

# A Localização de Falhas em um Sistema de Distribuição de Média Tensão com Geração Distribuída via Redes Neurais Artificiais

Leonardo Alves Paiva\* Mário Oleskovicz\*\*

\*Universidade de São Paulo, São Carlos, SP 13566-590 Brasil  
(e-mail: leonardoalvespaiva@alumni.usp.br).

\*\*Universidade de São Paulo, São Carlos, SP 13566-590 Brasil  
(e-mail: olesk@sc.usp.br)

---

**Abstract:** This work aims to address the problem of fault location in a medium voltage distribution system in the presence of Distributed Generation (DG), applying artificial intelligence. The chosen method is learning-based through Artificial Neural Networks (ANNs). The methodology consisted of simulating three-phase faults via PSCAD/EMTDC software, pre-processing (normalization and formatting of training and test sets), empirical tests, routine tests without DG, routine tests with DG, and choosing the best ANN topology. The results presented illustrate the applied tests and the best ANN topology found.

**Resumo:** Este trabalho tem como objetivo abordar o problema da localização de falhas em um sistema de distribuição de média tensão na presença de Geração Distribuída (GD), utilizando inteligência artificial. O método escolhido é baseado em aprendizagem pela aplicação de Redes Neurais Artificiais (RNAs). A metodologia consistiu na simulação de falhas trifásicas via o software PSCAD/EMTDC, no pré-processamento (normalização e formatação dos conjuntos de treinamento e de teste), e testes empíricos, testes sistemáticos sem GD, testes sistemáticos com GD, e na escolha da melhor topologia da RNA. Os resultados apresentados ilustram os testes aplicados e a escolha da melhor topologia da RNA encontrada.

**Keywords:** Artificial neural networks; Fault location; Distributed generation; Medium voltage distribution system.

**Palavras-chaves:** Redes neurais artificiais; Localização de falhas; Geração Distribuída; Sistema de distribuição de média tensão.

---

## 1. INTRODUÇÃO

Considerando que cerca de 80% da interrupção do fornecimento ao consumidor ocorre por causa de falhas (curtos-circuitos) na rede de distribuição (Bahmanyar et al. 2017), o enfoque em especial para essa área é de extrema importância para o tratamento do problema.

Assim, métodos para a localização de falhas com uma abordagem analítica têm sido propostos, entre eles, destacam-se os métodos baseados no cálculo da impedância, em medições esparsas e na teoria de ondas viajantes. Devido a questões de custos de implantação e à aplicabilidade em redes de distribuição, os métodos baseados em impedância são os mais interessantes de serem aplicados e vêm se adaptando à realidade da Geração Distribuída (GD) nos Sistemas de Distribuição de Média Tensão (SDMTs), que a fazem ter características ativas ao invés de somente passivas (Naidu et al. 2016).

Como existem vários tipos de falhas, o equacionamento para cada uma delas pode ser diferente. No entanto, há trabalhos sobre a formulação de uma única equação para todos os tipos de falhas, a qual fornece todas as possíveis informações e,

posteriormente, determina a localização exata de ocorrência do distúrbio baseada nas medições de tensão na subestação e nos pontos de instalação da GD (Alwash, Ramachandaramurthy and Mithulananthan 2015).

Por outro lado, métodos não analíticos, mas baseados em aprendizagem de máquina, têm sido aplicados para enfrentar os novos desafios propostos pela inserção de GD na rede. Entre esses métodos avaliados, estão as Redes Neurais Artificiais (RNAs), a *Support Vector Machine* (SVM), árvores de decisão e *Adaptive Boosting* (*AdaBoost*), além de outros métodos auxiliares como *k-means*, usado para prever dados de medições incompletas (Maruf et al. 2018).

Notavelmente, as RNAs têm recebido mais destaque e sido alvo dos esforços dos pesquisadores na área. Dessa maneira, RNAs com aplicações diferentes podem ser usadas conjuntamente para resolverem problemas relacionados à localização de falta, como, por exemplo, para detectar a seção física do sistema em que a falta ocorreu e depois para localizá-la mais precisamente (Petite, Santos and Asano 2017). Também se pode aplicar uma RNA para classificar o tipo da falta e, para cada tipo possível, treinar uma RNA específica (Usman, Ospina and Faruque 2018). Outra proposta ainda é aplicar uma RNA para cada ponto de

medição, neste caso na subestação e nos pontos de instalação da GD. A localização física da falta é apontada comparando os resultados dispostos pelas distintas RNAs (Dehghani, Khodnia and Dehghan 2017).

