

# Método para a detecção e identificação de defeitos simultâneos em sistemas de distribuição utilizando redes neurais artificiais

Kelvin B. Nascimento; Débora R. R. P. Araujo; Leandro R. Araujo

*Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Brasil.*

*(e-mails: kelvin.bryan@engenharia.ufjf.br; debora.rosana@ufjf.edu.br; leandro.araujo@ufjf.edu.br)*

---

**Abstract:** This work proposes a method to detect and identify simultaneous defects in distribution systems using artificial neural networks. The simultaneous defects are featured by open-conductor presence and contact with a surface through impedance. Therefore, these faults can be divided into two categories: faults with contact from the side closest to the source and faults with contact from the side closest to the load. Each one of these categories presents their own characteristics and they are briefly commented in this work. Posteriorly, the method to detect these defects is presented and tested by IEEE 34 buses simulations. Furthermore, different types of current measurements and the number of meters are tested to determinate the best operating condition of the proposed method.

**Resumo:** Este trabalho propõe um método para detecção e identificação de defeitos simultâneos em sistemas de distribuição usando redes neurais artificiais. Os defeitos simultâneos são caracterizados pela abertura de um cabo condutor com contato a uma superfície de determinada impedância. Assim, estes defeitos podem ser divididos em duas categorias: os defeitos com contato pelo lado mais próximo à fonte e os defeitos com contato pelo lado mais próximo à carga. Cada uma das categorias das faltas apresentam características próprias que são devidamente comentadas neste trabalho. Posteriormente, o método para a detecção dos defeitos simultâneos é apresentado e testado no sistema IEEE 34 barras. Além disso, são testados diferentes tipos de medições de correntes e o número de medidores para determinação da melhor condição de operação do método proposto.

**Keywords:** Fault detection; Simultaneous defects; Distribution systems; Artificial Neural Networks; Pattern Recognition; Smart Grids.

**Palavras-chaves:** Detecção de defeitos, Defeitos simultâneos; Sistemas de distribuição; Redes neurais artificiais; Reconhecimento de padrões; Redes inteligentes.

---

## 1. INTRODUÇÃO

A proteção dos sistemas de distribuição (SDs) é uma tarefa essencial para a continuidade do serviço prestado pelas concessionárias de energia. Essas empresas são reguladas pela Agência Nacional de Energia Elétrica (ANEEL) que impõe índices que limitam o tempo e à frequência de interrupção no fornecimento de energia elétrica. Quando esses limites são violados, as empresas são multadas e, como consequência, devem ressarcir os consumidores afetados em faturas futuras. Além disso, com as interrupções no fornecimento, as concessionárias deixam de lucrar com a energia não disponível para o uso do consumidor.

Por outro lado, a ocorrência de defeitos nos SDs, muitas vezes, causam prejuízos à população, no que diz respeito à queima de equipamentos eletrodomésticos e até mesmo pelo desconforto causado pela ausência de energia. Além disso, no caso dos defeitos com cabo caído ao solo, como no caso dos defeitos simultâneos, há ainda o risco de acidentes pela população local, podendo levar à óbitos.

Sendo assim, é imprescindível que a detecção e a correção dos defeitos ocorram sempre de forma mais rápida e precisa possível. Nesse contexto, o estudo de métodos e modelos para detecção de defeitos surge com grande ênfase. Neste mesmo cenário, o conceito de *Smart Grids* revolucionou os SDs no que diz respeito às tecnologias que podem ser empregadas, visto que os problemas relacionados a essa área estão cada vez mais dinâmicos. Então, as novas tecnologias propiciaram o desenvolvimento substancial dos equipamentos de automação, permitindo pesquisas com os mais diversos tipos de tecnologias para a tarefa de detecção dos defeitos, como por exemplo as redes neurais artificiais (RNAs).

