Detecção de Defeitos de Abertura em Sistemas de Distribuição

Kelvin B. Nascimento; Victor T. S. Rodrigues; Débora. R. R. P. Araujo; Leandro R. Araujo; Caio O. Mussi.

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

(e-mails: kelvin.bryan@engenharia.ufjf.br; victor.rodrigues@engenharia.ufjf.br; debora.rosana@ufjf.edu.br; leandro.araujo@ufjf.edu.br; caio.mussi@engenharia.ufjf.br).

Abstract: This paper proposes a method to detect open-circuit faults through areas among meters allocated in distribution systems. For this task, it is used one artificial neural network for each defined area and another neural network to detect the phase with defect. The main analysis executed in this paper refers to the influence that the type of measurement and the quantity of allocated meters perform in the effectiveness of the neural networks. The IEEE 34 buses system is used for tests.

Resumo: Este trabalho propõe um método de detecção de faltas de abertura através de áreas entre medidores alocados em sistemas de distribuição de energia. Para essa tarefa, utiliza-se uma rede neural artificial para cada área definida e outra rede neural para detecção da fase envolvida no defeito. A principal análise realizada neste trabalho diz respeito à influência que o tipo de medição e a quantidade de medidores alocados trazem na eficácia do método proposto. Para os testes, utiliza-se o sistema IEEE 34 barras.

Keywords: Artificial Neural Networks; Open-circuit faults; Distribution Systems; Pattern Recognition; Smart Grids.

Palavras-chaves: Redes neurais artificiais; Faltas de abertura; Sistemas de distribuição; Reconhecimento de padrões; Sistemas inteligentes.

1. INTRODUÇÃO

Um dos tipos de faltas mais comuns nos sistemas de distribuição (SDs) é a abertura de circuitos, o qual afeta diretamente no funcionamento dos SDs e, quanto mais distantes da subestação de energia, mais difícil se torna a detecção com medições apenas na subestação (Ledesma, 2016).

Todavia, uma das necessidades futuras para um sistema que opera de forma inteligente seria a rápida detecção de faltas. Os principais motivos para isso seriam a manutenção da continuidade do serviço pelas concessionárias e a segurança humana. No entanto, as faltas são inerentes a qualquer tipo de sistema de energia, principalmente aos sistemas de distribuição e, por isso, as pesquisas relacionadas a essa área de estudo e propostas de melhoria no desempenho da detecção de faltas tornam-se muito promissoras.

Nos SDs e, de forma geral, nos sistemas elétricos de potência (SEP), é cada vez mais evidente a evolução dos sistemas de comunicação, medição, controle e automação. Esse desenvolvimento viabiliza a utilização de técnicas inteligentes para a proteção dos sistemas elétricos, principalmente na área de detecção de defeitos. Nesse aspecto, muitas vezes a detecção de falhas é uma tarefa voltada para o reconhecimento de padrões, pois é necessário que se determine a presença ou não de falhas através de dados obtidos por meio de medições (correntes e/ou tensões).

Portanto, alguns trabalhos voltados para a detecção das faltas de abertura e outros trabalhos voltados para o uso de técnicas inteligentes na detecção de defeitos são revisados a seguir.

Em Gilany et al. (2010), uma técnica baseada na utilização de redes neurais artificiais (RNAs) é operada juntamente com um relé de distância para detectar faltas de aberturas em sistemas de transmissão de energia. O tempo de operação do esquema de proteção proposto não é muito grande porque a RNA é treinada previamente, em modo off-line. O método proposto ainda localiza a falta sem necessitar das correntes pré-falta.

Em Shu et al. (2016) é descrito um método para detectar faltas de abertura em inversores. Condições normais e em regime de falta são comparadas e processadas para absorção das características do defeito. Posteriormente, as faltas podem ser detectadas através de cálculos de autovalores das tensões linha-linha na saída do inversor. O método funciona independentemente da estratégia de controle adotada e em diferentes condições de carregamento do sistema.

Em Ledesma (2016) desenvolveu-se métodos numéricos para simulação de circuitos representando características dos sistemas de distribuição, como trafos abaixadores e circuitos de baixa tensão. Além disso, foram estudadas diversas construções de RNAs para detectar variados tipos de defeitos.

Em Liu et al. (2018) é proposto um esquema para melhorar a atuação das proteções de sobrecorrente de sequência zero,

para detecção de faltas de abertura. Além disso, em muitos esquemas de proteção, a corrente de sequência zero aferida é proporcional ao estado de carregamento do sistema. No esquema proposto, não é necessário ajustar a proteção quanto ao nível do carregamento.

