Classificação de faltas em alimentadores de redes coletoras de parques eólicos *onshore* utilizando Lógica *Fuzzy* e Meta-Heurísticas

Elis C. S. Trindade*
Rafael Y. S Yamamoto*.
**Universidade Estadual Paulista "Júlio de Mesquita Filho"*
(e-mail: elis.trindade@unesp.br, rafael.yuki@unesp.br).

Abstract: With the increasing competitiveness of wind power generation in the commercialization of electrical energy in the country, it is essential for the efficient integration of wind energy into the energy matrix to ensure its safety and reliability. Therefore, in the scope of the protection of power systems (SEP), in the event of a fault, they must be isolated as quickly as possible to mitigate the negative effects generated in the wind power generation system. Thus, this work presents a proposal for the classification of faults in feeders of an onshore Wind Farm, aiming to assist maintenance teams in eliminating a permanent short circuit in the SEP. The proposed method is based on a fuzzy inference system and meta-heuristics. The results demonstrate a favorable convergence of the method, as well as evaluate and compare different inference *fuzzy* methodologies (Mamdani and Takagi-Sugeno) and two distinct meta-heuristics.

Resumo: Com o aumento da competitividade das centrais de geração eólica na comercialização de energia elétrica no país é fundamental para a inserção eficiente da energia eólica na matriz energética garantir sua segurança e confiabilidade. Sendo assim, no âmbito da proteção de sistemas elétricos de potência (SEP), caso ocorra uma falta, devem ser isoladas o mais rápido possível de modo a mitigar os efeitos negativos gerados no sistema de geração eólico. Portanto, este trabalho apresenta uma proposta de classificação de faltas em alimentadores de um Parque Eólico *onshore*, a fim de auxiliar as equipes de manutenção na eliminação de um curto-circuito permanente no SEP. O método proposto baseia-se em um sistema de inferência *fuzzy e* meta-heurísticas. Os resultados demonstram uma favorável convergência do método, além de avaliar e comparar diferentes metodologias de inferência *fuzzy* (Mamdani e Takagi-Sugeno) e duas meta-heurísticas distintas.

Keywords: Wind farm; Electrical system protection; Fault detection; Fault classification; Fuzzy inference; Optimization.

Palavras-chaves: Parque eólico; Proteção do sistema elétrico; Classificação de faltas; Sistema de inferência *Fuzzy*; Otimização.

1. INTRODUÇÃO

A busca incessante pela diversificação da matriz energética brasileira e o aumento da confiabilidade no abastecimento e na operação são essenciais, dado que os transtornos provocados pela interrupção no fornecimento de energia elétrica afetam diversos tipos de atividades e consumidores. A integração dos parques eólicos ao Sistema Interligado Nacional (SIN) traz grandes desafios e inovações tecnológicas. Atualmente, o Brasil ocupa a 6ª posição no ranking mundial de capacidade total instalada de energia eólica onshore, com 30,45 GW de capacidade instalada, segundo o Global Wind Energy Council (GWEC) em 2024.

A operação segura de um Sistema Elétrico de Potência (SEP) implica no suprimento ininterrupto de energia elétrica dentro dos padrões adequados de qualidade. Contudo, devido à sua magnitude, o SEP está sujeito a frequentes distúrbios ocasionados por intempéries, falhas de equipamentos, presença de animais nas redes, falha humana, entre outros (Sato, 2014).

⋆ O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – código de financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Para a inserção eficiente da energia eólica na matriz energética, é necessário garantir sua segurança e confiabilidade, sendo de fundamental importância a agilidade e precisão no processo de restauração da normalidade em caso de alguma falha no Sistema Elétrico de Potência (SEP). No âmbito da proteção de sistemas elétricos de potência, as falhas devem ser isoladas o mais rapidamente possível para mitigar os efeitos negativos gerados (Santos, 2023).

Os investimentos em novas técnicas, tecnologias e filosofias de diagnóstico/prognóstico de faltas vêm sendo intensificados com o objetivo de minimizar a intervenção dos operadores de subestações, tornando o processo de diagnóstico de faltas mais ágil e preciso (Tonelli-Neto, 2015). Como o custo da interrupção da energia afeta tanto o gerador quanto o consumidor, e considerando que nenhuma rede elétrica é imune a blecautes, por menores que sejam as chances de ocorrência, o sistema deve estar preparado para restabelecer as cargas no menor tempo possível, possibilitando o retorno às condições normais de operação (Gomes, P.; Guarini, A.P., 2005).

