

Aplicação de Redes Neurais Artificiais para a Localização de Falhas por Área em Sistemas de Distribuição Considerando Geração Distribuída

João Pedro B. da Silva*. Leandro da G. Ribeiro**
Debora R. R. P. Araujo***. Leandro R. Araujo****

*Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora, Brasil
(e-mail: brito.joao@engenharia.ufjf.br).

**Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora, Brasil
(e-mail: leandro.ribeiro@engenharia.ufjf.br).

***Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora, Brasil
(e-mail: debora.rosana@ufjf.edu.br).

****Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora, Brasil
(e-mail: leandro.araujo@ufjf.edu.br).

Abstract: Due to the low magnitude of fault currents, traditional protection cannot detect high impedance faults (HIFs) in distribution systems. Concomitantly with this difficulty, distributed generation makes fault location even more difficult. Because of this, this work develops a method for detecting and locating single-phase high-impedance faults in distribution systems with distributed generation using Artificial Neural Networks. The work included tests on the IEEE 34 bus system. The results demonstrated that the developed method is highly efficient for all cases studied, providing a promising solution for detecting and locating FAIs in power distribution systems with distributed generation.

Resumo: A proteção tradicional é incapaz de detectar faltas de alta impedância (FAIs) em sistemas de distribuição devido à baixa magnitude das correntes de defeito. Concomitantemente a esta dificuldade, a geração distribuída contribui para dificultar ainda mais a localização de faltas. Por conta disso, neste trabalho é desenvolvido um método para detecção e localização de faltas monofásicas de alta impedância em sistemas de distribuição com geração distribuída, utilizando Redes Neurais Artificiais. O trabalho incluiu testes no sistema IEEE 34 barras. Os resultados demonstraram que o método desenvolvido possui alta eficiência para todos os casos estudados, fornecendo uma solução promissora para a detecção e localização de FAIs em sistemas de distribuição de energia com geração distribuída.

Keywords: High impedance fault; Fault location; Distribution systems; Artificial Neural Networks.

Palavras-chaves: Falta de alta impedância; Localização de falta; Sistemas de distribuição; Redes Neurais Artificiais.

1. INTRODUÇÃO

A localização de faltas em sistemas de distribuição de energia elétrica é uma questão de extrema importância para garantir a segurança e a confiabilidade do fornecimento de energia. Quando ocorrem faltas, seja por falhas em equipamentos, fenômenos naturais ou erros humanos, é essencial identificar rapidamente a localização dessas faltas para minimizar os danos, garantir a segurança humana e restaurar o serviço o mais rápido possível.

As faltas sólidas (baixa resistência de contato) são relativamente fáceis de serem detectadas, por outro lado, lidar com as chamadas faltas de alta impedância (FAIs) é considerado um desafio atualmente. Essas faltas de alta impedância são caracterizadas por correntes de falta de baixa magnitude, muitas das vezes com variações de magnitude semelhantes às correntes de operação normal do sistema, o que dificulta ou impossibilita sua detecção utilizando as técnicas

convencionais de proteção contra sobrecorrente dos sistemas de distribuição. Exemplos comuns de faltas de alta impedância incluem condutores caídos em solo seco ou cabos tocando galhos de árvores e postes (Ghaderi et al., 2017).

Junto ao exposto acima, existe uma crescente adoção da geração distribuída (GD) pelos diversos consumidores conectados aos sistemas de distribuição, apresentando desafios adicionais para a localização de faltas. A presença da GD introduz novos padrões de fluxo de corrente e pode afetar a detecção e localização de faltas em sistemas de distribuição (Gururajapathy et al., 2018).

Ademais, a inserção de GDs ocasiona impactos na coordenação da proteção do sistema como variação dos níveis de curtos-circuitos e fluxos bidirecionais (Britto et al., 2004). Em Wang et al. (2019) foram analisadas características de correntes de falta em sistemas de distribuição com integração de múltiplos sistemas fotovoltaicos.

Em Penido et al (2022) é proposto um método analítico de sequência zero, com o objetivo de localizar faltas em sistemas de distribuição ricos em geração distribuída. Semelhantemente, um método de localização de falhas monofásicas à terra em redes de distribuição com base nas características de distribuição dos componentes de sequência zero é desenvolvido em Rui et al. (2018).

