

Classificação de Faltas em Sistemas de Distribuição Considerando a Inserção de Energia Solar Fotovoltaica

Andréia S. Santos¹, Reginaldo J. Silva², Carlos R. Minussi³

UNESP, Ilha Solteira, SP

Lucas Teles Faria⁴

UNESP, Rosana, SP

Resumo. A classificação de faltas considerando a inserção de geração distribuída é um procedimento essencial para os sistemas de distribuição. O aumento significativo de geradores distribuídos conectados à rede elétrica afeta diretamente os sistemas de proteção convencionais, principalmente devido às mudanças nas características, direção e amplitude da corrente de curto-circuito. Neste estudo, analisa-se o impacto da penetração da energia solar fotovoltaica no processo de classificação de faltas de curto-circuito, introduzindo cenários que consideram a variação da quantidade de painéis fotovoltaicos. As condições de faltas são analisadas em um sistema teste IEEE 34 barras, modificado e modelado no ATP/ATPDraw. A rede neural ARTMAP *Fuzzy* é empregada para classificar os tipos de curto-circuito. A taxa mínima de acertos foi de 100% para os curtos monofásicos, 85,6% para bifásicos e 98,55% para trifásicos em todos os cenários adotados. Observa-se uma redução no percentual de acertos à medida que se aumenta a inserção de geração distribuída solar fotovoltaica.

Palavras-chave. Classificação de Faltas, Rede Neural ARTMAP *Fuzzy*, Painéis Fotovoltaicos, Sistema de Distribuição

1 Introdução

Os sistemas de distribuição de energia elétrica (SDEEs) tradicionais estão passando por transformações por causa da incorporação de recursos energéticos distribuídos. Esses recursos oferecem vantagens, como a redução das emissões de poluentes, a diversificação da matriz energética e a diminuição das perdas no sistema. No entanto, a inserção massiva e arbitrária de geração distribuída (GD) pode causar impactos significativos no SDEE [1, 3], relacionados às alterações na topologia do sistema, que passa a ser alimentado por múltiplas fontes, perdendo suas características radiais.

Por exemplo, a energia solar fotovoltaica (ESF) cresceu de forma exponencial nos últimos anos especificamente no Brasil. O impacto ocasionado pela sua alta penetração no SDEE está relacionada com o sistema de proteção, onde a GD contribui para corrente de curto-circuito. Assim, conforme a presença de GD aumenta em um alimentador, os padrões da corrente de falta se modificam significativamente em comparação com aqueles alimentadores sem GD [7]. As mudanças nos perfis de corrente pode impactar substancialmente na operação e coordenação dos dispositivos de proteção.

Assim, neste estudo, é realizada uma análise do impacto da penetração da ESF no processo de classificação de curtos-circuitos monofásicos (1ϕ), bifásicos (2ϕ) e trifásicos (3ϕ). Diferentes

¹andrea.faria@unesp.br

²reginaldo.silva@unesp.br

³carlos.minussi@unesp.br

⁴lucas.teles@unesp.br

cenários são introduzidos com variação na quantidade de Painéis Fotovoltaicos (PFs), a resistência da falta, localização da barra em falta e ângulo de inserção. Os sinais de correntes são extraídos na saída da subestação. As médias normalizadas dos sinais de correntes compõem o conjunto de entradas do classificador.

Ao longo dos anos, diversas publicações têm sido apresentadas na literatura especializada considerando a inserção de GD. Em [10] foi apresentado um estudo baseado em rede neural convolucional para classificação de faltas com a integração de GDs. Em [15] os autores propuseram um novo método para detecção e classificação de faltas, onde os modos de operação das unidades de GD foram considerados utilizando a abordagem *Fortescue*. Em [9] foi proposto um algoritmo para classificação de faltas em SDEE composto por GDs do tipo eólica. Em [6] uma proposta baseada em *deep belief networks* foi apresentada para classificação de faltas com e sem unidades de GD conectadas ao sistema.

2 Metodologia para Classificação de Faltas

2.1 Análise dos Sinais de Corrente

A classificação de faltas baseia-se na análise contínua dos sinais de correntes extraídos na saída da subestação. Quando ocorre uma perturbação no sistema, as correntes sofrem alterações e as fases cujos estados operativos das correntes encontram-se fora dos padrões nominais apresentam valores superiores em comparação às fases que operam em condições nominais. Assim, as características distintas dos variados tipos de curto-circuito podem ser obtidas por meio do cálculo das médias dos sinais das correntes trifásicas. A média de cada fase pode ser obtida aplicando uma janela fixa de dados composta por dois ciclos de amostra de sinais pós-falta conforme apresentado em (1) e de acordo com [13]:

$$M_i = \frac{1}{N} \sum_{j=1}^N x_{ij}, \quad i \in \{a, b, c\}, \quad (1)$$

O vetor contendo as médias das correntes trifásicas é apresentado em (2):

$$M = [M_a \ M_b \ M_c]. \quad (2)$$

Onde M_i representa a média de corrente de cada fase i , x_{ij} são as amostras j de sinais da fase i e N a quantidade de sinais da janela de dados, a qual possui a mesma quantidade de sinais para as três fases (a, b e c).

