# Localização de Faltas em Redes de Distribuição com GD Utilizando Inteligência Artificial

**Celestino P. T. Kalueyo** * **Byron O. Palate** * **Pedro S. De Aragão** * **Silvio G. Di Santo** **

* *Departamento de Engenharia de Energia e Automação Elétrica, Universidade de São Paulo, SP, (e-mail: bpalate@usp.br).*
** *Departamento de Engenharia de Energia e Automação Elétrica, Universidade de São Paulo, SP, (e-mail: silviogiuseppe@usp.br).*
*** *Departamento de Engenharia de Energia e Automação Elétrica, Universidade de São Paulo, SP, (e-mail: pedrosato@usp.br).*

**Abstract:** Fault location is a crucial aspect of electrical power systems. It helps to identify the closest point to the occurrence of a fault, which is advantageous for improving the reliability of the electrical network of utility companies. However, based on the literature review, the problem of locating faults on distribution grids with renewable energy generation still needs improvements. In the literature, several works employ different artificial intelligence models to locate faults and improve the system's observability in real-time. This work used three intelligent algorithms based on neural networks, KNN, and random forest for fault classification and location. The results showed that the algorithms classified and located all faults with 90% accuracy.

**Resumo**: A localização de faltas é um aspecto crucial dos sistemas de energia elétrica. Auxilia na identificação do ponto mais próximo da ocorrência de uma falta, o que é vantajoso para melhorar a confiabilidade da rede elétrica das distribuidoras. Porém, com base na revisão da literatura, o problema de localização de faltas em redes de distribuição com inserção de geração de energia renovável ainda necessita de melhorias. Assim, diversos trabalhos empregam diferentes modelos de inteligência artificial para localizar falhas e melhorar a observabilidade do sistema em tempo real. Portanto, neste trabalho utilizou-se três algoritmos inteligentes baseados em: redes neurais, KNN e Random Forest para classificação e localização de faltas. Finalmente, os resultados mostraram que os algoritmos classificaram e localizaram todas as faltas com 90% de precisão e 98% de accurácia média.

*Keywords:* Artificial intelligence, Renewable energy, faults.
*Palavras-chaves:* Inteligência Artificial, Energia Renováveis, Faltas.

## 1. INTRODUÇÃO

A localização precisa e rápida de faltas em sistemas elétricos é de suma importância para garantir a operação confiável e eficiente do sistema elétrico de potência (Kanwal, et. al 2024). Tradicionalmente, métodos convencionais de localização de faltas podem apresentar limitações em termos de precisão e velocidade de resposta. Portanto, pode resultar em tempo de inatividade prolongado e impactos negativos na qualidade do serviço elétrico. Assim, com os recentes avanços na área de eletricidade, aplicados na inteligência artificial, novas abordagens são exploradas para resolver esse desafio de maneira mais eficaz (Resmi, et. al 2019).

A integração de fontes renováveis de energia Geração distribuída (GD), como sistemas fotovoltaicos (PV) ou fazendas eólicas, em redes de média tensão têm aumentado significativamente . Essas GD tem como intuito mitigar as emissões de gases de efeito estufa e promover a sustentabilidade energética (Palate, et. al 2021). No entanto, essa integração apresenta desafios consideráveis para a operação e manutenção eficientes desses sistemas, especialmente na detecção e localização de faltas.

As técnicas de inteligência artificial podem auxiliar aos métodos convencionais de localização de faltas em sistemas elétricos. Ao combinar a experiência e heurísticas dos métodos tradicionais com a capacidade de aprendizado e generalização dos métodos de inteligência artificial, busca-se alcançar uma melhoria significativa na precisão e na velocidade de resposta do sistema de localização de faltas (Zhang, et. al 2021).

## 2. ESTADO DA ARTE

Na literatura, existem diversos trabalhos dedicados à localização de faltas, visando aprimorar a precisão dos cálculos matemáticos, desenvolver softwares mais eficientes para otimizar os resultados e considerar as complexidades inerentes aos sistemas elétricos de potência (Liang, et.

⋆ CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior).

al 2021). A Figura 1, representa algumas das metodologias existentes para localização de faltas. É importante ressaltar que um estudo sobre localização de faltas pode abranger mais de uma dessas metodologias.