Diante das dificuldades citadas, surgem oportunidades para o uso de técnicas avançadas, como redes neurais artificiais (RNAs), na localização de faltas por área em sistemas de distribuição de energia elétrica. As RNAs têm a capacidade de aprender padrões complexos a partir de dados e são capazes de lidar com a variabilidade dos sistemas elétricos, e em Ledesma et al. (2020), é proposto um método de identificação e localização de faltas de alta impedância em sistemas de distribuição com geração distribuída utilizando as grandezas de fase juntamente com as redes neurais artificiais e medições sincronizadas.

É possível utilizar várias ferramentas distintas para detecção e localização de faltas, em Cavalari et al. (2020), o método desenvolvido utiliza busca exaustiva para detectar e localizar FAIs em alimentadores de distribuição utilizando correntes de fase, e em Baquí et al. (2011) e Silva et al. (2018) são desenvolvidas metodologias para detecção de faltas de alta impedância utilizando transformada wavelet e redes neurais artificiais.

Este artigo apresenta um método baseado em redes neurais artificiais para a detecção e localização de faltas monofásicas de alta impedância em sistemas de distribuição de energia elétrica. O método proposto utiliza medidas de corrente fasoriais e de sequências zero e negativa, sendo a utilização conjunta de grandezas de fase e de sequência uma contribuição do método. A utilização dos dois conjuntos de medições facilita o desempenho das redes neurais em identificar as características dos defeitos, resultando em melhores resultados no processo de detecção das faltas.

No método proposto, o sistema analisado é dividido em áreas específicas de monitoramento que terão suas próprias redes neurais para cada fase para identificação de possíveis faltas. As características específicas dos sistemas de distribuição, como variação de carga, variação dos níveis das correntes de falta, desequilíbrios e presença de GD são consideradas.

2. CONSIDERAÇÕES INICIAIS

2.1 Modelagem das Faltas

As faltas em um sistema de distribuição podem ser transitórias ou permanentes. As faltas transitórias, ou momentâneas, são classificadas como um caso temporário que origina um curto-circuito sustentado pela ocorrência de arco elétrico, e podem ser extintas rapidamente pelo desligamento do circuito por meio do equipamento de proteção adequado.

As faltas podem acontecer em uma, duas ou até nas três fases, e envolver ou não a terra. Considerando a probabilidade de ocorrência, as faltas monofásicas envolvendo a terra

representa 70% do total verificado historicamente. Já as faltas bifásicas correspondem a 15% dos defeitos da rede, as bifásicas que fazem conexão com a terra equivalem a 10% e as trifásicas correspondem 5% de todas as ocorrências (Gururajapathy et al. 2017). Na Fig. 1 são ilustrados os tipos de falta que podem acontecer na rede elétrica.




Fig. 1 Faltas: representação dos tipos de faltas.

Neste trabalho serão utilizadas as medições de valores RMS e ângulos para realizar a detecção e localização da falta. Esse enfoque permite que a representação da falta seja feita por meio de um modelo de resistência simples, sendo o suficiente para a análise em regime permanente, uma vez que o uso de valores RMS permite filtrar o período transitório. A Fig. 2 ilustra o modelo de falta utilizado.




Fig. 2 Modelo de falta monofásica em barramento

2.2 Medidores

Em sistemas elétricos de potência, as medições das grandezas importantes para análises, como tensão e corrente, podem ser obtidas por meio de medições fasoriais ou não-fasoriais, sendo a última podendo ser sincronizada ou não.

Medidores não-fasoriais medem apenas o módulo das grandezas de interesse, ao contrário dos medidores fasoriais, que além do módulo, fornecem a defasagem angular e a frequência fundamental das grandezas medidas. Já as medições de sequência são adquiridas pela transformação dos valores das medições pelo Teorema de Fortescue, o qual fornece as componentes de sequência zero, positiva e negativa.

PMUs (*Phasor Measurement Unit*) são unidades de medição fasorial sincronizadas e possibilitam que o operador obtenha dados sincronizados. Esse tipo de medidor é utilizado nos testes neste trabalho para obtenção de medidas fasoriais e de sequência para avaliação do método.

