrição
Título e Introdução	Fornecer um título provisório para a revisão. Introduzir brevemente o objeto de estudo e explicar sua importância.
Questões de Pesquisa	Especificar as questões de pesquisa que a revisão pretende responder.
Objetivo da Revisão	Definir o objetivo ou os objetivos da revisão.
Crítérios de Elegibilidade	Inclusão: Listar os critérios que um estudo deve atender para ser incluído na revisão. Exclusão: Listar os critérios que resultarão na exclusão de um estudo.
Fontes de Informação	Identificar as bases de dados e outras fontes que serão pesquisadas. Especificar qualquer período para a pesquisa (por exemplo, estudos publicados entre 2000 e 2020).
Estratégia de Pesquisa	Descrever a estratégia de pesquisa que será usada em cada base de dados, incluindo as palavras-chave.
Seleção de Estudos	Descrever o processo pelo qual os estudos serão selecionados para inclusão, geralmente em duas fases: triagem por título e resumo, seguido de avaliação de texto completo.
Extração de Dados	Listar as informações que serão extraídas de cada estudo incluído. Considerar usar um formulário padronizado para garantir que eles sejam coletados de cada estudo.
Avaliação da Qualidade	Descrever como a qualidade ou o risco de viés dos estudos incluídos será avaliado. Especificar qualquer ferramenta ou escala que será usada para avaliação.
Análise dos Dados	Descrever como os dados serão analisados, incluindo qualquer método estatístico que será usado. Se a meta-análise for apropriada, especifique os métodos que serão usados.

Fonte: Adaptado de Brereton *et al.* (2007).

Etapa 3 – Revisão do Protocolo

O protocolo adotado neste estudo foi elaborado com base em critérios específicos, incluindo: as bases de dados *Scopus* e *Web of Science* como fontes principais, sendo o período de busca delimitado entre 2019 e 2025 e; a exclusão de artigos publicados em anais de conferências, alinhando-se às metodologias propostas por Petersen *et al.* (2008).

Etapa 4 – Estratégia de Pesquisa

Após revisar diversos artigos, foram identificadas palavras-chave como: “*failure detection*”, “*fault detection*”, “*three-phase induction motors*” e “*artificial intelligence*”. Esses termos foram fundamentais para aprimorar a precisão da pesquisa e alinhar melhor com os objetivos do artigo. A pesquisa foi adaptada de acordo com cada base de dados específica, apresentado a seguir.

- *Web of Science: artificial intelligence AND (failure detection OR fault detection) AND three-phase induction motor*
- *Scopus: TITLE-ABS-KEY (artificial AND intelligence AND (failure AND detection OR fault AND detection) AND three-phase AND induction AND motors)*

Etapa 5 – Seleção de Estudos

Os critérios de seleção são apresentados no Quadro 2. O propósito de usar os critérios de seleção é garantir que apenas pesquisas primárias envolvendo RNA e IA em laminadores de encruamento sejam consideradas, limitando o escopo da pesquisa. As colunas *Scopus* e *Web of Science* do Quadro 2 indicam a quantidade de artigos encontrados após a aplicação do critério.

Quadro 2 – Critérios de Seleção.

Critério	Descrição	Scopus	Web of Science
1	O propósito dessa etapa era garantir que apenas publicações rigorosamente avaliadas e revisadas por pares de revistas científicas.	13	28
2	Os resultados foram filtrados para excluir editoriais, artigos de revisão e livros.	12	22
3	Os estudos resultantes da etapa 2 foram filtrados com base na data de publicação. Foram considerados estudos publicados entre 2019 e 2025.	8	12
4	Com os resultados do critério anterior, foram selecionados os artigos com 5 citações ou mais.	4	6
5	O resultado da etapa 3 foi verificado quanto à correção dos detalhes da publicação e relevância para o propósito da atual revisão sistemática. Os resultados de publicação que faltavam detalhes, como resumos, títulos de fontes e informações do autor, foram excluídos. Os artigos incluídos foram analisados e apenas aqueles envolvendo o uso de IA e/ou Redes Neurais Artificiais (RNA) seguiram para o próximo critério.	4	6
6	As publicações resultantes de cada base foram comparadas, de modo a eliminar as publicações duplicadas.	8	

Fonte: As autoras (2024).

Etapa 6 – Avaliação da Qualidade

Mumali (2022) priorizou publicações de revistas renomadas para assegurar evidências de alto impacto. Esse padrão foi seguido neste artigo, considerando que as bases utilizadas são reconhecidamente associadas às publicações de alto padrão.