Várias técnicas podem ser utilizadas para a detecção de defeitos com contato ao solo através de impedâncias, como por exemplo, as que envolvem separações de padrões via RNAs (Zamboni et al. 2011) (Farias et al. 2018) ou as que associam as RNAs com as transformadas Wavelet (TW) que, por sua vez, são utilizadas para a realização da amostragem de sinais e extração de características de defeitos (Santos et al. 2017) (Silva et al. 2018).

Para a detecção de defeitos de abertura de condutores, pode-se utilizar técnicas voltadas à análise dos desbalanços de tensões após o defeito (Garcia-Santander et al. 2005) (Lau et al. 2017) ou também, pode-se utilizar técnicas abrangendo o uso da inteligência artificial, como as RNAs (Gilany et al. 2010) (Nareshkumar 2014).

Os defeitos simultâneos são caracterizados pela presença de contatos com o solo através de impedâncias juntamente com a presença de abertura de condutores. Então, derivações das técnicas anteriormente citadas podem ser usadas.

Sendo assim, pode-se citar a utilização das RNAs para a detecção de defeitos simultâneos (Ledesma 2016), além de técnicas voltadas para a análise dos desbalanços de tensão (Eugene 1986) (Vieira et al. 2018). Ainda, pode-se citar a classificação de defeitos baseada no ângulo das correntes de falta e com auxílio de RNAs (Oliveira et al. 2016).

Visto os principais métodos e modelos utilizados atualmente, este trabalho tem como objetivo principal propor um método baseado em RNAs para detectar defeitos simultâneos em SDs. Além disso, tem-se como objetivo secundário uma análise de características que permitam uma melhor detecção dos defeitos simultâneos no que diz respeito à abordagem do problema, ao tipo de medição e à quantidade de medidores.

## 2. CONSIDERAÇÕES INICIAIS

A seguir, os conteúdos considerados básicos para a compreensão do método proposto são brevemente descritos.

### 2.1 Defeitos simultâneos

Este trabalho trata, dentre todas as possíveis faltas que podem ocorrer nos sistemas de distribuição, dos defeitos simultâneos. Estes defeitos são caracterizados pela abertura de determinado cabo condutor de um alimentador com contato ao solo por algum dos lados, através de determinada impedância. A Fig. 1 mostra uma rede de média tensão de determinado alimentador com a possibilidade de ocorrência dos tipos de defeitos simultâneos.




Fig. 1 Defeitos simultâneos em um alimentador de um sistema de distribuição.

Primeiramente, é necessário entender que os defeitos são inerentes aos sistemas elétricos. Várias causas para os defeitos podem ser citadas, como por exemplo, a ação de chuvas, vendavais, animais, vandalismo, etc.

Os defeitos simultâneos com contato pelo lado mais próximo à subestação (DSS) são caracterizados por decréscimos de corrente proporcionais às cargas que foram desconectadas a montante do defeito com a abertura do condutor. Porém, ocorre também, um acréscimo de corrente que depende do valor da impedância de contato e do nível de tensão do sistema. Sendo assim, as correntes observadas na subestação de energia, em magnitude, na presença deste tipo de defeito, podem aumentar, diminuir ou se manterem iguais em relação à corrente observada durante condições normais de operação.

Já os defeitos simultâneos com contato pelo lado mais próximo à carga (DSC) é caracterizado por apresentar redução nas magnitudes das correntes, proporcionalmente às cargas desconectadas posteriormente ao defeito, devido à abertura de condutores. Diferentemente do DSS, não há fluxo considerável de corrente para a terra. Isso ocorre, porque o sistema de distribuição utilizado para os testes não possui GDs ou trafos abaixadores nas cargas, isto é, as cargas são diretamente conectadas na média tensão. Com isso, não há fluxo reverso de corrente que alimenta o defeito de contato.

Sendo assim, como ambos os defeitos apresentam características de correntes bem definidas, optou-se pela utilização das correntes aferidas por medidores como entrada das RNAs de detecção e identificação das faltas.