Figura 1. Métodos de localização de faltas

O método proposto em (Di Santo 2022) utilizou uma abordagem de otimização para localizar faltas, minimizando os erros entre as medições e os cálculos dos fasores de tensão e corrente após a ocorrência da falta. A principal vantagem desse algoritmo, em comparação com as técnicas presentes na literatura atual, foi sua capacidade de identificar a localização da falta, independentemente do design e da posição da compensação série na linha de transmissão. As características da tensão e corrente foram processadas usando a Transformada Wavelet Discreta (DWT) e, em seguida, utilizadas para treinar um modelo de Rede Neural Artificial (RNA) desenvolvido para localizar faltas na linha de transmissão. Em (Wang, et. al 2023), os autores propuseram um modelo de Rede Neural Convolucional com Memória de Curto e Longo Prazo (CNN-LSTM). Esse modelo foi projetado para usar imagens de forma de onda transitória como entrada, com o intuito de classificar o tipo de falta em linhas de transmissão, calcular a distância da falta.

No modelo Random Forest (RF) utilizado para a classificação e localização de faltas, foram empregados valores fundamentais de tensão, corrente e componentes de sequência zero das correntes da linha de transmissão de circuito duplo de 100 km e 400 kV como entradas. A técnica proposta foi treinada conforme descrito por (Sunitha et. al 2017), variando os parâmetros de resistência de falta, ângulo de incidência e distâncias ao longo da linha. Por outro lado, (Vincent et. al 2023) modelaram uma linha de transmissão trifásica de 330 kV e 500 km para extrair dados de corrente e tensão com falhas. Esses dados foram usados para treinar uma Rede Neural Artificial (RNA), resultando em 100% de precisão na detecção de falhas e aproximadamente 99,5% na localização de falhas em diversas distâncias. O tempo de detecção foi de 0,0017$\mu$s, com um erro médio variando de 0 a 0,5%.

Em (Sun et. al 2009) utilizaram a Transformada Discreta de Wavelet (DWT) para extrair os coeficientes de frequência dos sinais de tensão e corrente na linha de transmissão. Esses coeficientes foram inseridos como entradas na rede neural durante o treinamento do modelo. A rede neural foi ajustada utilizando o algoritmo de Levenberg-Marquardt, um método de otimização eficaz para o treinamento de redes neurais, permitindo que a rede aprendesse a correlação entre essas características e a presença de faltas na linha de transmissão. Os resultados dos testes mostraram que a estimativa de localização de falhas foi altamente precisa, com um erro percentual médio de 0,001%.

A técnica de validação hold-out, amplamente utilizada para avaliar a performance de modelos preditivos, envolve a divisão do conjunto de dados em duas partes distintas, uma para o treinamento e outra para o teste (Raschka, S., Mirjalili, V., 2020).

## 3. INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) consiste em desenvolver sistemas computacionais capazes de desempenhar tarefas que normalmente requerem intervenção humana. Esses sistemas são projetados para aprender com dados, adaptar-se a diferentes cenários e realizar atividades de forma autônoma, representando um avanço significativo no campo da tecnologia (Andrew, 2020).

### *3.1 Machine Learning*

Machine learning, frequentemente abreviado como ML, refere-se ao processo de adquirir a capacidade de executar uma tarefa específica com base em dados disponíveis ou de identificar e interpretar padrões relevantes presentes nesses dados (Andrew, 2020).

A escolha dos algoritmos de ML para este estudo foi baseada na literatura, trabalhos já consolidados sobre o assunto e na capacidade de cada um em lidar com as particularidades dos dados de localização de faltas em linhas de distribuição e transmissão . Os algoritmos: Random Forest (RF), o K-Nearest Neighbors (KNN) e Redes Neurais Artificiais (RNA), foram escolhidos por suas distintas características e benefícios, an aplicação de localização de faltas. Algoritmos inteligentes baseados em árvores de decisão como o RF é um dos algoritmos mais robustos quando se trata de dados estruturados (Y. Zhu, H. Peng, 2022)

K-Nearest Neighbors (KNN) é um algoritmo baseado em instâncias que classifica uma amostra de dados com base na proximidade dos seus vizinhos mais próximos. Porém, foi escolhido devido à sua simplicidade e eficácia em diferentes cenários de conjuntos de dados de faltas (Koti, et. al 2021).