2.3 Modelagem das GDs

Atualmente, nos sistemas de distribuição é comum encontrar unidades de geração de energia de médio e pequeno porte instaladas em proximidade às cargas. Essas unidades de geração podem ser tanto monofásicas, bifásicas quanto trifásicas e estão conectadas na rede de média ou na baixa tensão.

As gerações distribuídas (GDs) de maior porte, são frequentemente conectadas em média tensão (MT). A conexão de GD em sistemas de distribuição não altera a topologia radial das redes, no entanto, sua presença pode acarretar uma condição de operação na qual o fluxo de energia não seja mais unidirecional, permitindo o fluxo reverso nas redes de distribuição dependendo das condições de demanda e geração.

Neste trabalho as GDs foram modeladas com uma potência especificada de 20kW e foram conectadas na rede de média tensão por meio de transformadores delta-estrela.

3. METODOLOGIA PROPOSTA

A metodologia proposta neste trabalho possui como objetivo a localização da área e da fase e em que ocorrem faltas monofásicas na média tensão da rede de distribuição. O método proposto se baseia em Redes Neurais Artificiais para identificar as faltas e faz o uso de medições dos fasores de corrente, obtidos por meio de PMUs, e das componentes de sequência zero e negativa adquiridas através das Componentes Simétricas.

A metodologia implementada foi desenvolvida em duas etapas: Base de Dados e Localização de Faltas. A etapa de Base de Dados serve para a criação de uma base de dados para o treinamento das redes neurais.

Na etapa de Localização de Faltas é feita a leitura da base de dados que servirá para o treinamento das RNAs, e após o treinamento das RNAs, as mesmas estarão aptas por localizar a região defeituosa.

3.1 Base de Dados

O processo de construção da Base de Dados é realizado duas vezes, formando assim uma Base de Dados para treinamento e outra para teste das RNAs. Para cada RNA são utilizados 3000 casos simulados para treinamento e 4000 casos para teste.

A seguir é apresentada uma sequência de passos para o melhor entendimento da etapa de Base de Dados.

A1 - Neste passo é estabelecida a conexão entre o OpenDSS e o Matlab

A2 - Neste passo é inicializado o arquivo .DSS, o qual contém a modelagem do sistema de distribuição a ser testado

A3 - Neste passo são determinados os parâmetros para realizar as simulações que irão compor a base dados, sendo eles: conjunto de barras por área monitorada, número de casos que serão simulados com aplicação de faltas em cada área, número de casos que serão simulados sem aplicação de falta, limite de variação de carga, e valores mínimos e máximos de resistência de falta.

A4 - Neste passo inicia-se o primeiro processo iterativo, percorrendo cada área monitorada. A variável *ÁREA X*, com valor inicial 1, se refere a cada uma das áreas que terão seus casos com falta simulados, sendo incrementada a cada iteração para que se tenha a simulação de faltas em todas as áreas monitoradas.

A5 - Neste passo inicia-se o segundo processo iterativo, responsável por simular todos os casos com falta em cada área. A variável *CASO*, com valor inicial 0, tem seu valor incrementado a cada ciclo até atingir o valor máximo determinado no passo *A3*.

A6 - Neste passo é feita a verificação se todos os casos já foram simulados. A cada iteração, a variável *caso* é comparada com a variável *TOTAL CASOS*, a qual possui o valor de todos os casos que serão simulados para cada área monitorada. Logo, se houver igualdade entre ambas, o processo avança para o passo *A11*. Do contrário, a variável *CASO* é incrementada e o processo iterativo continua.

A7 - Neste passo são feitos sorteios aleatórios para o carregamento do sistema, a barra em que será aplicada a falta, a fase da base sorteada e a resistência de falta, respeitando seus respectivos limites e o conjunto de barras da área monitorada.

A8 - Neste passo o fluxo de potência do circuito é solucionado via OpenDSS.

A9 - Neste passo as informações referentes a todas as correntes de todos os medidores do sistema, para cada caso simulado, são armazenadas.

A10 - Neste passo o circuito criado é excluído para que não ocorra acumulação de faltas e conflitos de informações na simulação seguinte (se houver).