No entanto, um algoritmo completo para diagnóstico de faltas inclui as etapas de detecção, classificação e localização da falta

(LDF). Na literatura, muitos estudos pressupõem que as etapas de detecção e classificação da falta são realizadas por meio de dispositivos de proteção, como os relés. Embora a classificação do tipo de falta possa não ser necessária para alguns métodos de localização, o conhecimento das fases envolvidas na falta, bem como a presença ou ausência de terra, auxilia significativamente no processo de LDF e, consequentemente, no rápido restabelecimento da energia (Santos, 2023). Diante disso, a finalidade deste trabalho é verificar a aplicação de um método de classificação de faltas para ser empregado em etapas preliminares à LDF em uma rede interna de um parque eólico *onshore* conectado ao sistema de distribuição de energia elétrica (SDEE). O método proposto baseia-se em um sistema de inferência *fuzzy* e em meta-heurísticas. Para isso, foram comparadas diferentes metodologias de inferência *fuzzy* (Mamdani e Takagi-Sugeno) e duas meta-heurísticas distintas.

2. ESTADO DA ARTE

Nos últimos tempos, propostas significativas para a detecção e classificação de faltas foram publicadas na literatura. Neste contexto, esta seção abordará as publicações sobre métodos de diagnóstico de falta baseados principalmente em inteligência artificial, redes neurais e lógica *fuzzy* para SDEE. Métodos de LDF não serão abordados neste trabalho.

Das (2006) propôs um algoritmo baseado em lógica *fuzzy* para identificar o tipo de falta em um sistema de distribuição radial desbalanceado. A técnica proposta foi capaz de identificar com precisão as fases envolvidas em todos os dez tipos de faltas. O método utiliza três medições de corrente de linha disponíveis na subestação. Assim como em Chen et al. (2000), houve dificuldades em definir as regras do sistema de inferência *fuzzy*.

Em Decanini et al. (2012), o procedimento de detecção de faltas empregou análises estatísticas e diretas das formas de onda de corrente no domínio *wavelet*. As características dos sinais de corrente e tensão foram extraídas usando a Transformada *Wavelet* Discreta (TWD), análise multirresolução e conceito de energia. Esses índices comportamentais correspondem aos vetores de entrada de três conjuntos paralelos de redes neurais ARTMAP difusas, utilizadas para a classificação da falta. Biscaro et al. (2016) também utilizaram a TWD, análise de multirresolução e conceito de energia do sinal. O processo de diagnóstico de curto-circuito foi realizado em conjunto com a análise de qualidade de energia, no qual foram introduzidas redes neurais ARTMAP *Fuzzy* distintas com treinamentos independentes para a classificação da falta.

Dehghani et al. (2016) apresentaram uma combinação de Lógica *Fuzzy* e Entropia Singular *Wavelet* (ESW) para detecção e classificação de faltas em linhas de distribuição com a inserção de Geração Distribuída (GD). As características das correntes trifásicas foram extraídas pelo método ESW, composto pela Transformada *Wavelet* (TW), Decomposição de Valor Singular (DVS) e Entropia de Shannon. Esses recursos foram utilizados como entrada para o módulo de Lógica *Fuzzy*, com o objetivo de detectar e classificar faltas no sistema. Uma vantagem do uso da TW é a possibilidade de ajuste da largura de janela por meio da seleção da *wavelet* mãe. No entanto, os resultados dessa transformada são sensíveis a ruídos, o que pode prejudicar a detecção e classificação das faltas (Santos, 2023).

Zhao e Barati (2021) propuseram um classificador de faltas baseado no algoritmo *Convolutional Neural Network* (CNN), utilizando como entradas as variações de pré-falta e durante a falta das magnitudes e fases dos sinais de tensão e corrente obtidas por dispositivos de medição fasorial.

Em Rai, Londhe e Raj (2021), foi proposto um modelo CNN para classificar todos os tipos de faltas, incluindo as condições sem falta, em uma rede de distribuição integrada com geração distribuída (GD). Foram utilizados dados brutos e amostrados de sinais trifásicos de tensão e corrente de várias classes de falta e da classe sem falta.

Atualmente, a maioria dos trabalhos na literatura foca na etapa de LDF, enquanto alguns abordam todas as etapas do diagnóstico de faltas, e outros se concentram apenas em uma delas. Além disso, há poucos estudos relacionados ao diagnóstico de faltas em redes internas de centrais de geração eólica *onshore*, apesar do grande crescimento dessa tecnologia no Brasil e no mundo. As plantas eólicas estão se tornando cada vez maiores e mais complexas, o que exige modernização e otimização nos processos de restabelecimento em caso de falta.