Além da aplicação de RNAs como técnica de localização, também se pode usá-la em outras funções, como na detecção e na classificação das faltas. Sendo cada problema abordado por arquiteturas distintas e por conjuntos de dados representativos de forma a procurar um meio mais sistemático e menos empírico para suas configurações (Acácio et al. 2017).

Ademais, as RNAs podem ser associadas a outros métodos e ferramentas, inclusive analíticos. Por exemplo, medições na subestação de uma rede com GD podem ser submetidas à Transformada Rápida de Fourier (TRF) para obter o espectro de frequência e, em seguida, agrupar as frequências de cada fase em grupos para alimentar uma RNA, que porventura possa ter sua aprendizagem facilitada (Aslan and Yagan 2016). Outra ferramenta analítica que pode ser aplicada é a superposição de componentes na fase de processamento de sinais. Aplicar componentes superpostos, calculados como a diferença entre os sinais de pré e pós-falta, imprimem características desejáveis de imunidade às variações de carga, que, por consequência, podem tornar o desempenho das RNAs aplicadas mais robusto em tal cenário (Barra et al. 2019).

Dessa forma, tendo em vista a abrangência e aplicabilidade das RNAs, este trabalho vem abordar o problema da localização de faltas em um SDMT. A princípio, são realizados alguns testes empíricos para tomar decisões sobre a estrutura e topologia da RNA e, então, realizar testes sistemáticos para encontrar as melhores topologias em uma rede sem e com GD.

## 2. METODOLOGIA APLICADA

Os passos da metodologia aplicada nesta pesquisa podem ser seguidos na Figura 1 e são explicados na sequência.

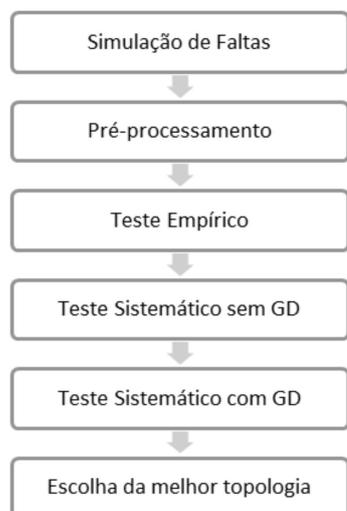


Fig. 1 Etapas consideradas.

### 2.1 Simulação de Faltas

Para os experimentos, foram utilizados dois conjuntos de dados (com e sem GD). Os dados de ambos os conjuntos foram obtidos através de simulações realizadas no software PSCAD/EMTDC (Manitoba HVDC Research Centre 2010), de faltas no trecho inicial do sistema teste do CIGRÉ (CIGRÉ 2014) (em destaque na Figura 2), com frequência de 60 Hz, configuração radial e cargas desconectadas nas barras 1 e 12, visando maior penetração da GD.

As faltas foram distribuídas em 29 locais igualmente espaçados (a cada 97,24 m) ao longo do trecho escolhido de 2,8 km. Para cada local, foram aplicadas as resistências de falta de 0,001  $\Omega$ , 1  $\Omega$ , 10  $\Omega$  e 20  $\Omega$ . Ao todo, foram 116 faltas trifásicas simuladas para cada conjunto. No caso das simulações com GD, foi inserido um gerador eólico de 2 MW na barra 8 do sistema. Para cada falta simulada, foram geradas sete referências: três para as amplitudes dos sinais trifásicos de tensão, três para as amplitudes dos sinais trifásicos de corrente e, um para a localização exata da falta.

### 2.2 Pré-processamento

Antes de iniciar os testes com RNAs, os dados obtidos precisaram ser pré-processados a fim de facilitar o aprendizado. Assim, todos os valores foram normalizados entre o máximo e o mínimo da função de ativação. Também se dividiu cada conjunto original em conjuntos de treinamento e de teste de forma aleatória, assegurando que os valores máximos e mínimos estivessem presentes nos dados empregados para a etapa de treinamento.