O vetor de média é normalizado de acordo com (3) conforme [13]:

$$\bar{M}_i = \frac{M_i}{\sum \mathbf{M}}. \quad (3)$$

2.2 Rede Neural ARTMAP Fuzzy

A rede neural artificial (RNA) ARTMAP *Fuzzy* implementada como classificador, emprega em seus operadores os cálculos dos conjuntos *Fuzzy* [14]. Essa rede, pertencente à classe denominada teoria da ressonância adaptativa (ART), foi introduzida por [4] e inspirada no funcionamento do cérebro. As redes pertencentes à família ART possuem sistemas de aprendizagem supervisionada e não supervisionada, bem como características importantes, tais como capacidade de aprendizagem rápida, incremental e estável.

A rede ARTMAP *Fuzzy* [2] possui uma estrutura composta por dois módulos ART: ART_a e ART_b , os quais são interligados por meio de um terceiro módulo denominado inter-ART. No módulo ART_a são inseridos os dados de entrada, enquanto o ART_b recebe as respectivas saídas desejadas. Os principais parâmetros da rede são apresentados a seguir:

- α : responsável pela escolha de categorias;
- β : controla a velocidade do processo de treinamento da RNA;
- ρ_a : parâmetro de vigilância pertencente ao módulo ART_a cujo objetivo é controlar a ressonância do respectivo módulo;
- ρ_b : parâmetro de vigilância pertencente ao módulo ART_b cujo objetivo é controlar a ressonância do respectivo módulo;
- ρ_{ab} : parâmetro de vigilância pertencente ao módulo Inter-ART;
- ϵ : constante responsável pelo acréscimo no módulo ART_a para exclusão da categoria incompatível;

Quando uma previsão realizada em ART_a é incompatível com a saída representada em ART_b , o processo *Match Tracking* é ativado via inibição da memória associativa inter-ART. A categoria prevista erroneamente é excluída por meio de um acréscimo no parâmetro de vigilância (ρ_a) pertencente ao módulo ART_a . Após a exclusão da categoria incompatível, o sistema inicia a busca por uma nova categoria em ART_a que resulta na ativação de uma categoria que prevê corretamente a saída representada ART_b . O processo de treinamento completo é apresentado em [11].

2.3 Métricas de Avaliação

As métricas da matriz de confusão são utilizadas para avaliar o desempenho do classificador. Ressalta-se que a aplicação da matriz de confusão é apropriada por causa da natureza binária das saídas fornecidas pela RNA, que consiste na identificação da ausência ou presença de faltas de curto-circuito. Na Tabela 1 são exibidos os parâmetros da matriz de confusão.

Tabela 1: Matriz de confusão.

	Falta	Sem Falta
Falta	VP	FN
Sem Falta	FP	VN

Em que VP representa o número de casos com faltas classificados corretamente, FN indica o número de fases com faltas erroneamente classificadas como sem faltas, FP denota o número de fases sem falta, mas incorretamente classificadas como falta, e VN expressa o número de casos sem falta classificados corretamente.

As métricas de acurácia e precisão, obtidas via matriz de confusão, são aplicadas para medir a eficiência do classificador. A acurácia, como mostrado em (4), fornece o desempenho geral do classificador, enquanto a precisão, obtida usando-se a equação (5), é a razão entre o número de casos reais com falta (verdadeiro-positivo) e o número de fases erroneamente classificadas com falta (falso-positivo).

$$\frac{VP + VN}{VP + FN + FP + VN} \tag{4}$$

$$\frac{VP}{VP + FP} \tag{5}$$

3 Resultados

3.1 Cenários de Faltas

O sistema teste IEEE 34 barras [8], modelado no ATP e sua interface gráfica ATPDraw, foi implementado para simulações das diversas condições de falta. Foram utilizados modelos de impedância constante para representar as cargas ao longo do alimentador. Os religadores de tensão

foram retirados. As diversas condições de falta foram realizadas a uma taxa de amostragem de 10,8 kHz. O classificador de faltas foi desenvolvido no ambiente do programa MATLAB.

