

Diagnóstico de Falhas em Máquinas de Indução Via Imagens Térmicas Utilizando Redes Neurais Convolucionais

Jonathan dos Santos Cruz * Mateus Giesbrecht **

* Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP, (e-mail: j264527@dac.unicamp.br).

** Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP, (e-mail: mateus@fee.unicamp.br).

Abstract: In this article, an algorithm combining the Region of Interest identification technique and a Convolutional Neural Network model to diagnose faults in an induction motor is introduced. The algorithm developed in PYTHON on the Google Colab platform was applied to classify 10 different failure modes and the healthy operation of an induction motor, presenting a classification accuracy superior than the Decision Tree, Random Forest, Support Vector Machine and K - Nearest Neighbors.

Resumo: Neste artigo, é apresentado um algoritmo baseado na combinação entre a técnica de identificação da Região de Interesse e o modelo de Redes Neurais Convolucionais para diagnosticar falhas em um motor de indução pela classificação de imagens térmicas. O algoritmo desenvolvido em PYTHON na plataforma Google Colab foi aplicado para classificar 10 diferentes modos de falha da máquina de indução, além da condição saudável, apresentando acurácia de classificação superior as técnicas de Árvore de decisão, Floresta aleatória, Máquina de Vetor Suporte e K-Vizinhos mais próximos.

Keywords: Motor; Classification; Machine learning; Operation conditions; Region of interest.

Palavras-chaves: Motor; Classificação; Aprendizado de máquina; Condições de Operação; Região de interesse.

1. INTRODUÇÃO

Os motores de indução estão entre as máquinas elétricas mais utilizadas. A ampla gama de sua utilização envolve operações críticas e desassistidas em que um procedimento de manutenção preditiva baseado em diagnóstico precoce pode ajudar a evitar falhas catastróficas posteriores. Assim, por questões de segurança e econômicas, é essencial monitorar a condição de motores de diferentes tamanhos, seja de grande ou pequeno porte Jose e Jose (2013). Um objetivo ainda não alcançado é o desenvolvimento de uma abordagem prática generalizada para o diagnóstico de falhas, permitindo que a indústria diagnostique com eficácia diferentes falhas potenciais do motor de indução Faiz et al. (2017).

Diversas técnicas para diagnóstico de falhas em motores de indução vêm sendo desenvolvidas para preencher essa lacuna, concentrando-se em processos teóricos, experimentais e computadorizados para diagnosticar falhas, construindo uma abordagem abrangente e estrutural que permita aos usuários selecionar a estratégia de diagnóstico adequada.

Uma variedade de falhas da máquina, como desequilíbrio dos parâmetros do estator e do rotor, falhas de enrolamento, barras do rotor quebradas, excentricidade e falhas de rolamento podem ocorrer em um motor de indução

Albrecht et al. (1986). Vários métodos de diagnóstico de falhas foram desenvolvidos e aplicados de forma eficaz para detectar falhas de máquinas em diferentes estágios, usando diferentes variáveis de máquina, como corrente, tensão, velocidade, eficiência, temperatura e vibrações. Atualmente, técnicas de diagnóstico por imagem têm sido muito utilizadas por serem metodologias não invasivas e possuírem grande aplicabilidade tanto para análise de órbitas quanto para imagens térmicas.

Recentemente, estudos baseados em Redes Neurais Convolucionais (CNNs) ganharam grande popularidade devido a seu alto desempenho e diversidade de aplicação. No contexto de identificação de falhas, tem-se o estudo de Jeong et al. (2016) onde é utilizada uma CNN para o reconhecimento de padrão de imagem aplicada em formas de órbitas geradas em uma plataforma de teste para diagnosticar o modo de falha. Em Langarica et al. (2019) a detecção e identificação de falhas em tempo real é baseada em Análise de Componente Principal Incremental Dinâmica (DIPCA) e Contribuição Baseada na Reconstrução (RBC). Quando uma falha é detectada pelas medições de vibração, uma Rede Neural Convolucional é usada para identificar o tipo de desequilíbrio ou falha do rolamento.