3. METODOLOGIA

Neste tópico, é apresentada a metodologia implementada neste trabalho para a classificação de faltas em parques eólicos *onshore*.

3. 1 Lógica Fuzzy

Tomando como exemplo a frase: “Se o dia está chuvoso, então deve-se dirigir em baixa velocidade”, nota-se a presença de dois termos subjetivos: "chuvoso" e "baixa velocidade". Uma garoa e uma tempestade, por exemplo, podem configurar um dia chuvoso, enquanto que "baixa velocidade" pode significar 70 km/h em uma rodovia ou 20 km/h dentro de uma cidade. Dessa forma, esses termos são difíceis de representar matematicamente por valores booleanos. A solução para esse cenário é a utilização da lógica fuzzy, também conhecida como lógica multivalorada, onde as variáveis podem assumir valores entre 0 e 1, permitindo um grau de intensidade para cada variável (Marro, 2010).

Em um sistema *fuzzy* convencional, dados os valores das entradas e com as regras e saídas definidas, obtém-se um resultado entre as saídas programadas. No caso deste artigo, os dados de entrada foram os parâmetros b_0 e a_1 , obtidos através de simulações e alguns cálculos, descritos com mais detalhes no tópico *3.2*, e a saída foi o conjunto das possíveis faltas (monofásica, bifásica, bifásica-terra e trifásica). Neste artigo, serão considerados os métodos de inferência *fuzzy* Mamdani e Takagi-Sugeno.

Neste artigo, as entradas e saídas utilizadas possuem formato triangular (exceto a saída do método de Takagi-Sugeno). O formato triangular foi escolhido por sua simplicidade e eficiência computacional, além de facilitar a definição das funções de pertinência, permitindo uma interpretação intuitiva e rápida no processo de inferência. Para as regras do sistema,

é possível utilizar tanto regras geradas a partir do conhecimento do operador sobre os parâmetros e dados utilizados quanto regras geradas por métodos de otimização, que serão abordados no próximo tópico.

3. 2 Otimização através de meta-heurísticas

A aplicação da lógica *fuzzy* para este problema tem sido amplamente explorada, mas a principal crítica a esse método refere-se à escolha dos valores dos parâmetros de entrada, saída e das regras lógicas utilizadas. Este artigo propõe uma solução para essa questão por meio da otimização dos parâmetros de entrada, saída e das regras, aplicando técnicas meta-heurísticas com o uso do componente "Fuzzy Logic Toolbox" disponível no software MATLAB®.

Neste artigo, foram utilizadas as meta-heurísticas Particle Swarm Optimization (PSO) e Genetic Algorithm (GA) para otimizar os parâmetros de entrada, saída e as regras do sistema fuzzy. Essas técnicas foram escolhidas devido à sua eficácia comprovada na exploração de espaços de solução complexos e multidimensionais, permitindo uma busca eficiente por soluções ótimas ou quase ótimas. Além dessas, também foram implementadas as técnicas Pattern Search (PS) e Simulated Annealing (SA) para comparação. No entanto, os resultados obtidos com PS e SA não foram tão satisfatórios quanto os obtidos com PSO e GA, e, portanto, não foram apresentados neste trabalho. A escolha por destacar PSO e GA se justifica pela qualidade superior das soluções encontradas, o que demonstra a adequação dessas meta-heurísticas para o problema em questão.

3. 3 Dados de entrada

Utiliza-se dois dados de entrada para o sistema de inferência, b_0 e a_1. Esses dados são calculados através da distância Euclidiana entre amostras no sinais de tensão. Para calcular as distâncias, considera-se um ciclo do sinal de tensão, que matematicamente pode ser representado pelo vetor $V = [v[1] \cdots v[N]]$, onde v[n] é a tensão instantânea na n-ésima amostra e N corresponde a quantidade de amostras da sequência, N varia de acordo com a frequência no qual o sinal de tensão é amostrado. Além disso, o sinal V é divido em dois semi-ciclos, contendo a mesma quantidade de amostras cada. As equações 1 e 2 representam matematicamente o processo descrito anteriormente.

$$V_1 = [v\,[1] \cdots v\,[\,N/2\,]\,] \tag{1}$$

$$V_2 = [v\,[(\,N/2) + 1\,] \cdots v\,[\,N]\,] \tag{2}$$

Com isso, a distância Euclidiana entre V_1 e o inverso de V_2 pode ser calculada através da norma Euclidiana (*dist*) entre V_1 e o inverso de V_2, conforme (3).

$$dist = \| \,[\,V_1 - (-V_2)]\,\| = \sqrt{\sum_{i=1}^{N/2} (V_1[i] + V_2[i])^2} \tag{3}$$

O operador $\| \,.\, \|$ corresponde à norma Euclidiana.