Foram criados três cenários variando parâmetros como tipo de curto-circuito, resistência de falta, localização da falta, ângulo de inserção e a quantidade de PF, conforme apresentado na Tabela 2. A composição de cenários têm como objetivo verificar o comportamento do processo de classificação em decorrência das alterações realizadas no sistema IEEE 34 barras por meio da variação da quantidade de penetração de ESF. Na Figura 1 (a) é exibido o cenário 2, no qual foram adicionadas duas unidades de PF (nas barras 840 e 848) modelados conforme [5], com potência instalada de 1MW cada uma. O cenário 3, apresentado na Figura 1(b) possui potência instalada de 3MW, com a instalação de três PFs nas barras 822, 840 e 848, respectivamente.

Tabela 2: Parâmetros das simulações para o sistema IEEE 34 barras.

Parâmetros	Valores
Resistência de Falta	1 a 40 Ω
Ângulo de Inserção	0°, 45°, 90° e 120°
Localização da Falta	806, 814, 828, 830, 850, 854 e 860
Tipo de Curto-Circuito	$A_g, B_g, C_g, AB, AC, BC, AB_g, BC_g, AC_g, ABC, ABC_g$
Cenários	cenário base, 2PFs e 3PFs

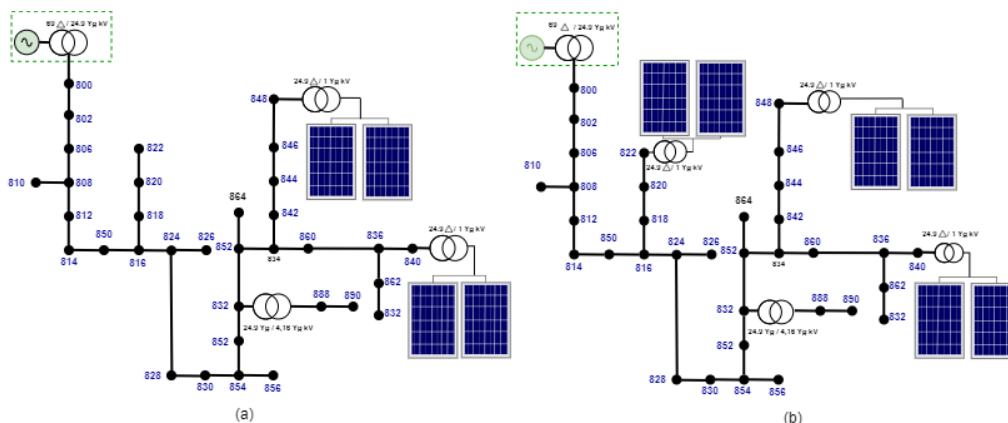


Figura 1: Sistema IEEE 34 barras cenários: (a) dois PFs (cenário 2); (b) três PFs (cenário 3). Adaptado de: [8].

3.2 Classificação de Faltas de Curto-Circuito

O estágio de classificação inicia-se após uma falta ser identificada pelo sistema de detecção, processo conforme descrito em [12]. As médias normalizadas das correntes trifásicas (Equação (3)) compõem o conjunto de entrada do classificador. A RNA ARTMAP *Fuzzy* é introduzida para identificação das fases com anomalia e classificação dos curtos-circuitos. Na saída, são apresentados valores binários, onde o bit 0 representa normalidade, enquanto o bit 1 indica ocorrência de curto-circuito. Posteriormente, o curto-circuito pode ser identificado por meio da contabilização das fases defeituosas.

Em cada cenário, foram simuladas 2.244 faltas, totalizando 8.976 simulações. Para as fase de treinamento, são utilizados 70% os dados, o que equivale a 6.284 simulações. Os 30% restantes, totalizando 2.692 simulações, são reservados para testes e validação do classificador. Três RNA

ARTMAP *Fuzzy* são implementadas, uma para cada tipo de curto-circuito, com o objetivo de maximizar a taxa de precisão. Os parâmetros considerados no processo de simulação são apresentados na Tabela 3. Ressalta-se que os mesmos valores foram aplicados para todos os tipos de curtos, e em todos os cenários.

Os resultados da classificação são apresentados na Figura 2. Na Figura 2(a), são exibidos os resultados para o cenário 1 (base), sem penetração de recursos energéticos distribuídos (REDs). Observa-se um percentual de acertos de 100% para todos os tipos de curto. Este resultado se mantém no cenário 2 (mostrado na Figura 2(b)), no qual dois PFs foram conectadas ao sistema. Por outro lado, no cenário 3 (Figura 2(c)), no qual foram adicionadas três PFs ao SDEE, nota-se uma redução significativa para os curtos-circuitos bifásicos e trifásicos, apresentando um erro de 14,4% e 1,45%, respectivamente.