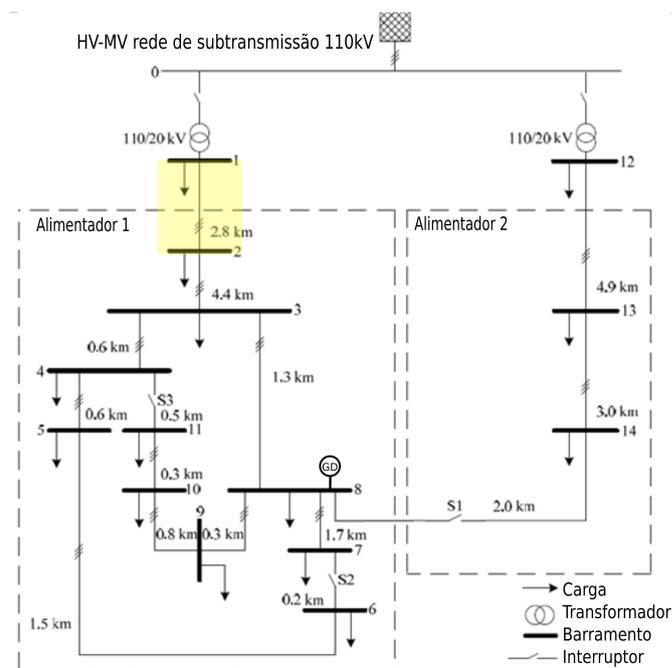


Fig. 2 CIGRÉ (trecho grifado com faltas simuladas e GD na barra 8).

### 2.3 Teste Empírico

Esta etapa buscou de forma empírica definir algumas condições para a fase de teste sistemática, de forma que esta fosse factível de ser efetuada. Inicialmente, o conjunto de dados foi dividido em 70% para treinamento e 30% para a fase de teste, sendo escolhida a função logística para ativação dos neurônios. Foram testadas topologias de uma camada (com 10 e com 20 neurônios) e de duas camadas (10 neurônios na primeira e 5 na segunda; 20 na primeira e 10 na segunda). Com a mesma divisão dos dados, também se testou a função de ativação hiperbólica para topologias de uma camada (com 10 neurônios) e de duas camadas (20 neurônios na primeira e 10 na segunda). Para estas mesmas duas topologias, foi aplicada a divisão dos dados em 80% para o treinamento e 20% para o teste, com a função de ativação logística. Além disso, também se testou a função linear para ativação do neurônio de saída neste caso. Os testes conduzidos nesta fase são expostos de maneira metódica na Tabela 1 e serão posteriormente comentados.

Além dos parâmetros já citados, também foram variados os tipos de entrada da RNA considerando: somente medidas de tensão (V), somente medidas de corrente (I), e medidas de tensão com medidas de corrente (V + I). A medida de desempenho escolhida para avaliar as topologias nesta fase foi o erro quadrático médio (MSE - *Mean Squared Error*) (Sammut and Webb 2011).

**Tabela 1. Testes realizados.**

% Dados Treinamento	Função de ativação	Neurônios	Resultados
70%	Logística	10	Tabela 2
		20	
	Tangente Hiperbólica	10 e 5	Tabela 3
		20 e 10	
80%	Logística	10	Tabela 5
		20 e 10	
	Logística + Linear na saída	10	
		20 e 10	

### 2.4 Teste sistemático sem GD

Com base nos testes realizados na etapa anterior, 70% do conjunto de dados foi separado para o treinamento, dos quais 15% das amostras foram utilizadas para a validação cruzada durante essa fase. Os outros 30% dos dados foram destinados ao teste após o treinamento. Foram consideradas somente medidas de tensão na camada de entrada. A função de ativação escolhida foi a logística, exceto para o neurônio de saída, ao qual se definiu a função linear.