A11 - Neste passo, após a simulação de todos os casos com falta de cada área monitorada, os dados de corrente armazenados são exportados para planilhas do Excel para se formar a base de dados que será lida na etapa de Localização de Faltas.

A12 - Neste passo é feita a verificação se todas as áreas monitoradas tiveram seus casos simulados, comparando-se a variável *ÁREA X* com a variável *TOTAL ÁREAS* relativa a quantidade de áreas que estão sendo analisadas. Logo, se houver igualdade entre ambas, o processo avança para o passo

A14 - Do contrário, a variável *ÁREA X* é incrementada e o processo avança para o passo *A13*.

A13 - Neste passo é feito o retorno do processo para o passo *A5*, dando prosseguimento ao ciclo iterativo para que todas as áreas tenham seus casos simulados.

A14 - Neste passo são feitas simulações de casos com variação de carregamento, porém sem aplicação de falta, para que se tenha uma base de dados completa para treinamento e teste das RNAs. Vale ressaltar que esse passo também é um processo iterativo, semelhante ao apresentado para a simulação de casos com falta, mas com a diferença de que não são sorteados os parâmetros para aplicação de falta (barra, resistência e fase).

Ao final da simulação de todos os casos sem falta e a exportação dos dados, o processo finaliza.

3.2 Localização de Falhas

Nesta etapa, as RNAs são treinadas e testadas, através da base de dados construída na etapa anterior, com o objetivo de reconhecer os padrões dos valores das correntes de falta e fornecer a localização da fase defeituosa em determinada área de monitoramento.

A seguir é apresentada uma sequência de passos para o melhor entendimento da etapa de Localização de Falhas.

B1 - Neste passo é feita a leitura das planilhas que compõem a Base de Dados, de treino e teste. Dentre as informações contidas nessas bases tem-se as correntes fasoriais de todos os medidores que serão utilizadas como entrada das RNAs, como também a barra e a fase de cada falta para cada caso simulado em cada área monitorada, as quais serão utilizadas como *target* no treinamento da RNA e como comparação para o cálculo da eficiência no teste da RNA.

B2 - Neste passo são calculadas as componentes de sequência das correntes obtidas por cada medidor, as quais servirão também como entrada das RNAs.

B3 - Neste passo são criadas as RNAs para cada fase de cada área monitorada. No processo de criação são definidos o número de neurônios na camada oculta, a função de ativação, o algoritmo de treinamento e a quantidade de conjuntos de entrada, além dos critérios de parada.

B4 - Neste passo é feito o treinamento das RNAs de cada fase de cada área monitorada. Para tal processo, utiliza-se como entrada as correntes fasoriais (módulo e ângulo) dos medidores que delimitam cada área, além do somatório das correntes de sequência zero (módulo e ângulo) de cada medidor e do somatório das correntes de sequência negativa (módulo e ângulo) de cada medidor. É importante salientar que é feita uma normalização para os dados de entrada, sendo uma para os módulos e outra para os ângulos, tal normalização transforma o menor valor em 0 e o maior em 1, e o restante assumirá valores entre 0 e 1. O treinamento é feito de forma supervisionada, tendo como alvo (*target*) a existência (ou não) da falta na respectiva fase analisada pela RNA, dentro da região de monitoramento. Os alvos são tratados para que se tenham valores iguais 1 (se houver falta na fase analisada) ou 0 (se não houver falta na fase analisada).

B5 - Neste passo é feito o teste das RNAs. As informações da base de dados de testagem são utilizadas para aferir a capacidade das redes neurais em identificar, dentre os valores de corrente que estão sendo testados, os casos em que uma fase de uma área monitorada esteja com falta ou não.

B6 - Neste passo os resultados relacionados ao teste das RNAs são exibidos e classificados da seguinte forma:

- a) Verdadeiros Positivos (VP): resposta que indica que há falta na fase monitorada e de fato existe.

- b) Verdadeiros Negativos (VN): resposta que indica que não há falta na fase monitorada e de fato não existe.
- c) Falsos Positivos (FP): resposta que indica que há falta na fase monitorada, mas não existe.
- d) Falsos Negativos (FN): resposta que indica que não há falta na fase monitorada, mas existe.