### 2.2 Redes neurais artificiais

As redes neurais artificiais consistem, basicamente, em uma formulação matemática que imita o comportamento dos neurônios biológicos. Com isso, as RNAs são treinadas para aprender padrões específicos e, posteriormente, podem realizar a separação dos mesmos padrões autonomamente. O neurônio artificial é o principal elemento que compõem as redes. A Fig. 2 ilustra um neurônio artificial.

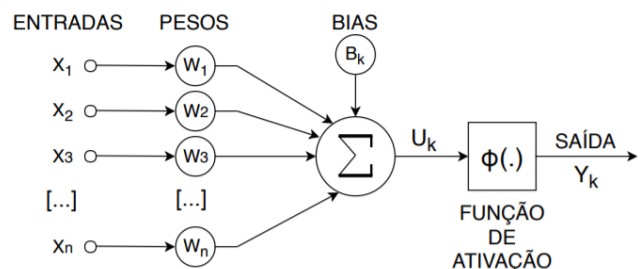


Fig. 2 Esquema de um neurônio artificial.

O fluxo de informações no neurônio artificial começa com a entrada de dados ( $X_N$ ) multiplicada pelos pesos sinápticos ( $W_N$ ) e somadas a parâmetro viés ( $B_K$ ). O resultado, então, ativa uma saída ( $Y_K$ ), através de uma determinada função definida pelo operador da rede ( $\Phi_K$ ). A operação matemática realizada por um neurônio artificial é mostrada em (1).

$$Y_K = \phi\left(\sum_{i=1}^N (X_i \times W)_i + B_K\right) \quad (1)$$

A partir do arranjo dos neurônios em camadas é possível estabelecer uma arquitetura para as RNAs, com a qual é treinada para separar os padrões selecionados. O processo de treinamento das RNAs consiste na definição dos pesos sinápticos e dos vies de cada neurônio, para fornecer saídas mais próximas possíveis às desejadas.

### 2.3 Divisão em áreas

Em algumas simulações trazidas neste trabalho optou-se por alocar mais do que um medidor no sistema. Com isso, o sistema passa a ser dividido em áreas sendo que as áreas são limitadas pelos medidores alocados. A Fig. 3 ilustra a divisão do sistema IEEE 34 barras em três áreas.




Fig. 3 Divisão do sistema IEEE 34 barras em três áreas.

Assim, o processo de detecção de defeitos deixa de ser realizado no sistema inteiro para ser dividido em cada uma das áreas criadas. Então, para cada área criada, uma rede neural é definida e treinada para detectar os defeitos internamente a própria área. Para cada uma dessas RNAs são fornecidas as informações dos medidores (correntes) que limitam a área em questão. A Fig. 4 mostra o fluxo de informações dos medidores para as áreas criadas no exemplo anterior.




Fig. 4 Conexão dos medidores alocados com as RNAs de acordo com o exemplo.

### 2.4 Sistema base

O sistema utilizado para os testes é o IEEE 34 barras, conforme ilustrado na Fig. 5.

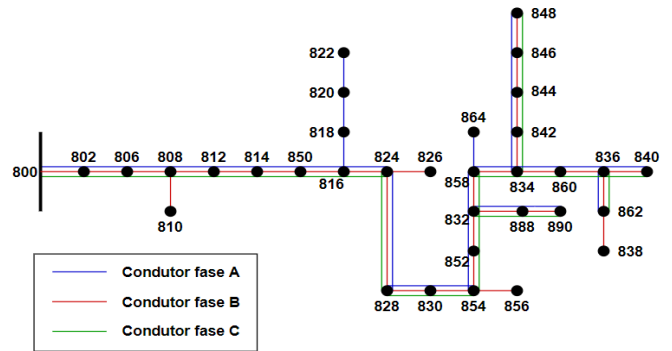


Fig. 5 Sistema IEEE 34 barras com representação das fases separadamente.

Cabe ressaltar que os defeitos podem ocorrer em quaisquer linhas que compõem o sistema, em fases sorteadas. No entanto, o sistema possui alguns ramais laterais com a presença de linhas monofásicas. Assim, para essas linhas, não há sorteio, ou seja, o defeito ocorre na única fase existente.