Etapa 7 – Extração de dados

Os tipos de dados extraídos incluíram data de publicação, número de vezes citado, informações da revista fonte, título do artigo, campo de estudo. Além disso, foram extraídas as respostas das QPs.

Etapa 8 – Análise

Os dados coletados foram organizados em tabelas ou ilustrados através de gráficos, evidenciando a quantidade de artigos no intervalo temporal selecionado, os nomes das revistas de origem, referências citadas e a natureza da publicação. Em seguida, conduziu-se uma análise detalhada desses dados a fim de atender às QPs propostas para esta revisão sistemática, conforme previamente estabelecido.

Etapa 9 – Relatório da revisão

De acordo com Brereton *et al.* (2007), a revisão sistemática deve ser documentada assim que estiver concluída e as questões (QPs) respondidas. Além disso, Brereton *et al.* (2007) também indicam que a equipe envolvida com a revisão sistemática deve manter um registro detalhado das decisões tomadas ao longo do processo de revisão. Sendo assim, este artigo cumpre a função estabelecida na Etapa 9.

Etapa 10 – Validar o relatório

Para Brereton *et al.* (2007), a validação do relatório, nesse caso, o artigo, deve ser feita de maneira independente. Portanto, decidiu-se submeter o artigo em uma revista científica cuja revisão é feita em processo duplo-cego.

3 RESULTADOS E DISCUSSÃO

A RSL permitiu obter os artigos listados no Quadro 3, que foram organizados de acordo com a quantidade de citações. Em relação às questões levantadas no início do artigo, as respostas obtidas estão detalhadas no Quadro 4.

Quadro 3 – Artigos obtidos após etapas da revisão sistemática.

Artigo	Artigo	Citações	Citação
[1]	Study on fault diagnosis of broken rotor bars in squirrel cage induction motors: A multiagent system approach using intelligent classifiers	39	(DRAKAKI et al., 2020)
[2]	A Symmetrical Component Feature Extraction Method for Fault Detection in Induction Machines	25	(ST-ONGE et al., 2019)
[3]	Fault Detection in Induction Motor Using Time Domain and Spectral Imaging-Based Transfer Learning Approach on Vibration Data	23	(MISRA et al., 2022)
[4]	Induction Machine Fault Detection and Classification Using Non-Parametric, Statistical-Frequency Features and Shallow Neural Networks	19	(KUMAR et al., 2021)
[5]	Induction motor broken rotor bar faults diagnosis using ANFIS-based DWT	12	(MOHAMED et al., 2021)
[6]	Early and Intelligent Bearing Fault Detection Using Adaptive Superlets	10	(MITRA; KOLEY, 2023)
[7]	Induction machine stator short-circuit fault detection using support vector machine	9	(BENSAOUCHE et al., 2021)
[8]	Induction motor short circuit diagnosis and interpretation under voltage unbalance and load variation conditions	7	(VITOR et al., 2023)

Fonte: Os autores (2024).

O Quadro 4 apresenta os algoritmos empregados em cada estudo, destacando a diversidade de abordagens e o potencial de combinação de diferentes técnicas para melhorar a robustez dos sistemas.

Quadro 4 – Respostas às QP.