### *3.2 Redes Neurais Artificiais*

Os fundamentos iniciais do modelo de RNA foram estabelecidos por (Oliveira, 2018), os quais apresentaram uma versão mais simplificada do neurônio artificial. Tal modelo demostrou de maneira matemática, os neurônios presentes no cérebro humano. Atualmente, as novas pesquisas tem à disposição modelos mais avançados, com diversas topologies de análise. No entanto, a verdadeira essência de suas capacidades e funcionalidades reside na interconexão dos neurônios em camadas e arquiteturas diversas. Portanto, a descrição matemática de um neurônio simples é mostrada em (1).

$$u_k = \sum_{j=1}^{n} w_{kj} * x_j + b_k \tag{1}$$

Cada entrada, $x_j$ é associado a um peso específico $w_{kj}$, adiocionado do $b_k$. Inicialmente, realiza-se uma soma ponderada das entradas multiplicadas pelos pesos. Em seguida,

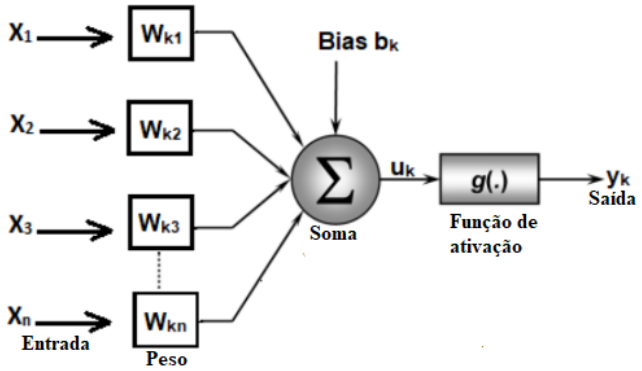


Figura 2. Arquitetura básica de rede neural (Kalueyo, 2023)

o resultado da soma, $u_k$, é submetida a uma função de ativação que determina a saída final do modelo $y$, conforme ilustrado em (2).

$$y_k = g(u_k) \tag{2}$$

A saída do neurônio, representada por $y_k$, é influenciada pela função de ativação $g$, que opera sobre a entrada do neurônio para determinar seu resultado. A Figura 2 ilustra como os neurônios processam informações e como as redes neurais desempenham tarefas de aprendizado.

## 4. METODOLOGIA PROPOSTA

Nesta seção é apresentada a metodologia proposta para a localização de faltas em redes de distribución. Assim, na seção 4.1 se mostra a classificação das faltas e já, na seção 4.2 se apresenta a lógica da localização de faltas.

### *4.1 Classificação de faltas*

A classificação do tipo de falta desempenha um papel crítico na eficiência, segurança e confiabilidade dos sistemas elétricos de potência. Essa classificação possibilita a adoção de medidas mais direcionadas, resultando em respostas rápidas e eficazes na localização de faltas. Para este propósito, foram instalados medidores em todas as barras do sistema teste abordado neste trabalho. Esses medidores, registraram os sinais de tensão e corrente antes, durante e após a falta. Os dados registrados foram armazenados em um banco de dados e empregados no treinamento de modelos de IA para classificação de diferentes tipos de faltas. Tais faltas são: fase terra (A-G, B-G, C-G), duplo-fase (A-B, B-C, C-A), duplo fase-terra (AB-G. BC-G, AC-G) e trifásica (ABC).

Na Figura 3, estão ilustradas faltas trifásicas e monofásicas a terra, onde a variável $R_f$ representa a resistência de falta. Essa resistência foi ajustada em diferentes valores ao longo do processo de simulação do circuito analisado.

O fluxograma apresentado na Figura 4 mostra a topologia do modelo de classificação de faltas (CF) desenvolvido para este trabalho. No qual $V_{abc}$ e $I_{abc}$ representam as tensões e correntes medidas nas barras da rede teste, utilizadas como entradas para o treinamento dos modelos de IA.