Admitindo que o sinal de tensão seja trifásico, a equação 3 pode ser reescrita por fase, conforme a equação 4, onde *f* representa a fase correspondente.

$$dist_f = \| \,V_{f1} + V_{f2}\,\| \tag{4}$$

Após o cálculo das distâncias ($dist_A$, $dist_B$ e $dist_C$), define-se como *distmin* e *distmax*, a menor e maior distância entre $dist_A$, $dist_B$ e $dist_C$, respectivamente, conforme as equações 5 e 6. Essa definição é utilizada para normalização das variáveis a seguir.

$$distmin = mínimo\ (dist_A\ ,\ dist_B\ ,\ dist_C\ ) \tag{5}$$

$$distmax = máximo\ (dist_A\ ,\ dist_B\ ,\ dist_C\ ) \tag{6}$$

Considerando que, curtos-circuitos em uma fase podem interferir em outras fases, determina-se a distância Euclidiana envolvendo todas as fases ($distt$) a partir da equação (7).

$$distt = \|(V_{A1} + V_{B1} + V_{C1}) + (V_{A2} + V_{B2} + V_{C2})\| \tag{7}$$

Após isso, as distâncias para cada fase calculadas na equação (4) são normalizadas, empregando a normalização Min-Máx conforme as equação (8). A normalização preserva as relações entre os valores de dados originais sendo os resultados obtidos em um intervalo entre 0 a 1.

$$dist_f(n) = \frac{dist_f - distmin}{distmax - distmin} \tag{8}$$

Determina-se em (9) a fase que possui valor mediano ($distmed_n$) de distância Euclidiana normalizada por fase (equação 8).

$$distmed_n = mediano\ [dist_A(n), dist_B(n), dist_C(n)] \tag{9}$$

Após esses cálculos, utiliza-se um sistema de inferência *fuzzy* para classificar o tipo de falta. Utiliza-se dois dados de entrada para o sistema de inferência, sendo o valor de *distt* e o $distmed_n$. Para melhor entendimento denomina-se o *distt* = b_0 e o $distmed_n$ = a_1.

3. 4 Algoritmo de classificação de faltas proposto

O objetivo do algoritmo proposto foi otimizar as entradas entradas b_0 e a_1 a partir de uma solução inicial ilustrada na Fig. 1.

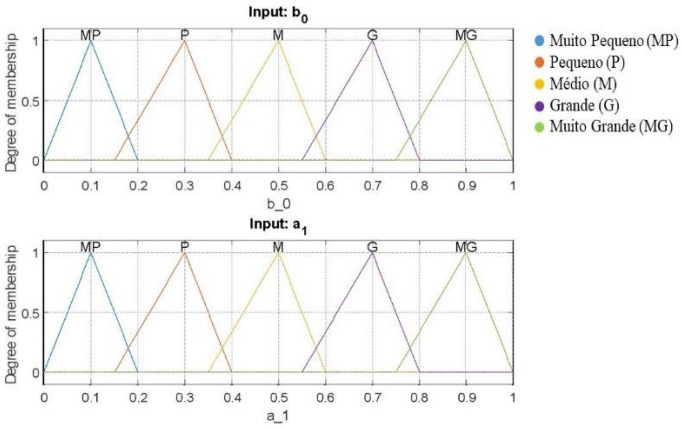

Fig. 1 Entradas iniciais.

As regras podem ser otimizadas de duas maneiras: partindo de um conjunto inicial de regras (Cenário 1) ou gerando novas regras até atingir um limite pré-estabelecido (Cenário 2).

O conjunto inicial de regras utilizado no Cenário 1 foi definido da seguinte forma:

Regra 1: SE $b_0 = G$ E $a_1 = P$, ENTÃO $R = 1$

Regra 2: SE $b_0 = P$ E $a_1 = G$, ENTÃO $R = 2$

Regra 3: SE $b_0 = MG$ E $a_1 = M$, ENTÃO $R = 3$

Regra 4: SE $b_0 = M$ E $a_1 = G$, ENTÃO $R = 4$

Onde R corresponde à saída, sendo que $R = 1$ representa uma falta monofásica (LG), $R = 2$ uma falta bifásica, $R = 3$ uma falta bifásica com o solo e $R = 4$ uma falta trifásica.