A medida de desempenho escolhida para o teste, exposta em (1), foi uma adaptação do erro absoluto médio percentual

(MAPE - *Mean Absolute Percentage Error*) (Kim and Kim 2016), sendo  $n$  o total de amostras de teste,  $y_i$  o valor esperado,  $x_i$  o valor predito pela RNA e  $L$  o comprimento do trecho do SDMT considerado, no caso 2,8 km. A adaptação efetuada teve como objetivo representar o quanto a localização predita está distante da real.

$$MAPE' = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - x_i|}{L} \quad (1)$$

Determinados os critérios do teste, então, variaram-se os números de neurônios na primeira e na segunda camada, ambos entre 1 e 30, a fim de se avaliarem as melhores topologias, resultando em 900 treinamentos e 900 testes. Essa avaliação sistemática de topologias foi repetida 3 vezes, totalizando 2.700 treinamentos e 2.700 testes, com o intuito de aferir conclusões consistentes. Vale ressaltar que, visando que os testes não se estendessem demasiadamente, foi adotado o máximo de 10.000 épocas de treinamento e, até 200 falhas na validação cruzada, objetivando encontrar topologias que fossem capazes de melhor absorver o conhecimento e aprender.

### 2.5 Teste sistemático com GD

Nesta etapa, foram aplicados os mesmos critérios usados na fase anterior, excetuando o conjunto de dados, substituído pelo conjunto simulado com o aerogerador de 2 MW na barra 8. Os dados foram divididos novamente em 70% para treinamento, dos quais 15% para validação cruzada, e os 30% restantes para teste. A medida de desempenho aplicada foi o MAPE adaptado. Também se efetuaram os mesmos 900 treinamentos e 900 testes repetidos 3 vezes, totalizando 2.700 treinamentos e 2.700 testes, bem como foi estipulado o máximo de 10.000 épocas de treinamento e até 200 falhas na validação cruzada.

### 2.5 Escolha da melhor topologia

Por último, foram comparadas duas topologias, uma com menos neurônios e outra com mais, obtidas no teste com GD. Para ambas, foram calculados os erros médios simples para cada amostra de teste ( $X_i$ ), como indicado em (2), em que  $x_i$  é a localização de falta obtida,  $e_i$  é o local exato e  $N$  o número de vezes em que o treinamento e teste foram repetidos, no caso 3. Para avaliar se os erros das topologias diferiam significativamente, foi aplicado o teste  $t$  pareado (Montgomery and Runger 2003). Para tanto, utilizou-se a variável  $D_i$ , equação (3), que é a diferença entre os erros médios das topologias para cada amostra. Foi considerado como hipótese nula que a média de  $D_i$  é igual a  $d_0 = 0$ , ou seja, os erros não diferem significativamente. Como hipótese alternativa, foi considerado que a média de  $D_i$  é diferente de  $d_0 = 0$ , ou seja, os erros diferem significativamente.

$$X_i = \frac{1}{N} \sum_{i=1}^N x_i - e_i \quad (2)$$

$$D_i = X_{1i} - X_{2i} \quad (3)$$

### 3. RESULTADOS

Os resultados da pesquisa de fato são evidenciados a partir da etapa de aplicação da RNA em um SDMT. Nesta etapa, foram testadas várias configurações e topologias para a RNA.

#### 3.1 Teste Empírico

A Tabela 2 apresenta os resultados para uma RNA com uma camada intermediária com 10 e 20 neurônios.

Já na Tabela 3, estão os resultados para a RNA com duas camadas intermediárias: uma com 10 neurônios na primeira camada e 5 na segunda, e outra com 20 neurônios na primeira camada e 10 na segunda.

**Tabela 2. Resultados para a RNA com uma camada intermediária.**

70% da base para treinamento / função logística					
RNA com uma camada intermediária					
10 neurônios			20 neurônios		
V + I	V	I	V + I	V	I
3,38E-02	3,56E-02	6,48E-02	3,40E-02	3,59E-02	6,48E-02

**Tabela 3. Resultados para a RNA com duas camadas intermediárias.**

70% da base para treinamento / função logística					
RNA com duas camadas intermediárias					
10 e 5 neurônios			20 e 10 neurônios		
V + I	V	I	V + I	V	I
3,38E-02	4,12E-02	6,48E-02	3,37E-02	3,42E-02	6,48E-02

Com os resultados obtidos, escolheram-se as topologias com os menores índices de erros para serem testadas com mais uma variação. Nesse caso, foi escolhida a topologia de uma camada intermediária com 10 neurônios (entradas com medidas considerando somente a tensão, e com medidas de tensão e corrente juntamente), bem como a RNA de duas camadas com 20 neurônios na primeira e 10 na segunda (considerando somente as medidas de tensão na entrada). Apesar das medidas de tensão e corrente apresentarem erros próximos, foi considerado que a aprendizagem com medidas somente de tensão seria mais eficiente, pois são necessários menos informações (medidas) de entrada e menos conexões entre os neurônios de entrada e da primeira camada intermediária. Além disso, uma topologia menor torna o processo de treinamento menos dispendioso computacionalmente e menos demorado, características importantes para viabilizar os testes sistemáticos da próxima etapa.