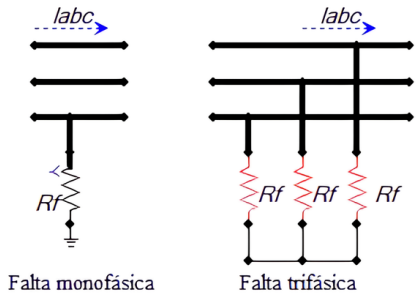


Figura 3. Tipos de Faltas

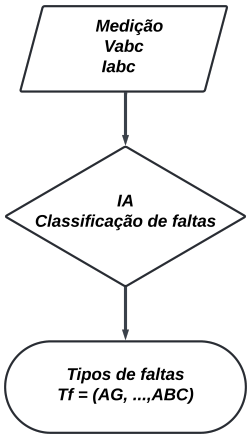


Figura 4. Fluxograma de classificação

### *4.2 Localização de Faltas*

Após a conclusão do processo de classificação do tipo de falta, foram desenvolvidos modelos de IA capazes de identificar e, posteriormente, localizar defeitos. Para o treinamento dos modelos de localização de falta, foram utilizadas as mesmas informações empregadas nos modelos de classificação de tipo de falta. No entanto, também foram consideradas as informações de saída dos modelos de tipo de falta, conforme mostrado na Figura 5.

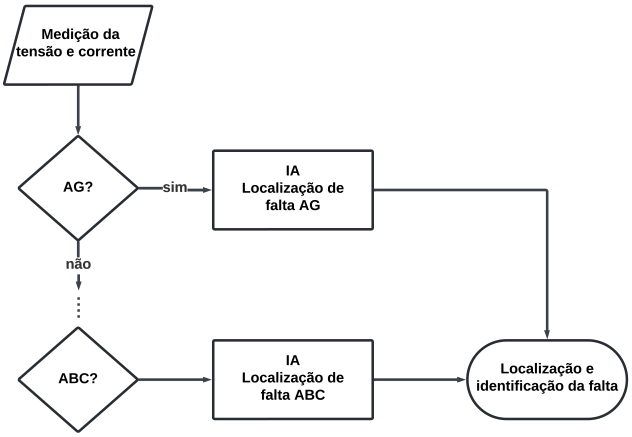


Figura 5. Identificação do local de Faltas

O processo de identificação do local da falta ocorre inicialmente com base no tipo de falta identificado. Assim,

um modelo de IA é treinado para estimar a localização da falta considerando os sinais de tensão e corrente para cada uma. Portanto, se o modelo de classificação detecta uma falta, se ativa um modelo de localização treinado especificamente para identificar o ponto de defeito. Da mesma forma, procede-se com a localização para os outros tipos de falta. Além disso, a saída do modelo indicará a posição estimada da falta.

## 5. SISTEMA TESTE

Com o propósito de demonstrar as técnicas de IA detalhadas para localização de faltas, neste trabalho realizou-se um modelo de parque eólico (Wind Power - WP). O sistema teste é modelado no programa computacional Power Factory - DIgSILENT (PowerFactory 2021) adaptado de um sistema IEEE de 14 - barras. O parque eólico é composto por doze turbinas eólicas, cada uma com capacidade de 0,5 MW, e está integrado a um sistema elétrico de 13,8 kV. A energia gerada por este parque é exportada para uma rede de 69 kV através de um alimentador de 13,8 kV com uma extensão de 1 km. Na Figura 6 mostra-se o circuito da fazenda eólica modelado. Já, na Figura 7 se apresenta o sistema elétrico da IEEE 14-bus conectado à fazenda eólica.

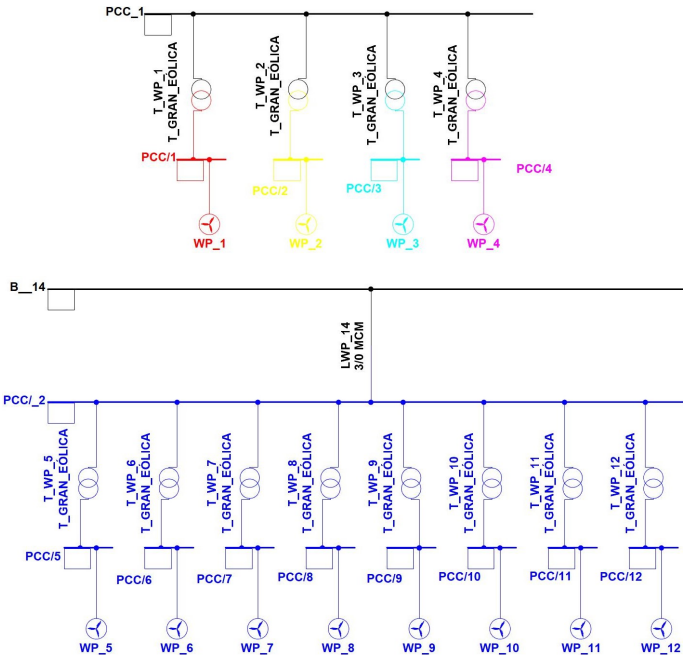


Figura 6. Modelo da fazenda eólica

O parque eólico foi simulado por meio de uma fazenda eólica de doze turbinas, que contém uma capacidade total de 6 MW. Além disso, uma característica importante desse sistema é o uso de geradores de indução de gaiola de esquilo (IG) no modelo das turbinas eólicas.