Este conjunto de regras foi desenvolvido com base na observação dos valores de entrada pelos autores, considerando que existem quatro possíveis saídas (os tipos de falta). Por outro lado, no Cenário 2, o limite foi estabelecido em 15 regras, permitindo que o algoritmo gere o melhor conjunto de regras possível por meio de otimização, sem restrições iniciais rígidas.

Para as saídas do método de inferência *fuzzy* Mamdani, foi otimizada a saída apresentada na Fig. 2, enquanto que no método de Takagi-Sugeno, o otimizador gerou as equações constantes e lineares para representar a saída.

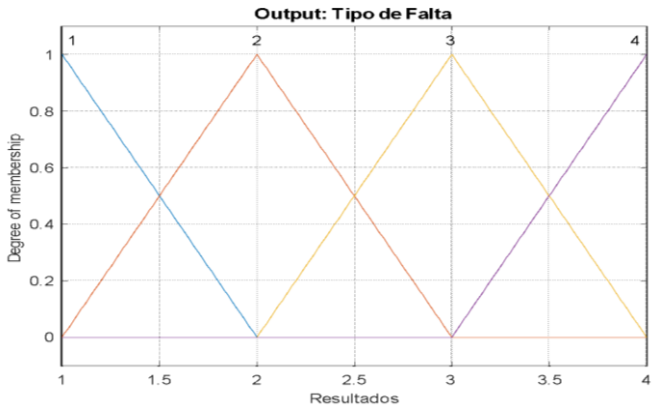

Fig. 2 Saída inicial (Mamdani).

Dos dados disponíveis, 75% foram selecionados aleatoriamente para treinar e otimizar o modelo, enquanto os 25% restantes foram usados para testar a precisão do modelo otimizado. Foram realizados 10 testes distintos para cada método, calculando a média da precisão tanto para o cenário geral quanto para cada tipo específico de falta. O processo de otimização foi conduzido por meta-heurísticas (PSO e GA) com um limite de 100 iterações/gerações.

Quando os parâmetros necessários não são especificados pelo usuário, o MATLAB utiliza configurações padrão para os algoritmos PSO e GA, ajustadas para fornecer uma solução balanceada em uma ampla gama de problemas, que foi a utilizada neste trabalho. No caso do PSO, o tamanho do enxame é definido como 100, o peso de inércia tem um valor padrão de 0,729, e os coeficientes de atração cognitiva e social são ambos configurados como 1,49445. Esses parâmetros controlam como as partículas exploram o espaço de busca e se movem em direção a soluções promissoras. Para o GA, o tamanho da população é também padrão de 100, a fração de crossover é definida como 0,8, indicando que 80% da nova geração é criada através de cruzamentos, e a contagem de elitismo preserva 5% dos melhores indivíduos para garantir a continuidade das boas soluções.

4. RESULTADOS

Nesta etapa, implementou-se utilizando o *software* DigSilent® *Power Factory* um circuito de um Parque Eólico de 34,5kV pertencente ao Complexo Eólico Ventos do Tianguá localizado na Serra de Ibiapaba, no município cearense de Tianguá. O circuito tem uma extensão de 6,438 km. São obtidos os resultados de fluxo de carga e análise de curto-circuito considerando todos os tipos de faltas (monofásica, bifásica, bifásica a terra e trifásica). Os dados do circuito analisado foram extraídos de Peixoto *et al*. (2020). Na Fig. 3, é possível observar o circuito do Parque eólico analisado implementado no *Software* DigSilent® Power Factory, composto por 8 aerogeradores de 1,690MW cada, conectados a uma rede de distribuição de 34,5 kV.

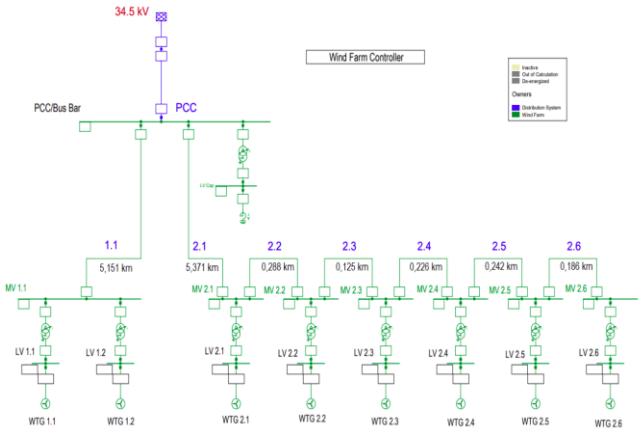

Fig. 3 Parque eólico consistindo de uma rede de distribuição de 34,5 kV. Fonte: Adaptado de Peixoto *et al* (2020).