Singh et al. (2016) propõem uma técnica online e não invasiva que utiliza termografia infravermelha, a fim de detectar a presença de falha entre espiras no acionamento do motor de indução. Dois métodos foram propostos para

detectar a falha e estimar sua gravidade. Um método usa monitoramento térmico transitório durante a partida do motor e outro aplica a técnica de pseudo coloração na imagem infravermelha do motor, depois que ele atinge um estado térmico estável. O modelo projetado para pseudo-coloração está em conformidade com o padrão termográfico da Associação Internacional de Testes Elétricos (NETA) de (Infraspection Institute, 2008). É proposto então um índice para avaliar a gravidade da falha presente no motor.

Em Bai et al. (2016), para aprimorar a extração de informações relacionadas à falha e melhorar à acurácia do diagnóstico, um novo método de análise de imagem infravermelha com base em transformada de contorno não subamostrado é investigado com aprimoramento difuso e ganho não linear. Os parâmetros das funções de aprimoramento *fuzzy* e ganho não linear são otimizados pelo algoritmo de enxame de partículas, em que o critério de otimização é formulado por entropia de informação e contraste de imagem infravermelha. Métodos de extração de características e redução de dimensionalidade são então aplicados para selecionar características para diagnóstico posterior.

Outra metodologia bastante utilizada corresponde à análise de imagens térmicas das condições de operação de máquinas elétricas. A metodologia proposta por Khanjani e Ezoji (2020) é baseada em quatro etapas. Primeiro, a Região de Interesse (ROI) é detectada nos termogramas usando a correspondência de pontos-chave baseada em Transformação de Característica Invariável em Escala (SIFT). Em seguida, as imagens são transformadas em vetores de características representativas com base em uma Rede Neural Convolutiva pré-treinada. Posteriormente, as amostras do vetor de treinamento são agrupadas em *clusters* frios e quentes por *K-means*. Para cada *cluster*, um classificador baseado em SVM é treinado. As amostras de vetor de características de teste são agrupadas e mapeadas em classes usando os classificadores baseados em SVM treinados correspondentes.

No estudo apresentado neste artigo é utilizada a metodologia de identificação da Região de Interesse proposta por Canny (1986) combinada à Rede Neural Convolutiva para classificar as condições de operação da máquina de indução. A classificação é baseada em imagens térmicas obtidas do motor durante a operação em regime permanente na condição saudável e em diferentes condições de falhas internas. Os objetivos são avaliar a acurácia de classificação da CNN e comparar os resultados com os obtidos utilizando as técnicas de Árvore de decisão, Floresta aleatória, SVM e KNN. Após uma ampla revisão bibliográfica verificou-se que a combinação da metodologia de Canny (1986) com à Rede Neural Convolutiva, no contexto de classificação de condições de operação de máquinas de indução, é inovadora no sentido de não haver estudos envolvendo essa combinação.

Para desenvolver o estudo, na seção 2 é descrito como foi feita a coleta de dados. Em seguida, na seção 3, é apresentado o método proposto para o diagnóstico de falhas baseado em imagens térmicas. A seção 4 é dedicada aos resultados obtidos. Finalmente, na seção 5 são apresentadas as conclusões.

2. COLETA DE DADOS

Foram utilizados os dados obtidos em uma plataforma experimental projetada para fins de diagnóstico desenvolvida pela *Babol Noshirvani University of Technology*. Os dados estão disponíveis em Khanjani e Ezoji (2021). A máquina de indução utilizada é de pequeno porte e possui as especificações apresentadas na Tabela 1.

Tabela 1. Especificações da máquina de indução.