Com o objetivo de analisar o comportamento do parque eólico durante a ocorrência de defeitos, uma metodologia de localização de faltas utilizando IA é proposto. O sistema teste foi simulado com três valores distintos de resistência, para todo tipo de falta, como é apresentado na Tabela 1.

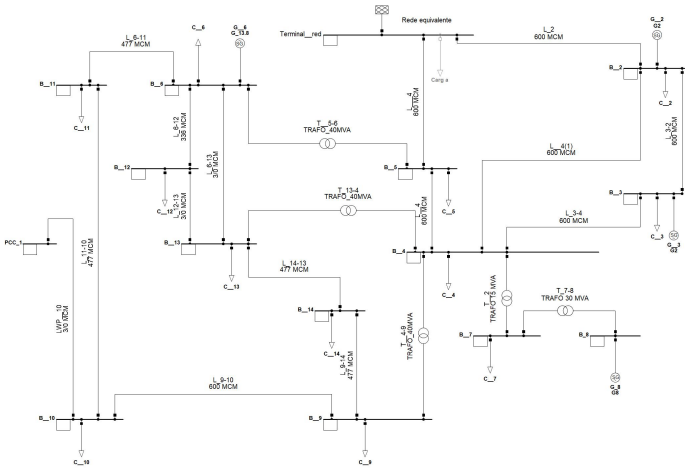


Figura 7. Sistema elétrico 14 - bus adaptado da IEEE (PowerFactory 2021)

Tabela 1. Tipo de falta testado

| Barra de falta | Tipo de falta | Rfalta |
|---|---|---|
| B2 - B14 | Trifásica (ABC) | 5 |
| | Duplo fase terra (AB, BC, CA) | 50 |
| | Fase terra (A, B, C) | 100 |

Aa Figura 8 mostra as tensões e correntes de falta na barra 14 (caso de mostra), com o fim de confrontar os dados obtidos no programa computacional.

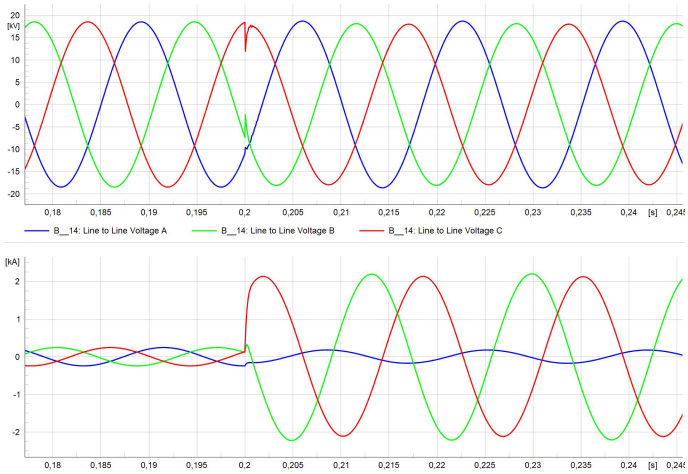


Figura 8. Tensão e corrente de falta na barra 14

Conforme evidenciado na Figura 9 (DIgSILENT, 2021), o bloco representa o processo de obtenção de dados por meio de medidores de tensão e corrente instalados nas barras da rede, como mostra a Figura 8. Esses dados são necessarios para alimentar os modelos de classificação e localização de faltas do modelo teste.