Para avaliar o método proposto, diversas situações de falta foram simuladas em diferentes alimentadores (AL) do parque eólico adotado. Os sinais de tensão foram amostrados na barra PCC da Fig. 3, para cada falta. Simulou-se faltas monofásicas, bifásica, bifásicas-terra e em alimentadores distintos, adotando-se os seguintes valores de resistências de falta: 0 Ω, 10 Ω, 30 Ω, 50Ω e 100Ω. Ao total 170 curtos-circuitos foram considerados.

A Tabela 1 apresenta o compilado dos resultados dos 10 testes. Os índices na coluna do sistema de inferência representam o cenário que está sendo analisado. Ao analisar por cenário, nota-se que ambos os sistemas de inferência apresentam resultados semelhantes na média para o Cenário 1, com o sistema de inferência Mamdani necessitando de um tempo menor para sua execução. Já no Cenário 2, observa-se que o método de inferência Mamdani não apenas foi mais rápido, mas também obteve, em média, soluções de melhor qualidade.

Em relação aos cenários, nota-se que quatro regras podem não ser suficientes para gerar um bom modelo *fuzzy*, considerando que todos os resultados do Cenário 2 foram superiores quando comparados aos do Cenário 1, independentemente da meta-

heurística utilizada para otimização ou do sistema de inferência escolhido.

Tabela 1 Resultados obtidos.

Sistema de Inferência	Meta-heurística	Precisão Geral			Tempo médio
		Mínima	Média	Máxima	
Mamdani¹	PSO	55,00%	76,50%	96,67%	205,15s
	GA	58,33%	72.67%	96,67%	152,12s
Takagi-Sugeno¹	PSO	60,00%	72,33%	95,00%	391,40s
	GA	60,00%	73,50%	91,67%	311,40s
Mamdani²	PSO	81,67%	88,67%	95,00%	270.46s
	GA	60,00%	85,00%	100,00%	204,31s
Takagi-Sugeno²	PSO	66,67%	88,83%	95,00%	237,68s
	GA	61,67%	75,17%	95,00%	426,60s

Por fim, ao analizar as meta-heurísticas abordadas para este problema, nota-se que o PSO obtém soluções melhores ou semelhantes às soluções obtidas pelo GA. Tabela 2 apresenta as precisões médias por tipo de falta em cada caso estudado. De modo geral, os melhores resultados foram obtidos no Cenário 2. Considerando a maior precisão mínima, o sistema de inferência Mamdani com a meta-heurística PSO se destaca (mínimo de 82,22%). No entanto, considerando que a falta mais comum (falta monofásica) e a falta mais complexa para o sistema de inferência Takagi-Sugeno com PSO se mostra superior, detectando a falta monofásica em 98,77% dos casos e a falta trifásica em 92,86% dos casos, embora apresente uma precisão de 79,17% para a falta bifásica.

Tabela 2 Precisão média por tipo de falta.

Sistema de Inferência	Meta-heurística	Tipos de falta			
		fase-terra	fase-fase	fase-fase-terra	fase-fase-fase
Mamdani¹	PSO	97,75%	41,71%	97,06%	69,81%
	GA	96,77%	17,13%	98,86%	86,21%
Takagi-Sugeno¹	PSO	96,47%	28,57%	94,94%	77,78%
	GA	96,30%	26,82%	94,71%	80,65%
Mamdani²	PSO	82,22%	96,10%	87,96%	92,00%
	GA	96,70%	36,69%	99,48%	80,00%
Takagi-Sugeno²	PSO	98,77%	79,17%	88,89%	92,86%
	GA	97,69%	32,07%	94,51%	83,61%

Para o Cenário 2, que apresentou os melhores resultados com o sistema de inferência Takagi-Sugeno utilizando PSO, são apresentadas as entradas (Fig. 4), as regras, a saída e a curva a $a_1 x b_0 x R$ (Fig. 5).