Motor de Indução	
Número de fases	3
Tipo de ligação	Y
Potência	1.1 kW
Tensão	220/380 V
Corrente de entrada	5 A
Velocidade	2800 RPM
Frequência	50 Hz

O conjunto de dados é formado por imagens térmicas das condições de operação do motor de indução. A aquisição da imagem térmica foi feita na bancada por uma câmera de imagem térmica infravermelha Dali-tech T4/T8 em um Laboratório de Máquinas Elétricas na temperatura ambiente de 23°C. Todas as falhas geradas no conjunto de dados são internas ao motor e não dependem de peças externas, nem de falha nos componentes elétricos da configuração inicial. Para o motor de indução, são consideradas as condições de Curto-circuito (Cc) nos enrolamentos do estator, Rotor Bloqueado (RB), Falha do Sistema de Ventilação (FSV) e operação Saudável (S). As falhas são detalhadas a seguir, nas subseções 2.1, 2.2 e 2.3.

2.1 Curto-circuito no enrolamento do estator

O enrolamento de estator é formado por espiras de cobre isoladas eletricamente e alocadas em ranhuras especialmente projetadas para essa finalidade. A camada isolante que envolve os fios de cobre tem como função impedir o contato entre as espiras. Quando a isolação tem sua integridade física comprometida, podem ocorrer falhas de curto-circuito entre fases ou entre bobinas de uma mesma fase, ou ainda entre espiras de uma mesma bobina.

As falhas de curto-circuito consideradas neste artigo correspondem ao curto-circuito trifásico entre as fases A, B e C, para 10% (Cc10% ACB) e 30% (Cc30% ACB) dos enrolamentos de cada fase, curto-circuito entre as fases A e C, para 10% (Cc10% AC) e 30% (Cc30% AC) dos enrolamentos de cada fase, curto-circuito entre as fases A e B, para 50% (Cc50% AB) dos enrolamentos de cada fase e curto-circuito entre espiras da fase A, para 10% (Cc10% A), 30% (Cc30% A) e 50% (Cc50% A) do enrolamento.

2.2 Rotor Bloqueado

A falha de rotor bloqueado (ou falha de aceleração) de um motor pode ser causada por diversos fatores, incluindo falha mecânica do motor, falha de alimentação de tensão ou a abertura de uma das fases de alimentação.

2.3 Falha do Sistema de Ventilação

A falha do sistema de ventilação é causada quando o fluxo de ar arrasta consigo poeira e materiais leves que obstruem

aos poucos as aberturas ou canais e impedem a passagem do ar e a dispersão normal de calor.

2.4 Condições de operação da máquina

As condições de operação da máquina de indução com a quantidade de imagens coletadas de cada condição são apresentadas na Tabela 2.

Tabela 2. Diferentes condições do motor de indução.

FSV	RB	Cc50%		Cc30%			Cc10%			S
		AB	A	ACB	AC	A	ACB	AC	A	
28	30	38	35	42	38	37	31	31	34	25
Total de 369 imagens										

3. METODOLOGIA DE DIAGNÓSTICO DE FALHAS

3.1 Estrutura básica do sistema

A estrutura básica do sistema utilizado neste artigo é dada pela Figura 1. A partir do banco de dados utilizado, foi aplicada a técnica de obtenção da Região de Interesse para detectar o corpo do motor, e posteriormente foi construída uma nova base de dados. Então, aplicou-se uma Rede Neural Convolucional para classificação das condições de operação. Os resultados obtidos pela CNN foram interpretados e comparados as metodologias de Árvore de decisão, Floresta aleatória, SVM e KNN.