### *5.1 Definição dos Dados*

No processo de classificação de faltas, o banco de dados foi composto por um total de 12300 amostras simuladas em todas as barras, abrangendo quatro tipos de faltas, com 3075 amostras para cada tipo. Para a análise, o conjunto de dados foi dividido em 70% para treinamento e 30%

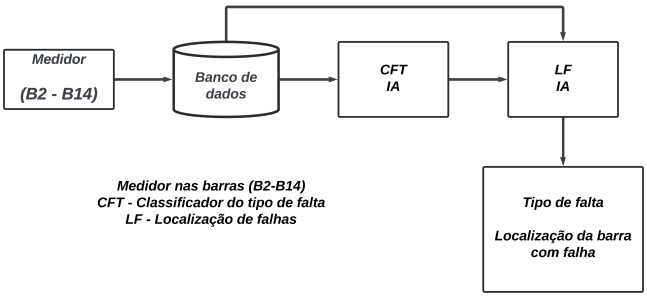


Figura 9. Bloco para classificação e localização de falta

para teste, utilizando a técnica de validação hold-out. Esse mesmo processo de divisão de dados foi adotado para a localização de faltas.

### *5.2 Acurácia dos modelos IA*

Neste estudo, foram avaliados três modelos de inteligência artificial para a localização de faltas, Random Forest, KNN e Rede Neural Artificial (RNA). A análise dos resultados revela que o modelo Random Forest apresentou um desempenho significativamente superior aos outros dois, como apresentado na Tabela 2.

Tabela 2. Acurácias dos modelos de IA

| Tipo de falta | Barra | Random Forest | KNN | RNA |
|---|---|---|---|---|
| AB | B8 | 0,99 | 0,98 | 0,97 |
| AB | B14 | 0,99 | 0,75 | 0,87 |
| AG | B14 | 0,98 | 0,95 | 0,94 |
| ABC | B14 | 0,99 | 0,97 | 0,96 |
| ABC | B2 | 0,99 | 0,98 | 0,98 |
| CG | B3 | 0,97 | 0,97 | 0,95 |
| BG | B4 | 0,99 | 0,95 | 0,99 |
| AG | B5 | 0,98 | 0,97 | 0,75 |
| AC | B6 | 0,98 | 0,96 | 0,97 |
| BC | B7 | 0,99 | 0,96 | 0,99 |
| CG | B9 | 0,97 | 0,95 | 0,97 |
| BG | B10 | 0,99 | 0,93 | 0,75 |
| AG | B11 | 0,98 | 0,93 | 0,97 |
| ABC | B12 | 0,99 | 0,97 | 0,99 |
| ABC | B13 | 0,99 | 0,99 | 0,99 |

O Random Forest alcançou uma acurácia de 0,99 em uma escala de 0,00 a 1,00, o que representa um desempenho alto na tarefa de localização de faltas. Essa pontuação próxima de 1,00 indica que, o modelo teve uma taxa baixa de erros na previsão e foi capaz de localizar corretamente a maioria das situações de faltas no conjunto de dados.

A Tabela 3, mostra queue o modelo RF foi o mais robusto com um desempenho consistentemente alto em todos os tipos de faltas.

Durante o processo de localização de faltas, os valores das resistências apresentados na Tabela 1 e os tipos de faltas mostrados na Tabela 2 foram variados. Assim, a Figura 10, mostra a acurácia do modelo RNA para uma falta fase-terra AB na barra 4, apresentando uma acurácia de 0,99%.

## 6. CONCLUSÃO

No modelo teste, métodos de Inteligência Artificial na localização de faltas em um sistema elétrico que incorpora um