## 3. MÉTODO PROPOSTO

Nesta seção, o método proposto para a detecção e identificação dos defeitos é apresentado. No método, as correntes de medidores alocados no sistema são utilizadas para treinamento e funcionamento das RNAs, as quais são utilizadas para reconhecer padrões de faltas nas correntes recebidas.

### 3.1 Fluxograma base para o funcionamento do método

O fluxograma da Fig. 6 ilustra de maneira resumida o método proposto.

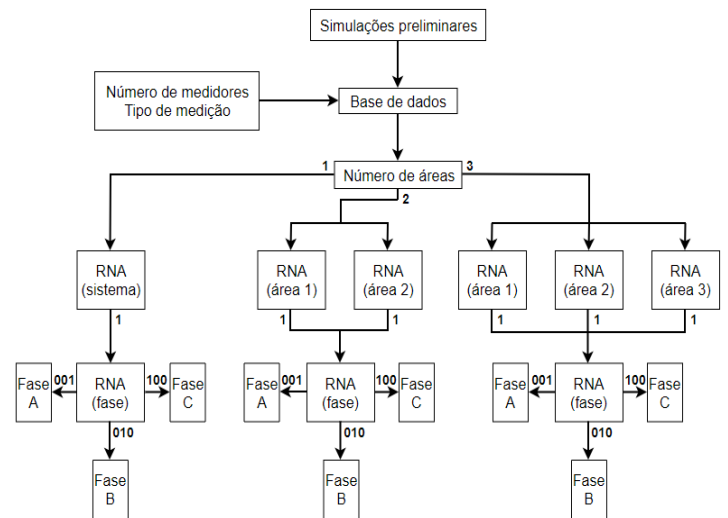


Fig. 6 Fluxograma para o método proposto neste trabalho.

Sabe-se que as RNAs devem ser primeiramente treinadas e validadas (em um único processo realizado internamente no *software* utilizado) para posterior funcionamento na tarefa de detecção ou identificação de defeitos. Dessa maneira, é necessário a criação de uma base de dados que armazena os casos operativos do SD, sob variadas condições, tais como: variações no carregamento, locais de falta diferentes, variadas impedâncias de falta, tipo de defeito (DSS e DSC), etc. Para as simulações utilizou-se uma comunicação entre os *softwares* Matlab e OpenDSS, isto é, a execução do OpenDSS é realizada dentro do Matlab.

Para este trabalho, define-se as variações de carregamento como  $\pm 50\%$ , ou seja, cada carga do sistema IEEE 34 barras é multiplicada por um número aleatório entre 0,5 e 1,5. Assim, variadas condições de carregamento são criadas, tornando o problema mais condizente com a realidade.

Além disso, as impedâncias dos defeitos foram definidas aleatoriamente entre 400 e 500 $\Omega$ . Dessa forma, pode-se inferir que os altos valores de impedância utilizados tornam o problema mais complexo, uma vez que as correntes geradas pelos defeitos podem não sensibilizar a proteção dos SDs.

Conforme já mencionado, o número de medidores alocados no sistema pode alterar o problema, ou seja, a detecção de defeito passa a ser realizada em áreas. Com isso, para cada área definida utiliza-se uma rede neural diferente para detectar defeitos simultâneos que ocorram no seu interior. As redes neurais utilizadas nas simulações possuíam apenas uma camada oculta e o número de neurônios da camada oculta varia de acordo com os tipos de simulações desenvolvidas, bem como o número de medidores conectados à rede.

As RNAs para a detecção de defeitos são treinadas para fornecer as saídas 0 e 1 em casos sem defeito e com defeito, respectivamente. Já as RNAs para identificação da fase defeituosa são treinadas para fornecerem as saídas 001, 010 e 100 para defeitos nas fases A, B e C, respectivamente. Cabe ressaltar ainda que as RNAs para identificação de defeitos somente são ativadas nos casos em que alguma das RNAs de detecção de defeitos foi ativada.