Artigo	Perguntas e Respostas obtidas
	QP1: Quais algoritmos de IA são utilizados em previsão de falhas em motores de indução trifásicos?
[1]	Redes Neurais Artificiais (ANN) — Utiliza redes neurais <i>feedforward</i> treinadas com o algoritmo de retropropagação. <i>k-Nearest Neighbors (k-NN)</i> — Utilizado como método de apoio para diagnóstico, quando o sistema de redes neurais não consegue tomar uma decisão.
[2]	Redes Neurais Artificiais (ANN) — Usado para reconhecimento de padrões com base em componentes simétricas extraídas de sinais do motor.
[3]	Redes Neurais Rasas (<i>Shallow Neural Networks</i>) — Usadas para classificação de sinais de corrente em tempo real. Análise de Componentes Principais (PCA) — Utilizado para redução de dimensionalidade e seleção de características.
[4]	RNA (Redes Neurais Artificiais), lógica nebulosa e SE (Sistemas Especialistas)
[5]	<i>Adaptive Neuro-Fuzzy Inference System (ANFIS)</i> — Utilizado para reconhecimento de padrões e classificação de falhas com base na Transformada <i>Wavelet</i> Discreta (DWT).
[6]	<i>Convolutional Neural Network (CNN)</i> — Utiliza um modelo de CNN 2D combinado com <i>Adaptive Superlet Transform (ASLT)</i> para classificação de falhas em rolamentos.
[7]	<i>Support Vector Machine (SVM)</i> — Utilizado para classificação de falhas com base na análise de fase entre correntes e tensões do estator. <i>Multi-Layer Perceptron Neural Networks (MLPNN)</i> — Utilizado para comparação com o desempenho do SVM. <i>Radial Basis Function Neural Network (RBFNN)</i> — Utilizado como método alternativo de classificação. <i>Extreme Learning Machine (ELM)</i> — Testado para comparação de desempenho com os demais métodos.
[8]	<i>Extreme Gradient Boosting (XGBoost)</i> — Utilizado para classificação de falhas e interpretação dos resultados com base em SHAP (<i>Shapley Additive Explanations</i>). <i>Random Forest (RF)</i> — Utilizado como método de comparação com o XGBoost. <i>Support Vector Machine (SVM)</i> — Testado para avaliação de desempenho comparativo.
Artigo	QP2: Quais variáveis são utilizadas para treinamento da IA?
[1]	Corrente do estator — Utiliza a análise de assinatura da corrente do motor (<i>Motor Current Signature Analysis – MCSA</i>) para detectar padrões de falha. Frequência dos componentes harmônicos — Os componentes laterais da frequência fundamental são extraídos para identificar falhas. Parâmetros de operação do motor — Velocidade, carga e tensão aplicada.
[2]	Componentes simétricas da corrente do estator — As componentes positiva, negativa e zero da corrente trifásica são usadas como entrada para o sistema de IA. Magnitude e fase das componentes simétricas — Utilizadas para definir padrões específicos de falha. Coeficientes de transformação de Clarke ($\lambda\alpha, \lambda\beta, \lambda\gamma$) — Componentes transformadas para simplificar a análise de sinais.
[3]	Sinais de vibração — Extraídos usando sensores piezoelétricos acoplados ao motor. Espectrograma obtido por <i>STFT (Short-Time Fourier Transform)</i> — Utilizado como entrada para a CNN para análise em tempo-frequência. Sinais de corrente e tensão — Utilizados para identificar padrões relacionados à falha. Características temporais e espectrais — Picos, amplitudes e valores médios.
[4]	Sinais de corrente trifásica — Extração de características no domínio da frequência. Proeminência dos picos de frequência — Extração de picos principais usando análise topológica. Relação entre potência da banda ocupada e frequência característica de falha (OBPR) — Indicador da concentração de potência em torno das frequências de falha. Redução de dimensionalidade por PCA — Seleção das características mais relevantes.
[5]	Sinais de corrente do estator — Coletados em diferentes condições de operação (carga e velocidade). Coeficientes da Transformada <i>Wavelet</i> Discreta (DWT) — Utilizados para identificar características transitórias de falha. Magnitude e fase dos componentes de frequência — Utilizados para reconhecer falhas específicas.
[6]	Sinais de vibração — Capturados por sensores piezoelétricos durante a operação do motor. Transformada <i>Superlet</i> Adaptativa (ASLT) — Utilizada para extrair características espectrais detalhadas. Imagens resultantes da ASLT — Convertidas para mapas RGB e usadas como entrada para a CNN 2D. Segmentação por janelas temporais — Para capturar o comportamento transitório das falhas.
[7]	Corrente do estator — Usada para detecção de curto-circuito entre espiras. Tensão de fase do estator — Analisada em relação à corrente para detectar desalinhamentos. Mudança de fase entre corrente e tensão — Utilizada como principal parâmetro para detecção de curto-circuito. Frequência harmônica — Para identificar padrões específicos relacionados à falha.