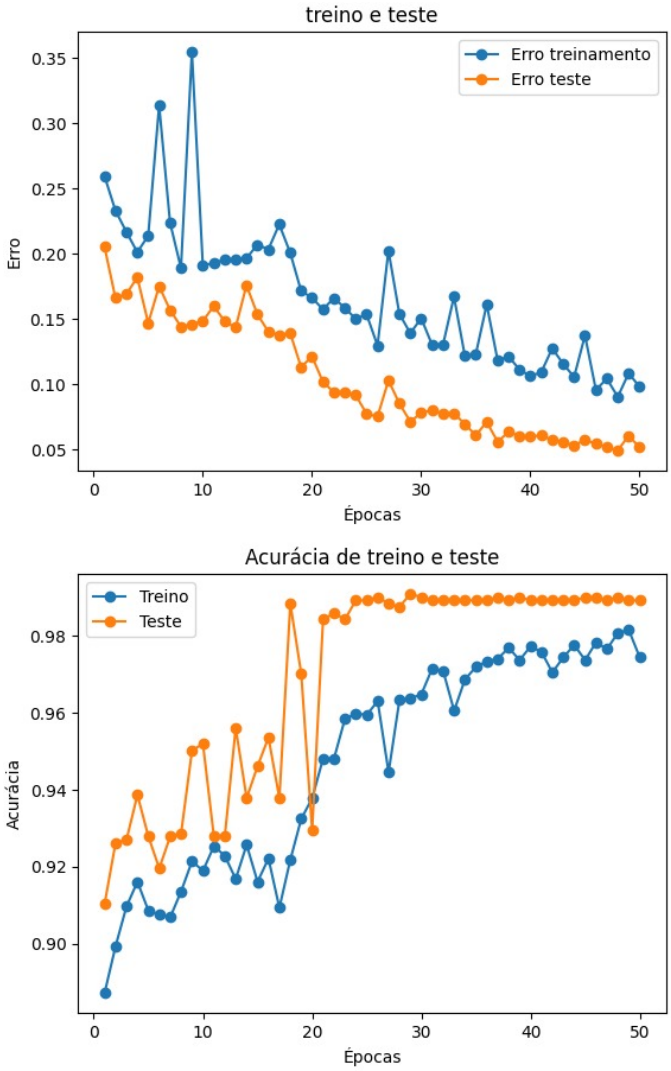


Figura 10. Acuracias

Tabela 3. Tabela media e desvio padrão

| Tipo de falta | RF (média) | RF (desvio padrão) | KNN (média) | KNN (desvio padrão) | RNA (média) | RNA (desvio padrão) |
|---|---|---|---|---|---|---|
| AB | 0,9900 | 0,0000 | 0,8650 | 0,1626 | 0,9200 | 0,0707 |
| ABC | 0,9900 | 0,0000 | 0,9775 | 0,0096 | 0,9775 | 0,0150 |
| AC | 0,9800 | - | 0,9600 | - | 0,9700 | - |
| AG | 0,9833 | 0,0058 | 0,9633 | 0,0115 | 0,9500 | 0,0100 |
| BC | 0,9800 | - | 0,9700 | - | 0,9700 | - |
| BG | 0,9900 | 0,0000 | 0,9400 | 0,0141 | 0,8500 | 0,1414 |
| CG | 0,9800 | 0,0141 | 0,9600 | 0,0141 | 0,9600 | 0,0141 |

parque eólico composto por doze turbinas foi proposto. Os modelos de IA apresentados demonstram eficácia notável na localização de faltas em sistemas elétricos com inserção da geração eólica, oferecendo uma perspectiva promissora para futuras implementações e avanços na gestão de faltas em ambientes similares. Já, na simulação, os resultados obtidos demonstraram uma notável acurácia de acima de 90% em todos os modelos de IA utilizados para a localização de faltas. Essa precisão representa um avanço significativo na confiabilidade e eficiência operacional do

sistema elétrico. Assim, notou - se ainda que, mesmo após a ocorrência da falta, os sinais de potência e corrente retornam à inestabilidade da rede (rede desequilibrada, comportamento inestável da rede) . Essa observação é importante e indica que existe muitos desafios no controle do sistema elétrico.

## REFERÊNCIAS

S. Kanwal and S. Jiriwibhakorn, "Advanced Fault Detection, Classification, and Localization in Transmission Lines: A Comparative Study of ANFIS, Neural Networks, and Hybrid Methods,"in IEEE Access, vol. 12, pp. 49017-49033, 2024, doi: 10.1109/ACCESS.2024.3384761.

R. Resmi, V. Vanitha, E. Aravind, B. R. Sundaram, C. R. Aswin and S. Harithaa, "Detection, Classification and Zone Location of Fault in Transmission Line using Artificial Neural Network,"2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT), Coimbatore, India, 2019, pp. 1-5, doi: 10.1109/ICECCT.2019.8868990.

Byron O. Palate, Tatiana P. Guedes, Ahda Grilo-Pavani, Antonio Padilha-Feltrin, Joel D. Melo, Aggregator units allocation in low voltage distribution networks with penetration of photovoltaic systems, International Journal of Electrical Power  Energy Systems, Volume 130, 2021, 107003, https://doi.org/10.1016/j.ijepes.2021.107003, ISSN 0142-0615.

M. Li, H. Zhang, T. Ji and Q. H. Wu, "Fault Identification in Power Network Based on Deep Reinforcement Learning,"in CSEE Journal of Power and Energy Systems, vol. 8, no. 3, pp. 721-731, May 2022, doi: 10.17775/CSEEJPES.2020.04520.