Por fim, é necessário destacar que 2000 pontos operativos distintos foram armazenados na base de dados utilizada para treinar as RNAs propostas no método, sendo que, 75% dos casos possuem defeitos simultâneos, ou seja, 1500 casos, enquanto 25% dos casos, ou 500 casos, não possuem defeitos. Esta proporção se justifica pelo fato de que os casos sem defeitos possuem menores discrepâncias entre si se comparados aos casos com defeitos, onde os locais e as fases em que foram aplicados causam grandes variações nos resultados obtidos.

### 3.2 Quantificação dos resultados

Após o processo de treinamento, as RNAs foram confrontadas com outra base de dados para quantificação dos resultados na proporção de defeitos e não defeitos iguais. Assim, a segunda base de dados possui 400 pontos operativos diferentes, sendo que, metade dos casos contém defeitos e

metade não contém. Então, quatro possíveis situações podem ocorrer na saída das RNAs de detecção de defeitos:

- A RNA indica que houve defeito quando realmente ocorreu (verdadeiro positivo ou VP).
- A RNA indica que não houve defeito quando realmente não ocorreu (verdadeiro negativo ou VN).
- A RNA indica que houve defeito quando, na verdade, não ocorreu (falso positivo ou FP).
- A RNA indica que não houve defeito quando, na verdade, ocorreu (verdadeiro negativo ou FN).

Dessa forma, a eficiência das redes neurais pode ser calculada com base em (2).

$$E_{DET}(\%) = \frac{VP + VN}{400} \times 100 \quad (2)$$

Sendo que: VP + VN é o número total de acertos da rede, dentro dos 400 dados que compõem a base de teste.

Da mesma forma, a eficiência das RNAs de identificação de defeitos pode ser calculada com base em (3).

$$E_{IDEN}(\%) = \frac{ACERTOS}{300} \times 100 \quad (3)$$

Sendo que os ACERTOS das RNAs de identificação dos defeitos são dependentes da eficiência das redes de detecção, pois as redes de identificação somente são ativadas quando alguma rede de detecção é ativada.

## 4. SIMULAÇÕES E RESULTADOS

Nesta seção, vários tipos de arranjos foram testados com relação ao número de RNAs e o tipo de entrada das mesmas. O objetivo é inferir qual topologia oferece os melhores resultados para detecção e identificação de defeitos simultâneos no sistema IEEE 34 barras.

### 4.1 Tipos de medições

Nesta subseção analisa-se o impacto do tipo de medição realizado. Para tanto, considerou-se que o sistema possuía apenas um medidor alocado na subestação de energia. Três tipos de entradas foram testadas: apenas os módulos das correntes de fase (medição não-fasorial); módulos e ângulos das correntes de fase (medição fasorial); e módulos das correntes de fase mais as razões entre as correntes de sequência zero e negativa pela corrente de sequência positiva.

Cabe ressaltar que a corrente de sequência negativa é um bom indício quanto ao desequilíbrio de correntes no sistema, devido à abertura de condutor e a corrente de sequência zero

é um bom indício quanto à corrente que caminha para a terra, devido ao contato com o solo. A corrente de sequência positiva foi utilizada para normalização das informações anteriores, mediante às variações no carregamento.

A Fig. 7 mostra o resultado para detecção e identificação dos defeitos no sistema utilizando medição não-fasorial.

### Medição não-fasorial (1 medidor)




Fig. 7 Resultados obtidos com medição não-fasorial utilizando apenas um medidor.

Já a Fig. 8 mostra o resultado para detecção e identificação dos defeitos no sistema utilizando medição fasorial.

### Medição fasorial




Fig. 8 Resultados obtidos com medição fasorial utilizando apenas um medidor.

Por fim, a Fig.9 mostra o resultado para detecção e identificação dos defeitos utilizando medição não-fasorial e as informações em coordenadas de sequência das correntes.

### Medição não-fasorial e sequências




Fig. 9 Resultados obtidos com medição não-fasorial e medições de sequência utilizando apenas um medidor.