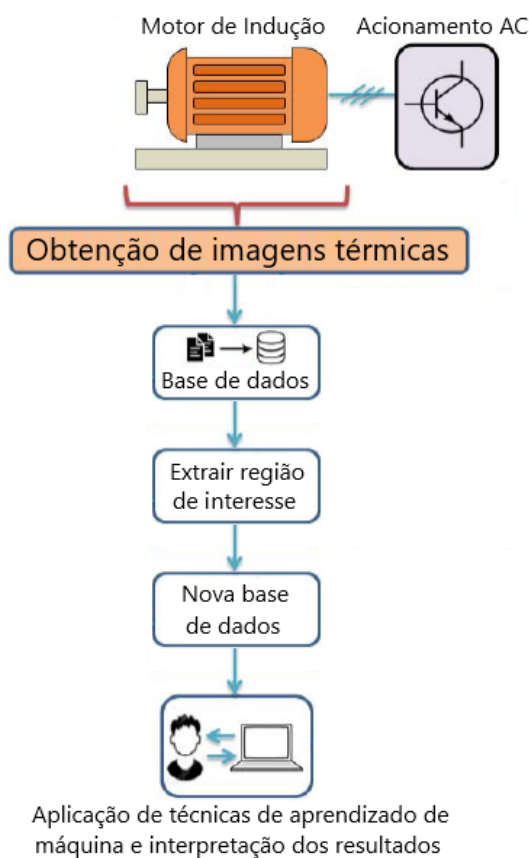


Figura 1. Estrutura do estudo.

3.2 Região de Interesse (ROI)

A Região de Interesse é uma parte de uma imagem que é desejável filtrar, extrair ou realizar alguma outra operação. A extração da Região de Interesse começou com a aplicação da técnica do detector de bordas apresentada em Canny (1986). O operador Canny detectou os pixels da borda do corpo do motor usando um processo de vários estágios. Em primeiro lugar, o limite da região foi suavizado pela aplicação de um filtro Gaussiano. Em seguida, a magnitude G e a direção do gradiente de intensidade da imagem $\theta(x, y)$ foram calculados utilizando as Equações 1 e 2 respectivamente:

$$|G| = \sqrt{I_x^2 + I_y^2} \quad (1)$$

$$\theta(x, y) = \arctan\left(\frac{I_y}{I_x}\right) \quad (2)$$

sendo I_x a primeira derivada na direção horizontal e I_y a primeira derivada na direção vertical. A região então foi varrida ao longo da direção do gradiente da região e, os pixels que não fizeram parte dos máximos locais, foram definidos como zero, processo que é conhecido como supressão não máxima. Então, um limite foi aplicado para selecionar os pixels de aresta relevantes, identificando então as bordas fortes da imagem, ou seja, o corpo do motor. Finalmente, extraiu-se a Região de Interesse utilizando os pontos extremos pertencentes às bordas aplicando um corte retangular na imagem que envolve esses pontos.

Para identificação da Região de Interesse, considerou-se uma imagem de referência com alta temperatura, já que para imagens frias o fundo se confundia com parte do corpo do motor, que resultava em imagens incompletas. Para a imagem de referência obtiveram-se os pontos que delimitam o corpo do motor e, a partir disso, realizou-se a extração da Região de Interesse das outras imagens, sejam elas de alta ou baixa temperatura, já que as imagens possuem o mesmo ângulo de visão. A imagem de referência utilizada com a Região de Interesse detectada (envolvida pelo retângulo verde) e com ela extraída é apresentada na Figura 2.




Figura 2. Operação de extração da Região de Interesse.

Na Figura 3 é possível verificar a Região de Interesse de cada uma das condições de operação do motor. As imagens apresentadas na figura foram utilizadas para a formação da nova base de dados.

O conjunto total de 369 imagens foi utilizado para análise de desempenho do algoritmo, sendo separadas 80% das imagens para o conjunto de treinamento (295 imagens) e 20% para o conjunto de validação (74 imagens). Na Figura 4 é possível identificar como ficou essa divisão com as respectivas classes.

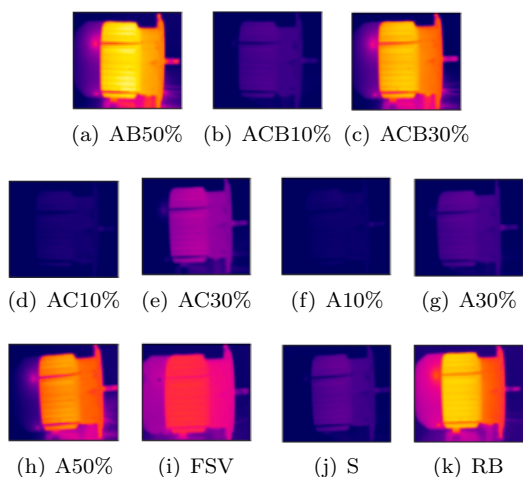


Figura 3. Imagens da nova base de dados.