Para as topologias escolhidas, a função de ativação foi alterada para tangente hiperbólica. As medidas de desempenho podem ser observadas na Tabela 4.

**Tabela 4. Resultados para as RNAs considerando a função de ativação tangente hiperbólica.**

70 % da base para treinamento / função tangente hiperbólica		
RNA com uma camada com 10 neurônios	RNA com duas camadas com 20 e 10 neurônios	
V + I	V	V
6,00E-04	4,42E-02	6,21E-02

Como se pode observar na Tabela 4, os resultados obtidos usando a tangente hiperbólica não são melhores que para a função logística. A seguir, foram usadas as mesmas topologias da variação anterior considerando 80% da base de dados na fase de treinamento. A função de ativação foi a logística, porém, foram testadas funções diferentes para o neurônio de saída: a função logística e a linear. Os resultados podem ser vistos na Tabela 5, na qual fica evidente que a função de ativação linear no neurônio de saída apresentou resultados com índices MSE menores.

**Tabela 5. Resultados para as RNAs considerando 80% da base de dados para o treinamento.**

80 % da base para o treinamento			
	RNA com uma camada com 10 neurônios	RNA com duas camadas com 20 e 10 neurônios	
	V + I	V	V
<b>Função de saída logística</b>	4,16E-02	4,43E-02	4,28E-02
<b>Função de saída linear</b>	0,00E+00	1,40E-03	1,50E-03

Para ressaltar o desempenho obtido de uma maneira gráfica e intuitiva em relação às possíveis entradas, a Figura 3 mostra as localizações das faltas estimadas em ordem crescente para as diferentes topologias e a localização esperada, isto é, o local real da falta.

Na Figura 4, encontra-se representado o erro percentual médio das topologias para cada falta aplicada da Figura 3. Vale lembrar que para esses casos as RNAs consideram funções de ativação logística em seus neurônios, exceto o de saída que conta com a ativação linear. Foram usados 70% da base de dados em seus treinamentos, sendo o restante para os testes. As descrições das quatro Topologias (Ti) empregadas são apresentadas a seguir.

#### Topologias:

T1 – RNA com uma camada intermediária: 10 neurônios, e empregando dados de tensão e corrente;

T2 - RNA com uma camada intermediária: 10 neurônios, e empregando dados de tensão;

T3 - RNA com duas camadas intermediárias: 10 e 5 neurônios, e empregando dados de tensão e corrente; e

T4 - RNA com duas camadas intermediárias: 10 e 5 neurônios, e empregando dados de tensão.

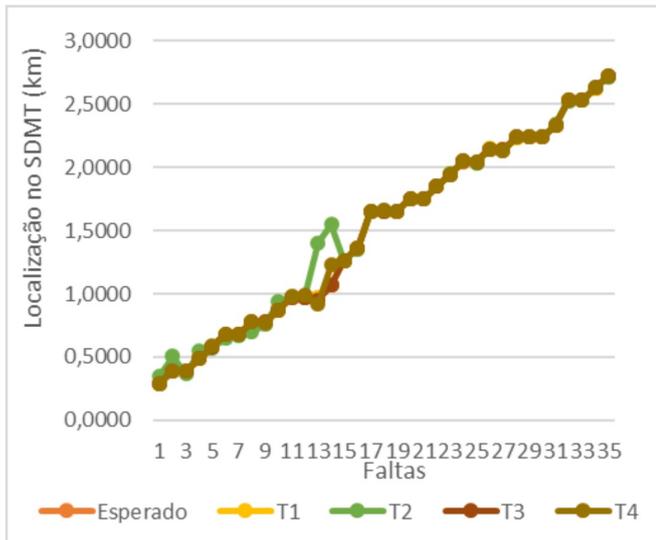


Fig. 3 A localização da falta a partir de cada uma das quatro topologias de RNA analisadas.