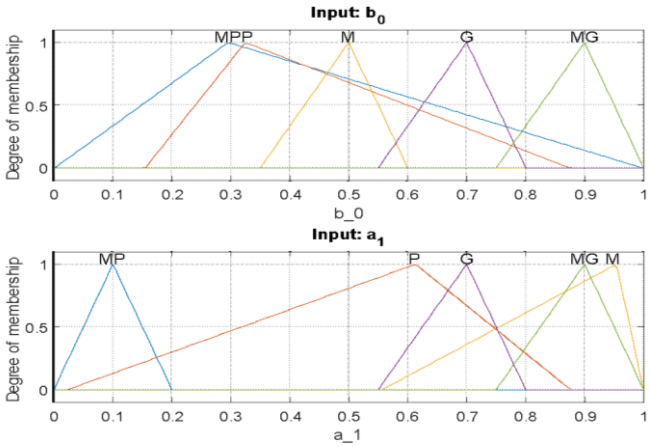

Fig. 4 Entrada do sistema de inferência Takagi-Sugeno utilizando PSO.

Tabela 3 Dados de entrada do sistema de inferência Takagi-Sugeno utilizando PSO.

	b_0	a_1
MP	[0,0014 0,2955 0,9975]	[0 0.1 0.2]
P	[0.1549 0.3245 0.8737]	[0.0233 0.6133 0.8759]
M	[0.35 0.5 0.6]	[0.5567 0.9540 0.9998]
G	[0.55 0.7 0.8]	[0.55 0.7 0.8]
MG	[0.75 0.9 1]	[0.75 0.9 1]

Regras:

1 SE $b_0 = P$ E $a_1 = MP$, ENTÃO $R = 1$

2 SE $b_0 = MG$ E $a_1 = MG$, ENTÃO $R = 2$

3 SE $b_0 = MP$ E $a_1 = P$, ENTÃO $R = 4$

4 SE $b_0 = M$ E $a_1 = G$, ENTÃO $R = 1$

5 SE $a_1 = P$, ENTÃO $R = 3$

6 SE $b_0 = MP$ E $a_1 = M$, ENTÃO $R = 4$

7 SE $b_0 = G$ E $a_1 = MP$, ENTÃO $R = 1$

8 SE $b_0 = P$ E $a_1 = M$, ENTÃO $R = 4$

9 SE $b_0 = MP$, ENTÃO $R = 1$

10 SE $b_0 = M$ E $a_1 = MP$, ENTÃO $R = 1$

11 SE $b_0 = P$ E $a_1 = MG$, ENTÃO $R = 4$

12 SE $b_0 = MG$ E $a_1 = P$, ENTÃO $R = 2$

13 SE $a_1 = MG$, ENTÃO $R = 2$

14 SE $b_0 = G$ E $a_1 = M$, ENTÃO $R = 4$

As saídas para este sistema são 4 funções constantes, sendo elas $f_1(x) = 0{,}9648$, $f_2(x) = 2{,}0145$, $f_3(x) = 3{,}9778$ e $f_4(x) = 4$.

Observa-se que o otimizador não diferencia os valores das entradas, apenas ajusta suas posições conforme necessário. Além disso, o número de regras utilizadas é significativamente maior em comparação com as 4 regras do cenário sem otimização, totalizando 14 regras distintas, o que resulta na curva apresentada na Fig. 5.

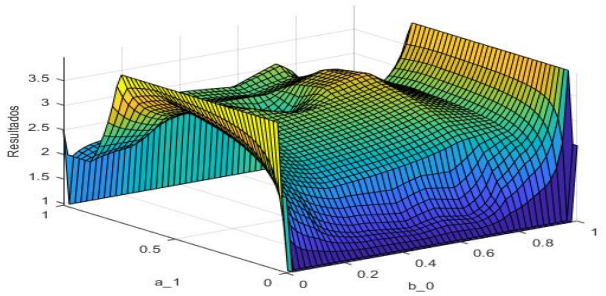

Fig. 5 Curva $a_1 x b_0 x R$.

5. CONCLUSÃO

Neste artigo, foi proposto um método baseado em inferência fuzzy e otimização por meta-heurísticas para a classificação de curtos-circuitos em alimentadores de Parques Eólicos. O objetivo foi solucionar o problema da escolha dos valores dos parâmetros de entrada, saída e das regras lógicas por meio da otimização desses parâmetros usando técnicas meta-heurísticas. Para validar o algoritmo proposto, 170 casos de faltas foram simulados em alguns alimentadores do parque eólico. Dois cenários foram definidos para avaliação dos resultados. Observou-se que ambos os sistemas de inferência apresentaram resultados semelhantes na média para o Cenário 1, com o sistema de inferência Mamdani exigindo menos tempo para sua execução. No entanto, no Cenário 2, o método de inferência Mamdani foi não apenas mais rápido, mas também alcançou, em média, soluções de melhor qualidade. Em relação às duas meta-heurísticas abordadas, o PSO obteve soluções melhores ou equivalentes às do GA. Por fim, os melhores resultados foram obtidos no Cenário 2, com o sistema de inferência Takagi-Sugeno utilizando a meta-heurística PSO se mostrando superior, detectando faltas monofásicas em 98,77% dos casos e faltas trifásicas em 92,86% dos casos.