Figura 4. Quantidade de imagens em cada classe por conjunto.

3.3 Arquitetura da CNN utilizada

A arquitetura da CNN utilizada possui a seguinte estrutura: (i) uma camada convolucional, seguida por (ii) uma camada de *pooling*, conectada a (iii) outra camada convolucional, que está ligada à (iv) uma segunda camada de *pooling*, sendo esta ligada à (v) uma camada *Fully connected*. Na Figura 5 a arquitetura da CNN utilizada é esboçada.




Figura 5. Arquitetura típica da CNN (Adaptado de Géron (2017)).

Inicialmente foi aplicado um processo de convolução com 15 *kernels* de tamanho 5x5 na imagem de entrada de dimensão 240x240. Em seguida aplicou-se a operação de *MaxPooling*, que reduziu o tamanho da imagem em 120x120. Posteriormente, foi executado outro processo de convolução com 30 *kernels* de tamanho 5x5 e na camada subsequente, a operação de *MaxPooling* novamente, que reduziu a dimensão da imagem para 60x60. Após isso utilizou-se a operação *Dropout*, que é de grande importância. Ao contrário da Regularização *L1* e *L2*, o *Dropout* não depende da modificação da função-custo, em vez disso, modifica a própria rede, onde alguns neurônios ocultos foram desativados temporariamente, definindo-se para este um fator de 0.4. Finalmente, após a operação *Dropout*,

a imagem foi transformada em um vetor (30x60x60 = 108000) para ser entrada da camada *Fully connected*, que é uma rede neural tradicional que possui como saídas as condições de operação da máquina de indução. Além disso, para o modelo utilizou-se do otimizador *Adaptive Moment Estimation (Adam)* de Kingma e Ba (2014) e da função-custo entropia cruzada.

3.4 Técnicas utilizadas para comparação de resultados

Após a identificação da Região de Interesse, outras metodologias de classificação além da CNN foram utilizadas como forma de comparação de resultados. Tratam-se das técnicas: Árvore de decisão, Floresta aleatória, SVM com utilização do *kernel* de Função de Base Radial (RBF) e KNN com variação do número de vizinhos mais próximos.

Neste trabalho, a ilustração de matriz confusão é usada para avaliar o desempenho da metodologia proposta, assim como a análise da acurácia de classificação. A acurácia é medida da seguinte forma:

$$Acurácia = \frac{TC_s}{TC_s + FC_s} \quad (3)$$

onde TC_s e FC_s são o número de amostras classificadas como verdadeiras e falsas, respectivamente.

Os algoritmos elaborados para extração da Região de Interesse e aplicação das técnicas de aprendizado de máquina foram desenvolvidos na plataforma *Google Colab* utilizando a linguagem *PYTHON* e executados em nuvem, com a seguinte configuração de *hardware*: processador *Intel Xeon CPU @ 2.30GHz* e *12GB* de *RAM*.

4. RESULTADOS

Para uma primeira análise dos resultados da CNN, a evolução da acurácia de classificação e do comportamento da função-custo ao longo de 200 épocas junto aos dados de treinamento e validação são apresentados nas Figuras 6 e 7. É possível identificar que a acurácia de classificação e a função-custo estão diretamente relacionadas, pois, enquanto a acurácia aumenta com o aumento do número de épocas, a função-custo diminuiu.