Em García et al. (2014) propôs-se uma técnica de detecção de faltas em sistemas de distribuição utilizando RNAs. A detecção das faltas é realizada através da análise das componentes harmônicas das correntes aferidas, bem como as taxas de distorções harmônicas (TDH) e as componentes de sequência zero, positiva e negativa. Então, a rede neural foi utilizada para separar os casos com defeitos dos demais possíveis casos, como por exemplo, variações de carregamento.

Em Hubana et al. (2017) compara-se dois métodos para detecção de faltas em sistemas de distribuição. No primeiro utiliza-se a transformada de wavelet discreta (TWD) para decompor os sinais de tensão e RNAs para a classificação das faltas. No segundo método, utiliza-se o cálculo das diferenças entre os ângulos das tensões, calculados com o auxílio da transformada de Hilbert (TH). Em ambos os métodos, os casos analisados foram classificados em quatro grupos: faltas monofásicas, bifásicas, trifásicas e os casos sem faltas.

Em Acácio (2017) realizou-se a alocação de medidores em sistemas de distribuição para detecção e localização de faltas com o auxílio de técnicas de inteligência artificial. O método proposto consiste na utilização de algoritmos genéticos (AG) para a determinação da localização de medidores utilizados na detecção e a localização de defeitos nos sistemas de distribuição usando RNAs.

Portanto, este trabalho busca aliar o uso de métodos de inteligentes com a detecção de faltas de abertura nos sistemas de distribuição. Em linhas gerais, o objetivo desse trabalho é realizar uma análise sobre o desempenho das redes neurais variando-se a quantidade de medidores alocados no sistema, bem como o tipo de medição aferida.

2. CONSIDERAÇÕES INICIAIS

Nesta seção, alguns conceitos importantes para a compreensão do método proposto são revisados.

2.1 Defeitos de abertura em sistemas de distribuição

Os sistemas de distribuição de energia estão sujeitos a diversos tipos de faltas. O contato de uma fase energizada com o solo através de algum objeto ou o rompimento de um cabo energizado são algumas possibilidades de defeitos. Esses exemplos definem os defeitos em derivação e os defeitos de abertura, respectivamente. Cada um desses tipos de defeitos possui características que os diferem significativamente.

Neste artigo, as faltas de abertura sem contato com o solo em ambos os lados da linha são tratadas para fins de detecção destes defeitos em sistemas de distribuição. Este tipo de falta, representado na Fig. 1, é caracterizado por manter a tensão do lado da linha mais próxima à subestação em nível nominal,

enquanto a tensão do lado oposto é reduzida drasticamente (Ledesma, 2016). A corrente da fase em que ocorre a falta tende a ser nula devido ao não contato com o solo. Desta forma, observa-se certo nível de desequilíbrio nas correntes, mas que depende fortemente da localização da falta em relação ao medidor mais próximo: quanto mais próxima, maior o desequilíbrio notado.

Fig. 1 Representação esquemática de uma falta de abertura.

2.2 Estrutura das RNAs

As redes neurais artificiais são utilizadas no contexto da detecção de faltas com o intuito de serem treinadas para reconhecer e separar os casos com a presença de defeitos dos demais casos.

Portanto, para realizar esta função, as RNAs possuem determinada arquitetura, ou seja, são compostas por camadas contendo certo número de neurônios. O tamanho das camadas de entrada e de saída variam de acordo com os dados de treinamento das redes. Já as camadas intermediárias (uma ou mais) possuem o número de neurônios desejados pelo programador da rede, podendo variar de acordo com a necessidade de cada método. Um neurônio artificial é representado na Fig. 2.

Fig. 2 Representação de um neurônio artificial.

Conforme pode-se observar, a entrada do neurônio (U_k) é definida pelo somatório das entradas (X_i) associadas a pesos sinápticos (W_i) mais um fator de offset denominado bias (B_k), conforme definido em (1).

$$U_k = \left(\sum_{i=1}^n W_i \times X_i \right) + B_k \quad (1)$$

Posteriormente, a entrada calculada é utilizada para acionar uma saída (Y_K) que varia de acordo com uma função de ativação, conforme em (2).

$$Y_K = \psi(U_K) \quad (2)$$

As funções de ativação (ψ) podem possuir diversas configurações. Algumas mais comuns são: linear, sigmoidal e tangente-sigmoide.

Outra característica importante a respeito das RNAs é quanto ao algoritmo de treinamento, que ajusta os pesos sinápticos e os bias de cada neurônio. Existem vários algoritmos de treinamento diferentes, mas, neste trabalho, optou-se pela utilização do método *backpropagation*, mais precisamente o método *Levenberg-Marquardt*, mais usado em tarefas de reconhecimento de padrões.

3. MÉTODO PROPOSTO

De maneira geral, este trabalho propõe uma metodologia baseada na utilização de redes neurais artificiais para detectar faltas de abertura em áreas entre medidores nos sistemas de distribuição de energia. Além disso, a metodologia utiliza uma outra RNA para determinar a fase envolvida no defeito.