Considerando $Casos_{falta}$ como a quantidade de casos simulados com falta na fase associada a cada RNA e a variável $Casos_{sem\ falta}$ como a quantidade de casos simulados sem falta na fase associada a cada RNA, a eficiência de rede neural pode ser obtida por (1):

$$E_f(\%) = \left(\frac{VP + VN}{Casos_{falta} + Casos_{sem\ falta}} \right) \times 100\% \quad (1)$$

3.3 Arquitetura das RNAs

Em relação as RNAs, utiliza-se a função sigmoideal como função de ativação e o algoritmo de retropropagação de Levenberg-Marquardt como algoritmo de treinamento. Existem três RNAs para cada área monitorada, sendo cada uma das três RNAs responsável por detectar falta em uma fase da área monitorada. A diferença entre cada RNA está no fornecimento dos dados de entrada e na determinação de seu *target*. A arquitetura de todas as RNAs é composta por uma camada de entrada que recebe os dados das correntes medidas, em coordenadas de fase e o somatório das correntes de sequência negativa e zero dos medidores que delimitam uma área, conforme apresentado na Fig. 3, uma camada oculta e uma camada de saída com um neurônio, que retorna '1' se detectar a falta e '0' se não detectar. São aplicados diferentes valores (1, 5, 10 e 25) para quantidade de neurônios na camada oculta com o objetivo de encontrar a melhor composição da rede neural. A Fig. 3 ilustra o esquemático da arquitetura da rede neural artificial implementada.

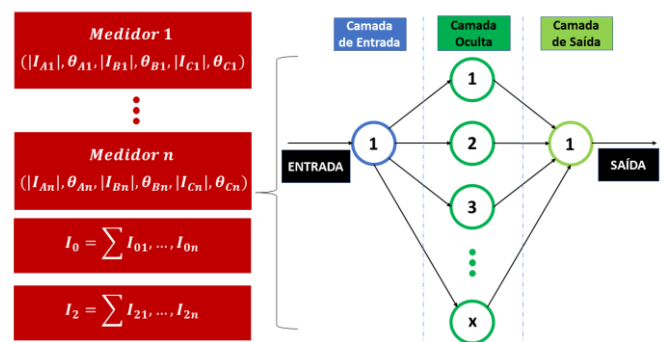


Fig.3 Arquitetura da RNA

4. RESULTADOS

Para a validação da metodologia proposta, foram realizadas simulações para 4 cenários diferentes para testar a eficiência das RNAs desenvolvidas. Os parâmetros simulados em cada cenário são apresentados na Tabela 1.

Tabela 1 – Cenários Simulados

Cenários	Resistência (Ω)	Varição de Carga
1	1 a 10	0 %
2	10 a 100	± 10 %
3	100 a 500	± 20 %
4	500 a 1000	± 20 %

4.1 Sistema Teste

Para aplicar o método proposto, o sistema IEEE 34 Node Test Feeder (IEEE, 2001) foi escolhido. A Fig. 4 ilustra o diagrama unifilar modificado deste sistema, apresentando em azul a localização dos medidores e em vermelho as barras em que foram alocadas as GDs.




Fig.4 Sistema IEEE 34 barras (IEEE, 2001).

A partir da localização dos medidores, três áreas foram definidas para monitoramento, sendo a área 1 delimitada pelos medidores inseridos entre as barras 800 e 802, e as barras 816 e 824, a área 2 é delimitada pelos medidores inseridos entre as barras 816 e 824, e as barras 858 e 834, e a área 3 é delimitada pelo medidor inserido entre as barras 858 e 834.

4.2 Resultados

A Tabela 2 apresenta os resultados de eficiências obtidas para o primeiro cenário.

Tabela 2 – Eficiências para o cenário 1

RNAs	Nº de Neurônios na Camada Oculta			
	1	5	10	25
Área - Fase				
1 – A	100,00%	100,00%	100,00%	100,00%
1 – B	100,00%	100,00%	100,00%	100,00%
1 – C	100,00%	100,00%	100,00%	100,00%
2 – A	100,00%	99,98%	99,95%	100,00%
2 – B	100,00%	99,98%	100,00%	99,98%
2 – C	99,95%	99,98%	99,98%	99,95%
3 – A	100,00%	100,00%	100,00%	100,00%
3 – B	100,00%	100,00%	100,00%	100,00%
3 – C	100,00%	100,00%	100,00%	100,00%

A Tabela 3 apresenta os resultados de eficiências obtidas para o segundo cenário.