### 3.2 Teste sistemático sem GD

A Figura 5 ilustra o desempenho médio para cada RNA composta de  $X_1$  neurônios na primeira camada e  $X_2$  neurônios na segunda camada, representado pela cor dos quadrados, de acordo com a escala de cores colocada ao lado. A região a partir do 18° neurônio da segunda camada, entre o 12° e o 18° neurônio da primeira camada aparenta melhores resultados. O mesmo vale para a região a partir do 18° neurônio da segunda camada, entre o 25° e o 30° neurônio da primeira camada. No entanto, vale destacar alguns desempenhos separados das topologias contendo: 14 neurônios na primeira camada e 19 na segunda; 12 neurônios na primeira camada e 24 na segunda; 27 neurônios na primeira camada e 26 na segunda; 29 na primeira camada e 30 na segunda; e 30 na primeira camada e 30 na segunda.

Os menores valores dos erros obtidos estão em torno de 5%, o que se mostra satisfatório para aplicações práticas (Petite, Santos and Asano 2017). Mesmo assim, vale ressaltar que foram adotadas algumas restrições para que a busca não se estendesse demasiadamente. Por exemplo, foi adotado o máximo de 10.000 épocas de treinamento e até 200 falhas na validação cruzada. O objetivo da busca foi encontrar a topologia que fosse capaz de melhor absorver o conhecimento e aprender. Por conseguinte, encontrada a topologia que melhor represente o problema, esta poderia ser treinada por mais tempo e ter os parâmetros de treinamento variados a fim de se aumentar o seu desempenho.

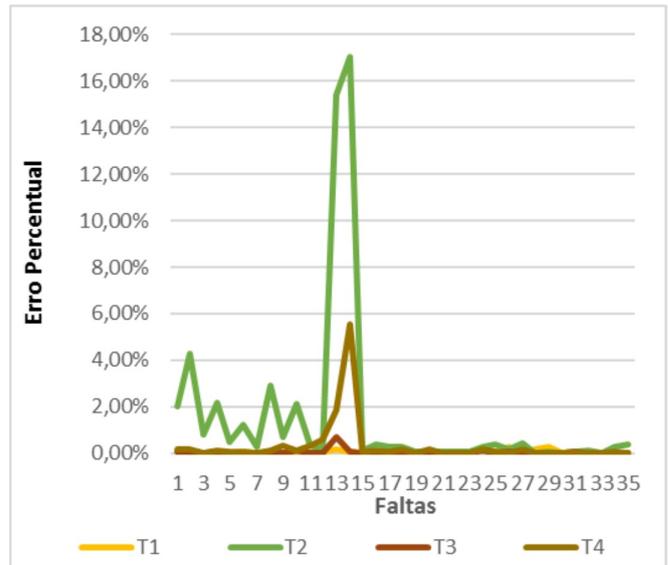


Fig. 4 Erro percentual na localização de falta para cada uma das quatro topologias de RNA.

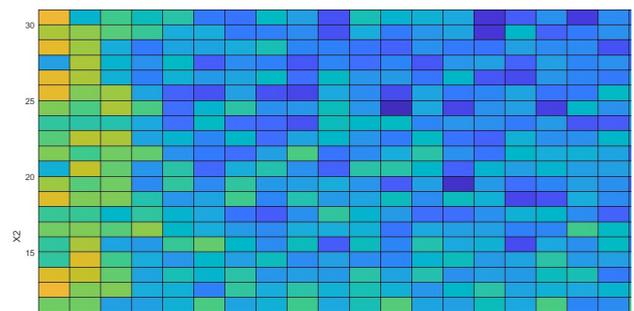


Fig. 5 Média de três simulações para o erro para cada combinação de neurônios nas primeira e segunda camadas da RNA implementada para o SDMT sem GD.

### 3.3 Teste sistemático com GD

Na Figura 6, é ilustrado o desempenho médio para cada RNA composta de  $X_1$  neurônios na primeira camada e  $X_2$  neurônios na segunda camada, representado pela cor dos quadrados, de acordo com a escala de cores lateral.