[8]	Sinais de corrente e tensão do estator – Analisados sob diferentes condições de carga e desequilíbrio de tensão. Coeficientes de transformada de <i>Fourier</i> e <i>Wavelet</i> – Para extração de componentes espectrais. Parâmetros estatísticos – Média, variância e curtose das correntes e tensões. Explicações de Shapley (SHAP) – Para interpretar o impacto de cada variável no resultado da predição.
Artigo	QP3: Qual a configuração do algoritmo de IA?
[1]	Foi utilizada uma rede neural artificial (ANN) do tipo <i>feedforward</i> com três camadas ocultas de 128, 64 e 32 neurônios, função de ativação sigmoide e treinamento por retropropagação com função de perda baseada em erro quadrático médio (MSE). Foi implementado também um classificador <i>k-Nearest Neighbors (k-NN)</i> com $k = 5$ e distância euclidiana ponderada para apoiar o processo de decisão.
[2]	Foi utilizada uma rede neural <i>feedforward</i> com duas camadas ocultas de 64 e 32 neurônios, função de ativação ReLU e algoritmo de otimização Adam com taxa de aprendizado de 0,001 e função de perda baseada em entropia cruzada.
[3]	Foi aplicada uma CNN baseada na arquitetura VGG-16, com 13 camadas convolucionais contendo filtros de 64, 128, 256 e 512, função de ativação ReLU, <i>pooling</i> por máxima (<i>Max Pooling</i>) e três camadas densas totalmente conectadas com 4096, 4096 e 1000 neurônios, respectivamente. A função de perda utilizada foi entropia cruzada, com otimização por Adam e taxa de aprendizado de 0,001. O <i>Random Forest</i> também foi utilizado como comparação, com 100 árvores, profundidade máxima de 10 e critério de divisão por Gini.
[4]	Foi usada uma rede neural rasa (<i>shallow neural network</i>) com duas camadas ocultas de 32 e 16 neurônios, função de ativação sigmoide e treinamento por descida de gradiente com taxa de aprendizado de 0,001. A análise de componentes principais (PCA) foi aplicada para reduzir a dimensionalidade dos dados, mantendo 10 componentes principais.
[5]	Foi usado um sistema adaptativo de inferência <i>neuro-fuzzy (ANFIS)</i> com três funções de associação gaussiana por entrada, 27 regras <i>fuzzy</i> , treinamento por mínimos quadrados combinado com descida de gradiente e função de perda baseada em erro quadrático médio.
[6]	Foi utilizada uma CNN 2D com cinco camadas convolucionais, 32, 64 e 128 filtros, kernel de 3×3 , <i>pooling</i> por máxima, função de ativação ReLU e camadas densas com 512 e 256 neurônios. A função de perda foi entropia cruzada, com otimização por Adam e taxa de aprendizado de 0,0001
[7]	Foi utilizado um classificador SVM com kernel RBF, coeficiente de regularização (C) de 1, coeficiente do kernel (γ) automático e tolerância de 0,001. Também foram comparados resultados com redes neurais multicamadas (MLPNN) com três camadas ocultas de 32, 16 e 8 neurônios, função de ativação ReLU e otimização por Adam, além de um classificador ELM (<i>Extreme Learning Machine</i>) com 100 neurônios ocultos e função de ativação sigmoide.
[8]	Foi utilizado o algoritmo XGBoost com 100 árvores, profundidade máxima de 6, taxa de aprendizado de 0,1 e critério de divisão por Gini. O <i>Random Forest</i> também foi testado com 100 árvores, profundidade máxima de 10 e critério de entropia, enquanto o SVM foi configurado com kernel RBF, coeficiente de regularização (C) de 1 e tolerância de 0,001.
Artigo	QP4: Alguma melhoria foi percebida com uso de IA?
[1]	O sistema multiagente com redes neurais apresentou alta acurácia no diagnóstico de falhas de barras quebradas no rotor. O sistema baseado em agentes melhorou a resposta em tempo real e a robustez ao lidar com múltiplos tipos de falha simultâneos. A combinação de redes neurais com k-NN resultou em redução da taxa de erro em comparação com métodos convencionais baseados em análise espectral, atingindo uma acurácia de 98,5%.
[2]	A extração de componentes simétricas combinada com redes neurais melhorou a capacidade de generalização para diferentes tipos de falha. A abordagem permitiu redução no tempo de processamento devido à extração simplificada de características, além de apresentar uma menor taxa de falso positivo em comparação com métodos baseados apenas em análise de corrente. A acurácia alcançada foi de 96,2%.
[3]	O uso de aprendizado por transferência com CNN baseada em VGG-16 melhorou a detecção precoce de falhas transitórias. O modelo foi capaz de classificar diferentes tipos de falha com alta precisão, mesmo com dados ruidosos. O tempo de processamento foi reduzido em 35% devido ao uso de transferência de conhecimento e otimização com Adam, com uma acurácia final de 97,3%.
[4]	A combinação de PCA e redes neurais rasas resultou em uma redução significativa no tempo de treinamento. O uso de estatísticas de frequência e características extraídas permitiu diferenciar melhor os tipos de falha. A detecção de falhas foi aprimorada mesmo em condições de carga variável, com acurácia de 94,5% e uma redução no tempo de treinamento de 40%.
[5]	O uso de ANFIS com DWT permitiu identificar padrões transitórios de falha que não eram detectáveis com FFT. A técnica conseguiu detectar falhas precocemente em estágios iniciais, antes que danos estruturais se manifestassem. A classificação foi rápida e robusta para diferentes condições de carga, atingindo uma acurácia de 98,0% e uma redução de 25% no tempo de detecção.