Tabela 3: Parâmetros da RNA ARTMAP *Fuzzy*.

Parâmetros	Curtos-Circuitos		
	1 ϕ	2 ϕ	3 ϕ
α	0,1	0,1	0,1
β	1	1	1
ρ_a	0,45	0,45	0,45
ρ_b	0,55	0,55	0,55
ρ_{ab}	1	1	1
ϵ	0,003	0,003	0,003

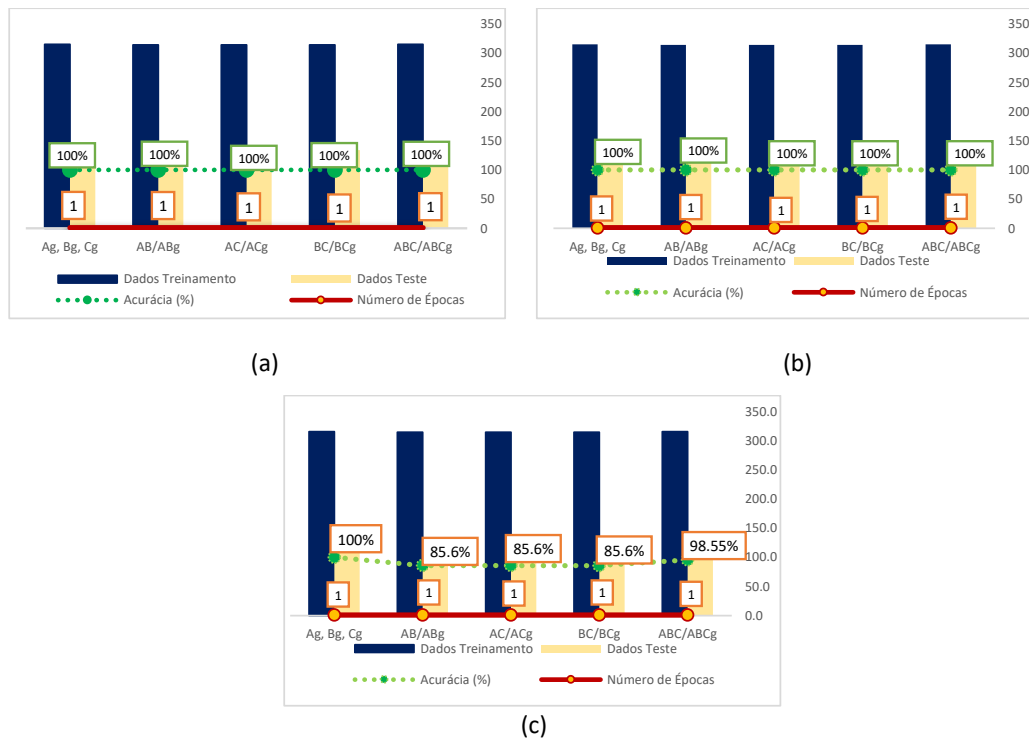


Figura 2: Resultados classificação (a) Cenário base, (b) 2PFs e (c) 3PFs. Fonte: Elaboração própria.

Tais reduções estão diretamente ligadas às alterações nos níveis de corrente ocasionadas pelo aumento da penetração da ESF. Em determinados casos, no cenário 3, a média normalizada da fase em curto-circuito torna-se muito próxima ou até inferior àquelas das fases sem anomalias, principalmente para as barras mais distantes da subestação.




Figura 3: Matriz de confusão do classificador curtos-circuitos bifásicos e trifásicos . Fonte: Elaboração própria.

3.3 Métricas de Avaliação

Na Figura 3, é apresentada a matriz de confusão referente ao classificador implementado para os curtos-circuitos bifásico e trifásico do cenário 3, os quais apresentaram uma redução na taxa de acerto. A acurácia para o curto bifásico (cenário 3) foi de 90,4%, enquanto a precisão foi de 92,80%. Por outro lado, o curto-circuito trifásico apresentou acurácia de 98,55% com precisão de 100%.

4 Considerações Finais

Neste estudo, realizou-se a análise do impacto da integração de PFs no processo de classificação de falhas de curto-circuito em um sistema de distribuição de energia. A técnica baseou-se na análise das correntes trifásicas medidas na saída da subestação. No processo de classificação, foram implementadas três redes ARTMAP *Fuzzy* para identificação dos curtos-circuitos. Os resultados obtidos no estágio de classificação para os diferentes tipos de curtos-circuitos adotados, em diferentes cenários, foram satisfatórios. A taxa mínima de acertos obtida foi de 100% para curtos monofásicos, 85,6% para bifásicos e 98,55% para trifásicos nos cenários 1, 2, e 3, respectivamente. Foi obtida uma acurácia de 90,5% para os curtos-circuitos bifásicos, e 98,55% para os trifásicos no cenário 3. Esses resultados evidenciam o impacto da integração dos PFs no sistema de distribuição.