Observando a Figura 6, é válido destacar algumas regiões: a partir do 12° neurônio na segunda camada, e a partir do 26° neurônio na primeira camada; e a partir do 24° neurônio na segunda camada e entre o 20° e o 22° neurônio na primeira camada.

Comparando as Figuras 5 e 6, é nítida a maior igualdade das cores, o que indica resultados mais satisfatórios e mais distribuídos. Todavia, ao analisar as escalas, percebe-se que essa homogeneidade se dá em um patamar maior de erro, em torno de 10%, o que é explicado pela presença da GD que adiciona fluxo bidirecional de potência e dificulta o processo de localização.

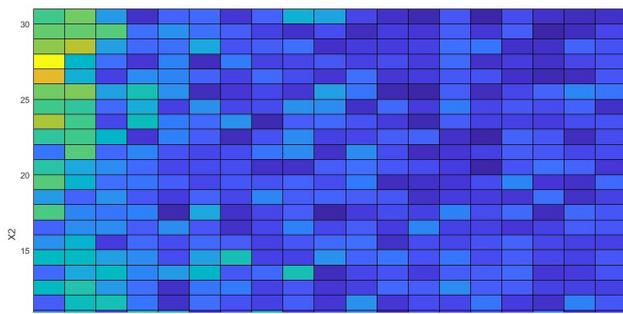


Fig. 6 Média de três simulações para o erro para cada combinação de neurônios nas primeira e segunda camadas da RNA implementada para o SDMT com GD.

Dado que os desempenhos aparentam ser mais próximos que na etapa anterior, tanto em topologias maiores quanto em menores, torna-se interessante comparar os desempenhos de uma topologia com menos neurônios e de uma topologia com mais neurônios para avaliar a mais eficiente, o que será feito na próxima seção.

### 3.4 Escolha da melhor topologia

Entre as topologias representadas na Figura 6, destacam-se duas: a primeira RNA com 21 neurônios na primeira camada e 24 na segunda; e segunda RNA com 7 neurônios na primeira camada e 12 na segunda. A primeira apresentou um índice MAPE adaptado de 10,92%, enquanto a segunda apresentou 11,19%. O primeiro valor evidencia um erro menor. No entanto, a diferença entre os índices é pequena e não necessariamente é significativa a ponto de escolher uma em detrimento da outra. Assim, aplica-se o teste *t* pareado, cujos resultados calculados são exibidos na Tabela 6, em que se pode ver que o *p*-valor é um número muito pequeno. O *p*-valor serve como limite para decidir se uma hipótese será aceita ou rejeitada, sendo o menor nível de significância que levaria à rejeição da hipótese nula com os dados fornecidos (Montgomery and Runger 2003). Portanto, a hipótese nula pode ser rejeitada mesmo ao nível de significância de 0,01%, o que significa que os resultados das topologias diferem significativamente.

Tabela 6. Medidas para o teste *t* pareado.

$\bar{D}$	$S_D$	T	P-valor
0,2023	0,0757	15,8162	3.0465e-17

Tabela 7. Medidas descritivas para o erro médio simples. (Xi).

Topologia	Média	Mediana	Variância
7 e 12	-0,3996	-0,1876	0,2489
21 e 24	-0,1973	-0,0166	0,2212

Sabendo que os resultados não são iguais, observam-se as medidas descritivas para o erro médio simples de cada

topologia, como mostrado na Tabela 7, constatando-se que a topologia 21 e 24 possui medidas menores de erro. Isto pode ser visto tanto pela média, quanto pela mediana, que é uma medida robusta a *outliers* (pontos fora da curva). As variâncias referentes às duas topologias são muito parecidas, embora seja menor para a topologia 21 e 24.

Em aplicações de RNA em que o treinamento ocorre em tempo real, uma topologia menor pode ser preferível mesmo que o índice de erros seja um pouco maior, visto que a agilidade no treinamento é uma característica preponderante. Entretanto, no caso de localização de faltas em um SDMT, o treinamento usualmente acontece *offline*, ou seja, é realizado anteriormente à aplicação. Logo, o tempo de treinamento e outros fatores relacionados acabam não influenciando a velocidade para a RNA localizar a falta, já que a rede neural, após treinada, resume-se a um conjunto de operações matriciais. Em contrapartida, devido às grandes extensões que uma linha de distribuição pode assumir, um pequeno incremento no erro de localização pode ser significativo e inconveniente na prática. Nesses casos, a exatidão da resposta da RNA é preferível em relação ao tempo de treinamento.