O limite de 100 iterações/gerações para cada meta-heurística foi definido de forma intuitiva, sem um estudo detalhado dos parâmetros. Embora tenha sido eficaz para este estudo, há a possibilidade de que essa escolha esteja limitando a eficiência do algoritmo, assim como os demais parâmetros considerados para as meta-heurísticas mencionadas anteriormente. Estudos futuros poderiam investigar diferentes limites de iterações/gerações e seu impacto na performance e precisão das soluções. Realizar uma análise sistemática desses parâmetros poderia fornecer uma base mais robusta para otimizar o desempenho do algoritmo.

REFERÊNCIAS

Biscaro, A. A. P.; Pereira, R. A. F.; Kezunovic, M.; Mantovani, J. R. S. Integrated fault location and power-quality analysis in electric power distribution systems. IEEE Transactions on Power Delivery, Institute of Electrical and Electronics Engineers (IEEE), v. 31, n. 2, p. 428–436, apr 2016.

Chen, W.-H.; Liu, C.-W.; Tsai, M.-S. On-line fault diagnosis of distribution substations using hybrid cause-effect network and fuzzy rule-based method. IEEE Transactions on Power Delivery, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 2, p. 710–717, apr 2000.

Das, B. Fuzzy logic-based fault-type identification in unbalanced radial power distribution system. IEEE Transactions on Power Delivery, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 1, p. 278–285, jan 2006.

Decanini, J.; Tonelli-Neto, M.; Minussi, C. Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. IET Generation, Transmission & Distribution, Institution of Engineering and Technology (IET), v. 6, n. 11, p. 1112–1120, nov 2012.

Dehghani, M.; Khooban, M. H.; Niknam, T. fault detection and classification based on a combination of wavelet singular entropy theory and fuzzy logic in distribution lines in the presence of distributed generations. International Journal of Electrical Power & Energy Systems, Elsevier, v. 78, p. 455–462, 2016.

Global Wind Energy Council – GWEC 2024, acessado em 25 de abril de 2024.

Gomes, P.; Guarini, A.P., “O Processo de Recomposição das Cargas após Grandes Perturbações: um processo de desenvolvimento continuado.” XVIII SNPTEE, Curitiba, PR, 16 a 21 de Outubro de 2005.

Marro, A. A.; Souza, A. M. C.; Cavalcante, E. R. S.; Bezerra, G. S.; Nunes, R. O., “Lógica Fuzzy: Conceitos e aplicações”, Rio Grande do Norte, 2010.

Peixoto, L. B.; Coelho, R. R. A.; Mamede, D. R.; Paula, D. G. A.; Santo, S. G. D. Aplicação do Método de Simples Reatância e Takagi na Localização de Falta em uma Rede de Média Tensão de um Parque Eólico, SBSE 2020.

Rai, P.; Londhe, N. D.; Raj, R., Fault classification in power system distribution network integrated with distributed generators using CNN, Electric Power Systems Research, Vol. 192, (2021).

Santos, G. G; Metodologia integrada para detecção, classificação e localização de faltas em redes de distribuição de energia elétrica ativas. 2023. 156f. Tese (Doutorado em Engenharia Elétrica) Universidade de São Paulo- EESC/USP. São Carlos, 2023.

Sato, F. Análise de Curto-circuito e Princípios de Proteção em Sistemas de Energia Elétrica. [S.l.]: CAMPUS - GRUPO ELSEVIER, 2014. ISBN 978-85-352-6886-7.

Tonelli-Neto, M. D. S. Desenvolvimento de um sistema inteligente para o diagnóstico e prognóstico de falhas em sistemas de distribuição de energia elétrica. 2015. 114 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista "Julio de Mesquita FIlho- UNESP. Ilha Solteira. 2015.

Trindade, E. C. S; Leão, F. B.; Proposta de um algoritmo para detecção de faltas em Parques Eólicos utilizando distância Euclidiana, CBA 2022.

Zhao, M.; Barati, M. A real-time fault localization in power distribution grid for wildfire detection through deep convolutional neural networks. IEEE Transactions on Industry Applications, Institute of Electrical and Electronics Engineers (IEEE), v. 57, n. 4, p. 4316–4326, jul 2021.