## 4.2 Número de medidores

Nesta subseção analisa-se o impacto que a quantidade de medidores alocados no sistema produz na detecção e identificação dos defeitos por áreas. Para esta análise utilizou-se medições do tipo não-fasorial.

A Fig.10 mostra o resultado obtido quando se utilizam dois medidores no sistema: na subestação de energia e na linha 830-854.

### Medição não-fasorial (2 medidores)

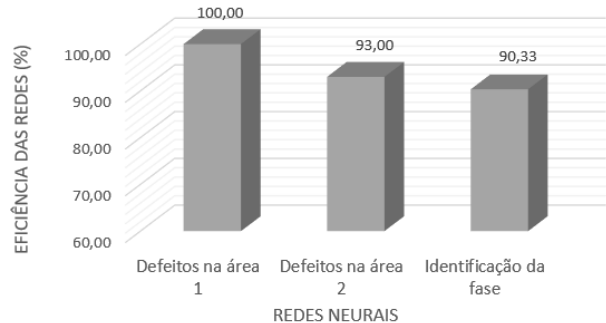


Fig. 10 Resultados obtidos com medição não-fasorial utilizando dois medidores.

Da mesma forma, a Fig. 11 mostra o resultado obtido quando se utilizam três medidores no sistema: na subestação de energia, na linha 830-854 e na linha 834-860.

### Medição não-fasorial (3 medidores)

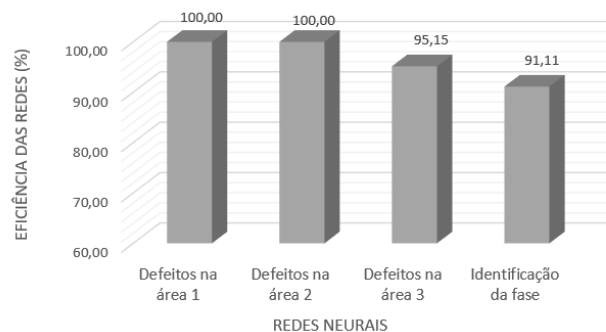


Fig. 11 Resultados obtidos com medição não-fasorial utilizando três medidores.

## 4.3 Divisão de parâmetros em duas redes neurais

Uma outra possível análise dá-se pela separação entre os DSS e DSC. Dessa forma, foram utilizadas duas redes neurais, sendo cada uma delas responsável por separar padrões relativos à cada um dos defeitos citados. A Fig. 12 mostra os resultados obtidos nesta análise.

## Medição não-fasorial (2 RNAs)




Fig. 12 Resultados obtidos com a divisão entre os defeitos.

## 5. CONCLUSÕES

Este trabalho apresenta um método para detecção e identificação de defeitos simultâneos em SDs usando RNAs. Sabe-se que os defeitos simultâneos são caracterizados pela abertura de um condutor com contato ao solo pelo lado mais próximo à geração de energia ou pelo lado mais próximo às cargas. Sendo assim, os dois tipos de defeitos simultâneos possuem características distintas as quais foram previamente analisadas.

Neste trabalho, foram utilizadas apenas medições de corrente na subestação de energia e em locais estratégicos do alimentador. Quando mais de um medidor é utilizado, o sistema é dividido em áreas, sendo que a responsabilidade pela detecção dos defeitos em cada uma das áreas é de uma RNA própria.

Nas simulações analisou-se a influência dos tipos de medidores utilizados bem como a quantidade deles para a detecção dos defeitos. Além disso, abordou-se o problema com a separação entre os defeitos pelo lado mais próximo à fonte e à carga, para constatação dos resultados obtidos.

Dentre as principais observações, cita-se que a quantidade de medidores foi o parâmetro mais influente na detecção de defeitos, com alta performance obtida nos testes. Além disso, nos testes em que se separaram os tipos de defeitos simultâneos, observou-se que os padrões relativos ao defeito mais próximo à geração são mais evidentes para o processo de classificação das redes neurais. Porém, constatou-se também, que não é vantagem a separação das RNAs para detecção de cada um dos defeitos, visto que a média entre os acertos diminui consideravelmente.