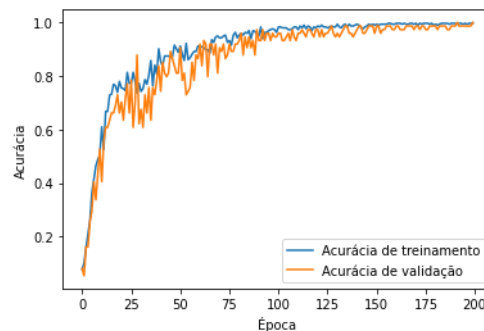


Figura 6. Curva de acurácia.

Com a arquitetura da CNN utilizada obteve-se acurácia de classificação de 100% junto aos dados de validação, sendo as 74 imagens térmicas classificadas corretamente. Na matriz de confusão apresentada na Figura 8 é possível observar as 74 imagens classificadas corretamente, sendo estas indicadas na diagonal principal.

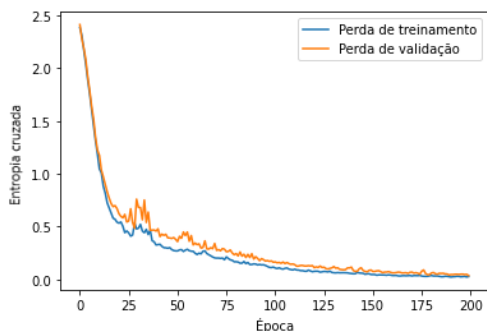


Figura 7. Curva da função-custo.




Figura 8. Matriz de confusão para CNN.

Para o algoritmo de árvore de decisão utilizado, obteve-se acurácia de classificação de 95.94%, sendo 71 imagens classificadas corretamente. A matriz de confusão apresentada na Figura 9 mostra quais classes obtiveram imagens classificadas corretamente e incorretamente.

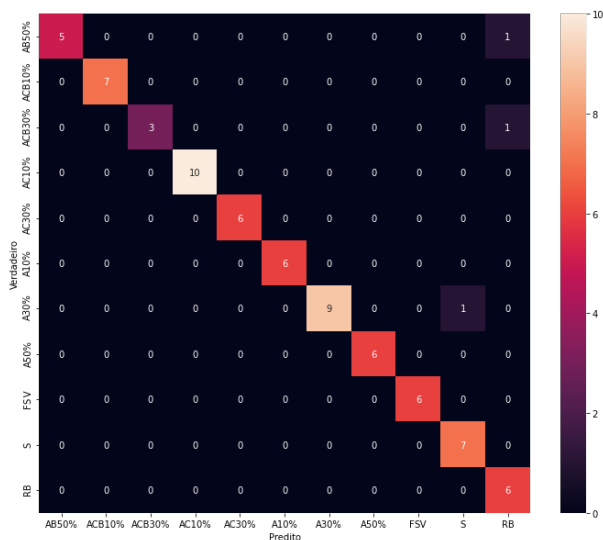


Figura 9. Matriz de confusão para árvore de decisão.

A técnica de floresta aleatória obteve acurácia de classificação de 98.64%. Apenas uma imagem foi classificada incorretamente, como é possível ver na matriz de confusão da Figura 10.




Figura 10. Matriz de confusão para floresta aleatória.

O algoritmo SVM foi aplicado utilizando o *kernel* RBF, obtendo 66.21% de acurácia de classificação, classificando incorretamente 25 imagens conforme apresentado na matriz de confusão da Figura 11.




Figura 11. Matriz de confusão para SVM.

Para técnica do KNN variou-se o valor do K-vizinho mais próximo de 1 a 10 para encontrar o K com melhor acurácia de classificação correspondente. A Figura 12 possibilita identificar que o melhor K corresponde a 1, com acurácia de classificação de 0.93 ou 93%.

Na Figura 13 é apresentada a matriz de confusão para o parâmetro K=1, sendo possível verificar que 5 imagens foram classificadas incorretamente.