Tabela 3 - Eficiências para o cenário 2

RNAs	Nº de Neurônios na Camada Oculta			
	1	5	10	25
Área - Fase				
1 – A	98,95%	99,70%	98,53%	98,53%
1 – B	100,00%	100,00%	99,75%	99,08%
1 – C	100,00%	99,65%	99,35%	99,23%
2 – A	91,23%	98,58%	99,78%	99,58%
2 – B	90,25%	93,73%	100,00%	100,00%
2 – C	99,18%	99,18%	100,00%	98,30%
3 – A	100,00%	100,00%	100,00%	100,00%
3 – B	100,00%	100,00%	100,00%	100,00%
3 – C	100,00%	100,00%	100,00%	100,00%

A Tabela 4 apresenta os resultados de eficiências obtidas para o terceiro cenário.

Tabela 4 - Eficiências para o cenário 3

RNAs	Nº de Neurônios na Camada Oculta			
	1	5	10	25
Área - Fase				
1 – A	94,43%	99,85%	99,90%	96,58%
1 – B	95,40%	95,00%	99,98%	99,95%
1 – C	97,00%	100,00%	99,78%	99,63%
2 – A	93,30%	91,33%	91,98%	94,25%
2 – B	94,90%	92,78%	95,28%	94,18%
2 – C	91,63%	93,70%	94,95%	98,38%
3 – A	97,23%	96,68%	96,95%	98,95%
3 – B	94,90%	95,63%	95,23%	96,20%
3 – C	95,65%	96,40%	96,05%	97,90%

A Tabela 5 apresenta os resultados de eficiências obtidas para o quarto cenário.

Tabela 5 - Eficiências para o cenário 4

RNAs	Nº de Neurônios na Camada Oculta			
	1	5	10	25
Área - Fase				
1 – A	87,78%	88,18%	87,78%	87,78%
1 – B	92,70%	92,70%	92,70%	93,90%
1 – C	94,53%	94,53%	94,53%	94,58%
2 – A	89,55%	90,03%	89,45%	89,75%
2 – B	89,45%	89,10%	89,10%	89,10%
2 – C	91,38%	91,33%	91,35%	91,80%
3 – A	91,70%	91,70%	91,70%	91,70%
3 – B	90,48%	90,48%	90,48%	90,48%
3 – C	92,83%	92,83%	92,83%	92,83%

As simulações realizadas, aplicando-se faltas monofásicas nas barras, tiveram como objetivo observar a eficácia das RNAs no processo de localização das faltas mediante a diferentes cenários.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), a FAPEMIG, a CAPES, o INERGE e à Universidade Federal de Juiz de Fora (UFJF) pelo apoio e incentivo na realização deste trabalho.

REFERÊNCIAS

A partir dos resultados obtidos, é evidente que os melhores índices de eficiência foram observados no primeiro cenário, o que era esperado, uma vez que esse cenário foi projetado principalmente para validar a metodologia proposta. Nesse cenário, foram considerados valores de resistência mais baixos e sem variação de carga, o que resultou em incrementos significativos nas correntes durante casos de falta em comparação com as operações nominais. Essa diferença acentuada nas correntes facilitou o processo de reconhecimento de padrões realizado por cada RNA.

Nos cenários em que a carga foi variada e a resistência de falta aumentada, era esperado que os resultados fossem inferiores em comparação ao cenário 1. Essas variações nos parâmetros do sistema introduziram desafios adicionais no reconhecimento de padrões pelas RNAs. Em alguns casos, os valores das correntes durante a operação nominal foram maiores do que nos casos de falta, o que dificultou a identificação das faltas com base apenas nas características das correntes. No entanto, mesmo diante dessas dificuldades, as RNAs ainda apresentaram bons resultados nos cenários 2, 3 e 4. Embora os valores de eficiência tenham sido reduzidos em comparação ao cenário 1, as RNAs demonstraram desempenho satisfatório, com as menores taxas de acerto próximas as 90%.