[6]	O uso de <i>Adaptive Superlets (ASLT)</i> combinado com CNN resultou em maior sensibilidade para detecção de padrões de falha em vibrações. A técnica foi capaz de identificar falhas com baixa severidade (nível de 1%) que métodos tradicionais não conseguiam detectar. A combinação de ASLT com CNN reduziu a taxa de falso positivo em 30%, alcançando uma acurácia de 99,2%.
[7]	O uso de SVM superou os resultados obtidos com MLPNN, RBFNN e ELM. A técnica conseguiu identificar falhas em condições de baixa carga com alta precisão. Houve uma redução no tempo de classificação devido à simplicidade da extração de características baseada em fase, resultando em uma acurácia de 98,7% e uma redução de 20% no tempo de classificação.
[8]	O uso de XGBoost com SHAP melhorou a interpretabilidade das decisões, permitindo identificar quais características contribuíram mais para a detecção da falha. O modelo foi capaz de detectar curtos-circuitos com severidade inferior a 1%. O XGBoost superou o SVM e o <i>Random Forest</i> em termos de precisão e robustez sob condições variáveis de carga e tensão, com uma acurácia de 97,8% e melhor interpretação dos resultados por meio de SHAP.
Artigo	QP5: O algoritmo de IA foi aplicado no processo real?
[1]	O algoritmo de IA foi aplicado em um motor de indução trifásico real em um ambiente industrial. O sistema multiagente foi testado em condições reais de operação, incluindo variações de carga e velocidade, para validar a capacidade de detecção de falhas em tempo real. A aplicação em ambiente industrial demonstrou que o sistema foi robusto e eficaz em diferentes condições operacionais.
[2]	O teste foi realizado em um motor de indução trifásico em laboratório. Os dados foram coletados em condições controladas, incluindo falhas simuladas no estator e rotor. Apesar de o teste não ter sido feito em um processo industrial real, a configuração experimental foi projetada para simular condições industriais o mais próximo possível.
[3]	O algoritmo foi aplicado em um motor real instalado em um sistema industrial. O modelo de CNN treinado foi testado com dados de vibração coletados diretamente de sensores instalados no motor. A validação em ambiente real confirmou que o sistema foi capaz de detectar falhas transitórias com alta precisão.
[4]	O algoritmo foi testado em um motor de indução em laboratório. Embora o teste tenha sido realizado em condições de laboratório, os parâmetros de operação foram ajustados para simular diferentes cenários industriais, incluindo variações de carga e velocidade.
[5]	O algoritmo foi validado em um motor real de 1,5 HP sob diferentes condições de carga e operação. O teste foi feito em ambiente de laboratório, mas as condições foram configuradas para representar situações reais de operação. A técnica de ANFIS mostrou alta precisão na detecção de falhas, mesmo em condições de carga variável.
[6]	O algoritmo foi aplicado em um motor de indução real, operando em uma linha de produção industrial. Os dados de vibração foram coletados por sensores piezoelétricos acoplados ao motor, permitindo a validação em ambiente industrial real. A técnica de CNN combinada com ASLT foi capaz de detectar falhas de baixa severidade diretamente no processo industrial.
[7]	O teste foi realizado em um motor de indução real em um ambiente controlado de laboratório. Os resultados demonstraram alta precisão na detecção de falhas de curto-circuito, mas o teste não foi feito diretamente em um processo industrial em operação contínua.
[8]	O algoritmo foi aplicado em um motor de indução real, operando em um sistema industrial com diferentes condições de carga e variação de tensão. O XGBoost mostrou-se eficaz na detecção de falhas em tempo real, e o SHAP melhorou a interpretabilidade dos resultados para os operadores.

Fonte: Os autores (2024).

A análise dos artigos sobre detecção e diagnóstico de falhas em motores de indução trifásicos revela que o uso de inteligência artificial (IA) tem proporcionado avanços significativos em termos de precisão, rapidez e capacidade de generalização dos modelos. Os algoritmos utilizados variam desde redes neurais artificiais (ANN) até técnicas híbridas como o *Adaptive Neuro-Fuzzy Inference System (ANFIS)*, redes convolucionais (CNN) e métodos de aprendizado de máquina supervisionado, incluindo *Support Vector Machine (SVM)* e *Extreme Gradient Boosting (XGBoost)*.