Para simplificar a visualização das acurácias de classificação de cada algoritmo tem-se a Tabela 3, que deixa

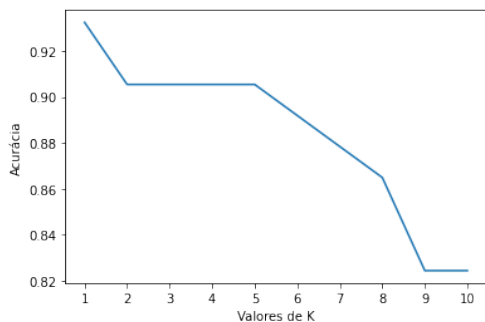


Figura 12. Acurácia e variação de K.




Figura 13. Matriz de confusão para KNN.

explícito que a CNN, Árvore de decisão e o algoritmo de Floresta aleatória obtiveram os melhores desempenhos, sendo o KNN com desempenho próximo ao da Árvore de decisão e o SVM com desempenho bastante inferior.

Tabela 3. Acurácias dos algoritmos.

Técnicas	Acurácias (%)
CNN	100
Árvore de decisão	95.94
Floresta aleatória	98.64
SVM	66.21
KNN	93

5. CONCLUSÃO

Neste trabalho foi proposta a combinação da técnica de obtenção da Região de Interesse com Redes Neurais Convolucionais para o diagnóstico de falhas em máquinas de indução por meio da análise de imagens térmicas obtidas durante os regimes de operação da máquina para as condições de falhas e saudável. O algoritmo apresentou um excelente desempenho e mostrou-se robusto junto aos dados de validação quando comparado as metodologias de Árvore de decisão, Floresta aleatória, SVM e KNN, provando que pode ser de grande utilidade na modalidade de diagnóstico de falhas em máquinas elétricas. Embora em um nível fundamental, o conceito apresentado pode

permitir avanços úteis no desenvolvimento de plataformas de monitoramento de condições autônomas, sendo seu desenvolvimento prático adicional e implementação em tempo real serão objetos de estudos adicionais.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

Albrecht, P., Appiarius, J., McCoy, R., Owen, E., e Sharma, D. (1986). Assessment of the reliability of motors in utility applications – updated. *IEEE Transactions on Energy Conversion*, EC-1, 39–46.

Bai, T., Zhang, L., Duan, L., e Wang, J. (2016). Nsc-based infrared image enhancement method for rotating machinery fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 65, 2293–2301.

Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8, 679–698.

Faiz, J., Ghorbanian, V., e Joksimovic, G. (2017). *Fault Diagnosis of Induction Motors*. The Institution of Engineering and Technology (IET), 1rd edition.

Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn & TensorFlow*. O’Reilly Media, 1rd edition.

Infraspection Institute (2008). *Standard for Infrared Inspection of Electrical Systems & Rotating Equipment*. Burlington, NJ, USA.

Jeong, H., Woo, S., Kim, S., Park, S., Kim, H., e Lee, S. (2016). Deep learning based diagnostics of orbit patterns in rotating machinery. *Annual Conference of the prognostics and health management society*, 1–7.

Jose, G. e Jose, V. (2013). Induction motor fault diagnosis methods: A comparative study. *International Conference on Electrical Engineering (ICEE - 2013)*, 63–69.

Khanjani, M. e Ezoji, M. (2020). Electrical fault detection in three-phase induction motor using deep network-based features of thermograms. *Measurement*, 1—6.

Khanjani, M. e Ezoji, M. (2021). Ir-motor-bmp.rar. <https://data.mendeley.com/datasets/m4sbt8hbk/1/files/b189b1c9-8200-4429-a425-4c45ebccc211>. Acesso em: 5 de jan. de 2021.

Kingma, D. e Ba, J. (2014). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations*, 1, 1–55.

Langarica, S., Ruffelmacher, C., e Nunez, F. (2019). An industrial internet application for real-time fault diagnosis in industrial motors. *IEEE Transactions on Automation Science and Engineering*, 284—295.

Singh, G., Kumar, T.A., e Naikan, V. (2016). Induction motor inter turn fault detection using infrared thermographic analysis. *Reliability Engineering Centre*, 277–282.