Agradecimentos

Esta pesquisa foi financiada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código de Financiamento 001, e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Referências

- [1] ANEEL. **Geração Distribuída**. Online. Acessado em 15/12/2023, <http://www.aneel.gov.br>.

- [2] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds e D. B. Rosen. “Fuzzy ART-MAP: A neural network architecture for incremental supervised learning of analog multidimensional maps”. Em: **IEEE Transactions on neural networks** 3 (1992), pp. 698–713. DOI: 10.1109/72.159059.
- [3] B. K. Chaitanya e A. Yadav. “An intelligent fault detection and classification scheme for distribution lines integrated with distributed generators”. Em: **Computers and Electrical Engineering** 69 (2018), pp. 28–40. DOI: 10.1016/j.compeleceng.2018.05.025.
- [4] S. Grossberg. “Adaptive pattern classification and universal recoding: II. Feedback, expectation, olfaction, illusions”. Em: **Biological cybernetics** 23 (1976), pp. 187–202. DOI: 10.1007/BF00340335.
- [5] H. K. Høidalen, L. Prikler e F. Peñaloza. **ATPDRAW version 7.3**. Online. Acessado em 15/06/2021, <http://www.atpdraw.net>.
- [6] C. Hong, Z.Y. Zeng, Y. Z. Fu e M. F. Guo. “Deep-Belief-Networks Based Fault Classification in Power Distribution Networks”. Em: **IEEJ Transactions on Electrical and Electronic Engineering** 15 (2020), pp. 1428–1435. DOI: 10.1002/tee.23213.
- [7] H. Hooshyar e M. E. Baran. “Fault analysis on distribution feeders with high penetration of PV systems”. Em: **IEEE Transactions on Power Systems** 28 (2013), pp. 2890–2896. DOI: 10.1109/TPWRS.2012.2227842.
- [8] W. H. Kersting. “Radial distribution test feeders”. Em: **IEEE Transactions on Power Systems** 6 (1991), pp. 975–985. DOI: 10.1109/59.119237.
- [9] T. Patcharoen e A. Ngaopitakkul. “Fault classifications in distribution systems consisting of wind power as distributed generation using discrete wavelet transforms”. Em: **Sustainability** 11 (2019). DOI: 10.3390/su11247209.
- [10] P. Rai, N. D. Londhe e R. Raj. “Fault classification in power system distribution network integrated with distributed generators using CNN”. Em: **Electric Power Systems Research** 192 (2021). DOI: 10.1016/j.epsr.2020.106914.
- [11] A. S. Santos, H.R.S. Bernardes, L. T. Faria, M.L.M. Lopes e C.R. Minussi. “Detecção e Classificação de Falhas de Curto-Circuito em Sistemas de Distribuição de Energia Elétrica com Inserção de Geração Distribuída”. Em: **In: XXIII Congresso Brasileiro de Automática (XXIII CBA)**, Congresso Virtual, Brasil. Vol. 1. CBA, 2020. DOI: 10.48011/asba.v2i1.1632.
- [12] A. S. Santos, L. T. Faria, M. L. M. Lopes, A. D. P. Lotufo e C. R. Minussi. “Efficient Methodology for Detection and Classification of Short-Circuit Faults in Distribution Systems with Distributed Generation”. Em: **Sensors** 22 (2022). DOI: 10.3390/s22239418.
- [13] A. S. Santos, A. B. A. Ferreira, P. A. Montenegro, L. T. Faria e C. R. Minussi. “Fault Classification in Power Distribution Systems with Photovoltaic Distributed Generation Insertion”. Em: **International Symposium on Energy: Energy Transition, Green Hydrogen and Sustainable Industry**. Vol. 1. 2023. DOI: 10.55592/ISE.2023.6196040.
- [14] L. A. Zadeh. “Fuzzy sets”. Em: **Information and control** 8 (1965), pp. 338–353. DOI: 10.1016/S0019-9958(65)90241-X.
- [15] C. Zhang, J. Wang, J. Huang e P. Cao. “Detection and classification of short-circuit faults in distribution networks based on fortescue approach and softmax regression”. Em: **International Journal of Electrical Power & Energy Systems** 118 (2020), pp. 105812–105812. DOI: 10.1016/j.ijepes.2019.105812.