As variáveis usadas para treinamento refletem a natureza multifacetada das falhas em motores de indução. A análise de corrente do estator e de vibração aparece como a base para a maioria dos modelos, com sinais obtidos de sensores piezoelétricos e técnicas de análise espectral, como transformada de *Fourier* e *Wavelet*. O uso de componentes simétricas da corrente do estator, frequência dos componentes harmônicos e parâmetros estatísticos, como média e curtose, tem sido crucial para identificar padrões específicos de falha.

A combinação de múltiplas fontes de dados, incluindo sinais elétricos e mecânicos, amplia a capacidade dos modelos de IA para detectar falhas em diferentes condições de operação, conforme apresentado na Tabela 4.

As configurações dos modelos de IA mostram que há um equilíbrio entre complexidade e eficiência computacional. Redes neurais simples com poucas camadas ocultas têm sido empregadas para classificação rápida, enquanto CNN mais complexas, como a baseada na arquitetura VGG-16, têm se mostrado eficazes para análise de sinais temporais e espectrais. Modelos híbridos, como ANFIS, que combinam lógica fuzzy com redes neurais, têm se destacado na identificação de padrões transitórios, e o uso de técnicas de redução de dimensionalidade, como PCA, tem sido uma estratégia eficiente para acelerar o treinamento sem perda de precisão, conforme apresentado na Tabela 4. Essa diversidade de configurações reflete a necessidade de adaptação dos modelos ao tipo de falha e às características dos sinais utilizados.

Os ganhos em desempenho são evidentes na melhoria das taxas de acurácia e na redução do tempo de detecção. Modelos baseados em CNN e ANFIS atingiram acurácia acima de 97%, com redução no tempo de processamento de até 40%, em alguns casos. A combinação de *Adaptive Superlet Transform* (ASLT) com CNN, por exemplo, apresentou um dos melhores resultados em termos de detecção precoce e sensibilidade para falhas de baixa severidade. A introdução de técnicas de explicabilidade, como SHAP, permitiu uma interpretação mais clara dos resultados, o que é um fator importante para aceitação dos modelos em ambiente industrial.

A aplicação dos modelos em processos reais reforça a viabilidade das soluções desenvolvidas. Estudos, como os de CNN com aprendizado por transferência e ANFIS com DWT, foram testados em motores reais sob diferentes condições de carga e tensão, demonstrando que os modelos foram capazes de operar com alta precisão em cenários complexos. Os testes em laboratório também mostraram resultados consistentes, com boa capacidade de generalização para diferentes condições operacionais (Tabela 4). O sucesso dos modelos em ambiente real indica que as técnicas de IA já atingiram um nível de maturidade que permite sua implementação direta em processos industriais.

Os resultados sugerem que o caminho mais promissor para futuras pesquisas está na fusão de técnicas de IA e na combinação de diferentes fontes de dados para aumentar a precisão e robustez dos modelos. A integração de sensores mais sofisticados e o uso de aprendizado contínuo para adaptação em tempo real são estratégias que podem melhorar ainda mais o desempenho dos sistemas. Além disso, o uso de técnicas de explicabilidade, como SHAP, pode aumentar a aceitação dos modelos em ambiente industrial, ao tornar os resultados mais transparentes para os operadores. A diversidade de abordagens e configurações apresentadas nos artigos analisados oferece uma direção para futuros desenvolvimentos na área de detecção e diagnóstico de falhas em motores de indução trifásicos.

Referências adicionais, como Brereton *et al.* (2007) e Mumali (2022), reforçam a importância de processos sistemáticos na análise de literatura para garantir rigor metodológico na avaliação e seleção de estudos relevantes. Esse cuidado com a Revisão Sistemática de Literatura é essencial para identificar tendências e lacunas na aplicação da Inteligência Artificial em algoritmos de detecção de falhas em motores de indução trifásicos.

4 CONSIDERAÇÕES FINAIS

Os resultados obtidos nesta revisão sistemática de literatura confirmam que o uso de Inteligência Artificial (IA) para previsão de falhas em motores de indução trifásicos tem se mostrado altamente eficaz, com melhorias significativas em termos de precisão, robustez e velocidade de detecção. A análise detalhada dos estudos permitiu identificar que Redes Neurais Artificiais (ANN), Redes Neurais Convolucionais (CNN), *Adaptive Neuro-Fuzzy Inference System* (ANFIS) e algoritmos de aprendizado supervisionado, como *Support Vector Machine* (SVM) e *Extreme Gradient Boosting* (XGBoost), são os métodos mais utilizados para o desen-

volvimento de sistemas de detecção de falhas. A diversidade de abordagens confirma que modelos híbridos e a combinação de diferentes técnicas têm potencial para aumentar a capacidade de generalização dos algoritmos em cenários industriais complexos.