J. Liang, T. Jing, H. Niu and J. Wang, "Two-Terminal Fault Location Method of Distribution Network Based on Adaptive Convolution Neural Network,"in IEEE Access, vol. 8, pp. 54035-54043, 2020, doi: 10.1109/ACCESS.2020.2980573.

C. K. Y. Zerahny, L. K. Yun, W. J. K. Raymond and K. T. Mei, "Fault Classification and Location in Three-Phase Transmission Lines Using Wavelet-based Machine Learning,"2020 8th International Conference on Intelligent and Advanced Systems (ICIAS), Kuching, Malaysia, 2021, pp. 1-5, doi: 10.1109/ICIAS49414.2021.9642641.

H. Livani and C. Y. Evrenosoglu, "A Machine Learning and Wavelet-Based Fault Location Method for Hybrid Transmission Lines,"in IEEE Transactions on Smart Grid, vol. 5, no. 1, pp. 51-59, Jan. 2014, doi: 10.1109/TSG.2013.2260421.

Anamika Yadav, Aleena Swetapadma, A single ended directional fault section identifier and fault locator for double circuit transmission lines using combined wavelet and ANN approach, International Journal of Electrical Power e Energy Systems, Volume 69, 2015, Pages 27-33, ISSN 0142-0615

Hao Wu, Jian Wang, Dongliang Nan, Qiushi Cui, Jinxin Ouyang,Transmission line fault cause identification method based on transient waveform image and MCNN-LSTM, Measurement, Volume 220, 2023,113422,ISSN 0263-2241.

M. Niyas and K. Sunitha, "Identification and classification of fault during power swing using decision tree approach,"2017 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES), Kollam, India, 2017, pp. 1-6, doi: 10.1109/SPICES.2017.8091347.

Vincent Nsed Ogar, Sajjad Hussain, Kelum A.A. Gamage, The use of artificial neural network for low latency of fault detection and localisation in transmission line, Heliyon, Volume 9, Issue 2, 2023, e13376, ISSN 2405-8440.

MathWorks. MATLAB Simulink. Versão 2022a. Natick, MA: MathWorks, 2022.

Aggarwal, Charu C. Machine Learning With Shallow Neural Networks.Neural Networks and Deep Learning: A Textbook, p. 54-69, 2018.

M. U. Usman, J. Ospina and M. O. Faruque, "Fault Classification and Location Identification in a Smart Distribution Network Using ANN,"2018 IEEE Power e Energy Society General Meeting (PESGM), Portland, OR, USA, 2018, pp. 1-6, doi: 10.1109/PESGM.2018.8586471.

W, Andrew. Machine Learning Simplified: A Gentle Introduction to Supervised Learning.THEMLSBOOK.COM.

B. Sun, J. Du and T. Gao, "Study on the Improvement of K-Nearest-Neighbor Algorithm,"2009 International Conference on Artificial Intelligence and Computational Intelligence, Shanghai, China, 2009, pp. 390-393, doi: 10.1109/AICI.2009.312.

DIgSILENT, DIgSILENT PowerFactory 2021, (2021) 1. https://www.digsilent.de/en/ (accessed May 8, 2021).

KALUEYO, C. P. T, Redes neurais artificiais para localizacao de faltas em linhas de transmissao com derivacao. 2023. Dissertacao (Mestrado em Sistemas de Potencia) - Escola Politecnica, Universidade de São Paulo, S ao Paulo, 2023. doi:10.11606/D.3.2023.tde-08082023-101741.Acesso em: 2023-09-30.

Oliveira, Ruy Flávio de. Inteligência Artificial: Editora e Distribuidora Educacional S.A., Londrina 2018.

DI SANTO, Silvio Giuseppe. Localização de faltas em linhas de transmissão com compensação série utilizando técnicas heurísticas. 2022. Tese (Livre Docência em Sistemas de Potência) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2022.

Raschka, S., Mirjalili, V. (2020). Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2, 3rd Edition. Packt Publishing.

Multiple Random Forests Based Intelligent Location of Single-phase Grounding Fault in Power Lines of DFIG-based Wind Farm,"in Journal of Modern Power Systems and Clean Energy, vol. 10, no. 5, pp. 1152-1163, September 2022.

(2021). Fault location and classification in transmission lines using KNN and SVM classifiers. International Journal of Electrical Power  Energy Systems, 127, 106655.