Portanto, tendo em vista a situação de localização de faltas em um SDMT, com base nas medidas descritivas da Tabela 7, e sabendo que os erros diferem significativamente, pode-se afirmar que a topologia de 21 neurônios na primeira camada e 24 na segunda apresenta o melhor desempenho para localização de faltas no sistema com GD.

## 4. CONCLUSÕES

Nesta pesquisa foram realizados vários testes para encontrar a melhor topologia para localizar faltas em um sistema com GD. Foram aplicados primeiramente testes empíricos para definir diretrizes para, depois, testar topologias sistematicamente. Obtidos os resultados e comparados os desempenhos, então procurou-se atestar qual seria a melhor topologia. Esta abordagem mostra-se promissora, estando aberta a evoluções e adaptações, tanto para outros casos (outros SDMTs ou tipos de falta), quanto devido ao melhor processamento das informações decorrente de avanços tecnológicos.

## REFERÊNCIAS

- Acácio, L. C., Guaracy, P. A., Diniz, T. O., Araujo, D. R. R. P. and Araujo, L. R. (2017). Evaluation of the Impact of Different Neural Network Structure and Data Input on Fault Detection. *2017 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*, p. 1-5.
- Alwash, S.F., Ramachandaramurthy, V. K. and Mithulananthan, N. (2015). Fault-Location Scheme for Power Distribution System with Distributed Generation. *IEEE Transactions on power delivery*, volume (30), n. 7, p.1187-1195.
- Aslan, Y. and Yagan, E. (2016). ANN based fault location for medium voltage distribution lines with remote-end source. *2016 International Symposium on Fundamentals of Electrical Engineering*, p. 1-5.

- Bahmanyar, A., Jamali, S., Estebsari, A. and Bompard, E. (2017). A comparison framework for distribution system outage and fault location methods. *Electric Power Systems Research*, volume (145), p.19-34.
- Barra, P. H. A., Pessoa, A. L. S., Menezes, T. S., Santos, G. G., Coury D. V. and Oleskovicz, M. (2019) Fault location in Radial Distribution Networks Using ANN and Superimposed Components. *2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*, p. 1-6.
- CIGRE. (2014). *Benchmark Systems for Network Integration of Renewable and Distributed Energy Resources*, p. 119.
- Dehghani, F., Khodnia, F. and Dehghan, E. (2017) Fault location of unbalanced power distribution feeder with distributed generation using neural networks. *CIREC - Open Access Proceedings Journal*, volume (2017), n. 1, p. 1134-1137.
- Kim, S. and Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, volume (32), p. 669-679.
- Manitoba HVDC Research Centre (2010). *User's guide: a comprehensive resource for EMTDC*. Manitoba HVDC Research Centre, Winnipeg.
- Maruf, H. M. M., Müller, F., Hossan, M. S. and Chowdhury, B. (2018). Locating Faults in Distribution Systems in the Presence of Distributed Generation using Machine Learning Techniques. *2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG)*, p. 1-6.
- Montgomery, D. C. and Runger, G. C. (2003). *Applied statistics and probability for engineers*. 3rd ed. John Wiley & Sons, New York.
- Naidu, O., Gore, R., George, N. and Ashok, S. (2016). A new approach for fault location on modern distribution systems with integrated DER. *2016 Biennial International Conference on Power and Energy Systems: Towards Sustainable Energy (PESTSE)*, p. 1-6.
- Petite, F. S. V., Santos, R. C. and Asano, P. T. L. (2017). A Scheme Based on ANNs for Single-Phase Fault Location in Distribution Systems with DG. *2017 IEEE Manchester PowerTech*, p. 1-6.
- Sammut, C. and Webb, G. I. (2011). *Encyclopedia of machine learning*. Springer, New York.
- Usman, M. U., Ospina, J. and Faruque, M. O. (2018). Fault classification and location identification in a smart distribution network using ANN. *2018 IEEE Power & Energy Society General Meeting (PESGM)*, p. 1-6.