Por fim, é possível analisar que a quantidade de neurônios na camada oculta das redes neurais não teve grande influência nos valores de eficiência obtidos. Pelos resultados apresentados, tem-se que as eficiências obtidas em cada cenário para cada RNA foram próximas umas das outras ao se variar a quantidade de neurônios.

5. CONCLUSÕES

Este estudo apresentou uma análise de um método de detecção de faltas em alimentadores de distribuição com base em Redes Neurais Artificiais, levando em consideração a presença de geração distribuída. O método utiliza como dados de entrada medições fasoriais obtidas por PMUs, juntamente com medições de sequência, condição que durante os testes apresentou melhores resultados. Para garantir uma representação precisa dos sistemas de distribuição reais, foram simuladas falhas com diferentes valores de resistência e diferentes níveis de carga na rede, resultando em variações nas magnitudes das correntes de falta, o que dificulta o reconhecimento de padrões pelas RNAs.

A metodologia foi desenvolvida utilizando os softwares OpenDSS e Matlab, utilizando o sistema teste IEEE 34 barras modificado. Foram instalados três medidores PMUs, que delimitam três áreas de monitoramento. Os resultados obtidos em todos os cenários de simulação foram favoráveis, com uma eficiência mínima de aproximadamente 88% nos casos de falhas com altas resistências e variação de $\pm 20\%$ na carga da rede. Em resumo, os resultados obtidos são considerados positivos, validando a metodologia e alcançando os objetivos propostos, mesmo em situações de altas resistências de falta.

- Baqui I., Zamora I., Mazon J., Buigues G. (2011). High impedance fault detection methodology using wavelet transform and artificial neural networks. *Electric Power System Research*, 81(7), 1325–1333.
- Britto, T.M., Morais, D.R., Marin, M.A., Rolim, J.G., Zurn, H.H., Buendgens, R.F. (2004). Distributed generation impacts on the coordination of protection systems in distribution networks. *IEEE Latin America Trans.* 623–628.
- Cavalari, C.F., Mussi, C.O., Araujo, D.R.R.P., Araujo, L.R. (2020). Localização de Faltas de Alta Impedância em Alimentadores de Distribuição Utilizando Busca Exaustiva. *Anais Do Simpósio Brasileiro de Sistemas Elétricos 2020*.
- Ghaderi A., Ginn H.L., Mohammadpour H.A. (2017). High impedance fault detection: a review. *Electric Power System Research*, 143, 376–388.
- Gururajapathy S.S., Mokhlis H., Illias H.A. (2017). Fault location and detection techniques in power distribution systems with distributed generation: a review. *Renew Sustain Energy Rev*, 74, 949–958.
- IEEE, 2001. 34-Bus Test Feeder - Distribution Test Feeder Working Group. IEEE PES Distribution System Analysis Subcommittee.
- Ledesma, J.J.G., do Nascimento, K.B., de Araujo, L.R., Penido, D.R.R. (2020). A two-level ANN-based method using synchronized measurements to locate high-impedance fault in distribution systems. *Electric Power Systems Research*, 188, 1065–1076.
- Penido, D.R.R., de Araujo, L.R., Rodrigues, V.T.S., do Nascimento, K.B. (2022). An Analytical Zero Sequence Method to Locate Fault in Distribution Systems Rich in DG. *IEEE Transactions on Smart Grid*, 13, 1849–1859.
- Rui L., Nan P., Zhi Y., Zare F. (2018). A novel single-phase-to-earth fault location method for distribution network based on zero-sequence components distribution characteristics. *Electric Power Energy System*, 102, 11–22.
- Silva S., Costa P., Gouvea M., Lacerda A., Alves F., Leite D. (2018). High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. *Electric Power System Research*. 154, 474–483.
- Wang P.Y., Liang F.Y., Song J.Y., Guo L., Zhang J.F., Xie Y.Y., Wang S.Z. (2019). Fault current characteristics in active distribution networks with integrations of multiple PVs. *Advanced Power System Automation and Protection (APAP)*, 1403–1407, IEEE, Xi'an, China.