Por fim, lembra-se que neste trabalho não se realizou qualquer análise quando ao custo de aquisição e implantação dos medidores levantados. O acréscimo de uma análise de investimentos poderia ou não levar a outras soluções na detecção dos defeitos simultâneos.

## AGRADECIMENTOS

Os autores gostariam de agradecer à CNPq, CAPES, FAPEMIG, INERGE e UFJF pelo suporte dado ao desenvolvimento deste trabalho.

## REFERÊNCIAS

- Eugene, C. (1986). A new simple and effective approximate formulation for determination of three-phase unbalance by the voltmeter method. *CIGRE*.
- Farias, P. E., Morais, A. P. de, Rossini, J. P. and Cardoso, G. (2018). Non-linear high impedance fault distance estimation in power distribution systems: A continually online-trained neural network approach. *Electr. Power Syst. Res.*, vol. 157, pp. 20-28.
- Garcia-Santander, L., Bastard, P., Petit, M., Gal, I., Lopez E. and Opazo, H. (2005). Down-conductor fault detection and location via a voltage based method for radial distribution networks. *IEEE Proceedings - Generation, Transmission and Distribution*, vol. 152, no. 2, pp. 180-184.
- Gilany, M., Al-Kandari, A. and Hassan, B. (2010). ANN based technique for enhancement of distance relay performance against open-conductor in HV transmission lines. *The 2nd International Conference on Computer and Automation Engineering (ICCAE)*, Singapore, pp. 50-54.
- Lau, S. K. and Ho, S. K. (2017). Open-circuit fault detection in distribution overhead power supply network. *Journal of International Council on Electrical Engineering*, vol. 7, no. 1, pp. 269-275.
- Ledesma, J. J. G. (2016). Metodologia para Detecção, Identificação e Localização de Defeitos de Alta Impedância com a presença de Geração Distribuída. *Tese de Doutorado*. UFJF, Juiz de Fora, MG, Brasil.
- Nareshkumar, A. (2014). Series (Open conductor) fault distance location in three phase transmission line using artificial neural network. *International Journal of Scientific Research Engineering & Technology (IJSRET)*, vol. 3, no. 7, pp. 2278 – 0882.
- Nascimento, K. B., Rodrigues, V. T. S., Araujo, D. R. R. P. and Araujo, L. R. (2019). Detection of Open-Circuit Faults in Areas Among Meters in Distribution Systems Using Artificial Neural Networks. *Innovative Smart Grid Technologies*, Gramado, RS, Brasil.
- Oliveira, A. R., Garcia, P. A. N., Oliveira, L. W., Oliveira, E. J. and Silva, H. A. (2016). Fault Classification in Distribution Systems Based on Fault Current Angles. *IEEE Latin America Trans.*, vol. 14, no. 1, pp. 199-205.
- Santos, W. C., Lopes, F. V., Brito, N. S. D. and Souza, B. A. (2017). High-Impedance Fault Identification on Distribution Networks. *IEEE Trans. Power Del.*, cap. 32, no.1, pp. 23-32.
- Silva, S., Costa, P., Gouvea, M., Lacerda, A., Alves, F. and Leite, D. (2018). High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. *Electr. Power Syst. Res.*, vol. 154, pp. 474-483.
- Vieira, F. L., Filho, J. M. C., Silveira, P. M., Guerrero, C. A. V. and Leite, M. P. (2018). High impedance fault detection and location in distribution networks using smart meters. *18th International Conference on Harmonics and Quality of Power (ICHQP)*, pp. 1-6.
- Zamboni, L., Silva, I. N. da, Soares, L. N. and Fernandes, R. A. S. (2011). Fault Detection in Power Distribution Systems Using Automated Integration of Computational Intelligence Tools. *IEEE Latin America Trans.*, vol. 9, no. 4, pp. 522-527.