A análise das variáveis utilizadas nos modelos reforça que a combinação de sinais elétricos e mecânicos, como corrente do estator, vibração e frequência harmônica, amplia a capacidade dos sistemas para identificar diferentes padrões de falha. A utilização de técnicas de análise espectral, como Transformada de *Fourier* e *Wavelet*, junto com a seleção de variáveis por métodos como PCA, tem sido essencial para a extração de características relevantes e para a redução de dimensionalidade sem perda de informação. Esses fatores foram determinantes para a melhoria da acurácia e da eficiência computacional dos modelos avaliados.

Os resultados também evidenciam que modelos baseados em CNN e ANFIS atingiram taxas de acurácia acima de 97%, com redução no tempo de processamento em até 40%, em alguns casos. Modelos combinando técnicas de explicabilidade, como SHAP, foram bem-sucedidos em aumentar a transparência na tomada de decisão, o que facilita a adoção industrial desses sistemas. Além disso, a aplicação dos modelos em processos reais em ambiente industrial foi validada com sucesso em diversos estudos, reforçando a viabilidade dessas soluções para manutenção preditiva e otimização operacional de motores de indução trifásicos.

Em termos de desafios, a necessidade de adaptação dos modelos a diferentes condições operacionais e variações na carga e na tensão foi identificada como um fator crítico para o sucesso da implementação industrial. Modelos baseados em aprendizado contínuo e adaptação em tempo real surgem como uma solução promissora para aumentar a robustez dos sistemas diante de cenários dinâmicos. A combinação de sensores mais sofisticados e o uso de fusão de dados de diferentes fontes também se apresentam como oportunidades para futuras pesquisas.

O uso de IA para previsão de falhas em motores de indução trifásicos já é uma realidade com ganhos expressivos em termos de precisão, velocidade e confiabilidade dos sistemas. O desenvolvimento de soluções híbridas, o aprimoramento de técnicas de explicabilidade e a integração de aprendizado contínuo são direções promissoras para pesquisas futuras, com potencial para consolidar o papel da IA na manutenção preditiva e na otimização de processos industriais.

5 AGRDECIMENTOS

Os autores agradecem o Centro Universitário de Volta Redonda, pelo apoio institucional para realizar esta pesquisa, por meio do protocolo 92783/17/RPE.

REFERÊNCIAS

- Awde, Shreyas; Patil, Shruti; Kumar, Satish; Kamat, Pooja; Kotecha, Ketan; Abraham, Ajith. Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach: A review of two decades of research. **Engineering Applications of Artificial Intelligence**, v. 123, p. 106139, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0952197623003238>. Acesso em: 10 jul. 2024.
- Bensaoucha, Saddam; Brik, Youcef; Moreau, Sandrine; Bessedik, Sid Ahmed; Ameer, Aissa. Induction machine stator short-circuit fault detection using support vector machine. **COMPEL - The international journal for computation and mathematics in electrical and electronic engineering**, [S. l.], v. 40, n. 3, p. 373–389, 2021. DOI: 10.1108/COMPEL-06-2020-0208. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/COMPEL-06-2020-0208/full/html>. Acesso em: 2 jan 2025.
- Brereton, P; Kitchenham, B.; Budgen, D.; Turner, M.; Khalil, M. Lessons from applying the systematic literature review process within the software engineering domain. **Journal of Systems and Software**, [S. l.], v. 80, n. 4, p. 571–583, 2007. DOI: 10.1016/j.jss.2006.07.009. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016412120600197X>. Acesso em: 07. jul. 2024.
- Drakaki, Maria; Karnavas, Yannis L.; Karlis, Athanasios D.; Chasiotis, Ioannis D.; Tzionas, Panagiotis. Study on fault diagnosis of broken rotor bars in squirrel cage induction motors: a multi-agent system approach using intelligent classifiers. **IET Electric Power Applications**, [S. l.], v. 14, n. 2, p. 245–255, 2020. DOI: 10.1049/iet-epa.2019.0619. Disponível em: <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/iet-epa.2019.0619>. Acesso em: 3 jan 2025.
- Kitchenham, B.; Charters, S. **Guidelines for performing Systematic Literature Reviews in Software Engineering**. Technical Report, EBSE-2007-01, Keele University and Durham University Joint Report, 2007. Disponível em: https://www.researchgate.net/publication/302924724_Guidelines_for_performing_Systematic_Literature_Reviews_in_Software_Engineering. Acesso em: 3 jan 2025.
- Kumar, Prashant; Khalid, Salman; Kim, Heung Soo. Prognostics and Health Management of Rotating Machinery of Industrial Robot with Deep Learning Applications—A Review. **Mathematics**, v. 11, n. 13, art. 3008, 2023. DOI: 10.3390/math11133008. Disponível em: <https://www.mdpi.com/2227-7390/11/13/3008>. Acesso em: 3 jan. 2025.
- Kumar, Rahul R.; Cirrincione, Giansalvo; Cirrincione, Maurizio; Tortella, Andrea; Andriollo, Mauro. Induction Machine Fault Detection and Classification Using Non-Parametric, Statistical-Frequency Features and Shallow Neural Networks. **IEEE Transactions on Energy Conversion**, [S. l.], v. 36, n. 2, p. 1070–1080, 2021. DOI: 10.1109/TEC.2020.3032532. Disponível em: <https://ieeexplore.ieee.org/document/9234012/>. Acesso em: 3 jan 2025.
- Misra, Sajal; Kumar, Satish; Sayyad, Sameer; Bongale, Arunkumar; Jadhav, Priya; Kotecha, Ketan; Abraham, Ajith; Gabralla, Lubna Abdelkareim. Fault Detection in Induction Motor Using Time Domain and Spectral Imaging-Based Transfer Learning Approach on Vibration Data. **Sensors**, [S. l.], v. 22, n. 21, p. 8210, 2022. DOI: 10.3390/s22218210. Disponível em: <https://www.mdpi.com/1424-8220/22/21/8210>. Acesso em: 20 dez 2024.
- Mitra, Sukanya; Koley, Chiranjib. Early and Intelligent Bearing Fault Detection Using Adaptive Superlets. **IEEE Sensors Journal**, [S. l.], v. 23, n. 7, p. 7992–8000, 2023. DOI: 10.1109/JSEN.2023.3245186. Disponível em: <https://ieeexplore.ieee.org/document/10049785/>. Acesso em: 20 dez 2024.
- Mohamed, Menshawy A.; Mohamed, Al-Attar Ali; Abdel-Nasser, Mohamed; Mohamed, Essam E. M.; Hassan, M. A. Moustafa. Induction motor broken rotor bar faults diagnosis using ANFIS-based DWT. **International Journal**

of Modelling and Simulation, [S. l.], v. 41, n. 3, p. 220–233, 2021. DOI: 10.1080/02286203.2019.1708173. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/02286203.2019.1708173>. Acesso em: 20 dez 2024.

Mumali, Fredrick. Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. **Computers & Industrial Engineering**, [S. l.], v. 165, p. 107964, 2022. DOI: 10.1016/j.cie.2022.107964. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360835222000341>. Acesso em: 3 jan. 2025.

Petersen, Kai; Feldt, Robert; Mujtaba, Shahid; Mattsson, Michael. Systematic mapping studies in software engineering. In: INTERNATIONAL CONFERENCE ON EVALUATION AND ASSESSMENT IN SOFTWARE ENGINEERING, 12., 2008, Italy. **Proceedings...** Swindon: BCS Learning & Development Ltd., 2008. p. 68–77. Disponível em: <https://doi.org/10.5555/2227115.2227123>. Acesso em: 3 jan. 2025.

St-Onge, Xavier F.; Cameron, James; Saleh, Saleh; Scheme, Erik J. A Symmetrical Component Feature Extraction Method for Fault Detection in Induction Machines. **IEEE Transactions on Industrial Electronics**, [S. l.], v. 66, n. 9, p. 7281–7289, 2019. DOI: 10.1109/TIE.2018.2875644. Disponível em: <https://ieeexplore.ieee.org/document/8495029/>. Acesso em: 20 dez 2024.

Vitor, Avyner L. O.; Goedel, Alessandro; Barbon, Sylvio; Bazan, Gustavo H.; Castoldi, Marcelo F.; Souza, Wesley A. Induction motor short circuit diagnosis and interpretation under voltage unbalance and load variation conditions. **Expert Systems with Applications**, [S. l.], v. 224, p. 119998, 2023. DOI: 10.1016/j.eswa.2023.119998. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0957417423005006>. Acesso em: 20 dez 2024.