Propõe-se, também, uma análise referente à eficácia das RNAs quanto à quantidade de medidores alocados no sistema e quanto ao tipo de medição utilizado. Para tanto, o método proposto foi testado utilizando o sistema IEEE 34 barras com auxílio dos softwares OpenDSS e Matlab.

O método é constituído por três módulos independentes. O primeiro módulo é responsável pela criação de uma base de dados com informações das correntes aferidas no sistema utilizado. Já o segundo módulo é responsável por treinar e testar as RNAs criadas para detecção das áreas com defeitos. E o terceiro módulo é responsável por treinar e testar a RNA criada para detecção da fase em que a falta ocorreu.

3.1 Módulo Base de dados

Este módulo consiste na criação de bancos de dados com as correntes aferidas nas linhas do sistema IEEE 34 utilizado. Para a simulação dos casos, utilizou-se uma interface entre softwares, executando-se o OpenDSS através de linhas de comando no Matlab. O fluxograma da Fig. 3 ilustra o funcionamento deste módulo.

Para tornar as simulações mais próximas da realidade são implementados casos com e sem defeitos no sistema, com uma proporção de 50%. Considera-se também apenas defeitos monofásicos neste trabalho.

A primeira parte do processo consiste no sorteio dos casos com falta, definindo-se a linha e a fase em que o defeito será alocado. Realiza-se também, a verificação se a fase sorteada realmente existe na linha desejada, devido a presença de ramais monofásicos e bifásicos no sistema base.

Posteriormente, a comunicação entre o Matlab e o OpenDSS é estabelecida e testada por meio de comandos específicos.

Em seguida, os parâmetros das linhas, das cargas, dos transformadores e reguladores, entre outros equipamentos do sistema base, são lidos pelo Matlab para serem executados por linhas de comando.

Fig. 3 Fluxograma do módulo Base de dados.

A partir de então, o método torna-se iterativo, simulando-se cada um dos casos sorteados anteriormente que possuem características de defeitos diferentes.

Dentro do processo iterativo, antes da execução dos comandos que inserem as cargas no sistema, é realizado o processo de variação de carregamento, onde cada carga base é multiplicada por um número aleatório (entre 0.85 e 1.15). A intenção de aplicar essa variação é dificultar a execução das RNAs e ao mesmo tempo, tornar o método mais realista.

Em seguida, os demais equipamentos são também conectados no sistema pelas linhas de comando do Matlab.

Se o determinado caso que está sendo simulado possuir defeito, utiliza-se um comando para abrir a linha na fase sorteada. Posteriormente, a simulação no OpenDSS é iniciada e a solução é obtida. Com isso, as correntes que passam em todas as linhas do sistema são aferidas e salvas na base de dados.

Por fim, o circuito é limpaado, ou seja, todos os equipamentos e comandos são apagados e a simulação recomeça para o caso seguinte até o último caso. Neste trabalho foi utilizada uma base de dados contendo 5000 casos operativos.

3.2 Módulo Detecção de faltas

Este módulo é responsável por utilizar a base de dados do módulo anterior para treinar e testar cada uma das redes neurais criadas. Portanto, primeiramente define-se a quantidade de medidores utilizados, bem como em quais linhas foram alocados.

Para cada medidor alocado no sistema define-se uma área entre medidores que por sua vez define uma RNA. Para cada área, são utilizados dados dos medidores que compõe a borda dessa área. A Fig. 4 ilustra a divisão em áreas entre medidores no sistema IEEE 34 barras.

Fig. 4 Divisão em áreas entre medidores.

No exemplo, foram utilizados três medidores: M1, M2 E M3. Com isso, são definidas três áreas entre medidores. Conforme pode-se observar, os medidores M1 e M2 estão na borda da Área 1, os medidores M2 e M3 estão na borda da Área 2 e apenas o medidor M3 está na borda da Área 3. Dessa maneira, as redes neurais responsáveis pela detecção de faltas nas Áreas 1, 2 e 3 são alimentadas pelas correntes dos medidores M1-M2, M2-M3 e M3 respectivamente. Obviamente, nos casos em que se tem medição apenas na subestação, ela é responsável pela detecção de faltas no sistema inteiro.

Além disso, neste trabalho, são testados dois tipos diferentes de correntes de entrada para as redes neurais: os módulos das correntes de cada fase nas linhas determinadas e os módulos e ângulos das correntes de cada fase nas linhas determinadas. Dessa maneira, supõe-se que os tipos de medições citados são do tipo não-fasorial e fasorial, respectivamente. A Fig. 5 ilustra a construção de uma RNA para uma área com o segundo tipo de entrada citado, ou seja, entradas obtidas com medição do tipo fasorial.

Os tipos de entradas bem como a variação do número de medidores serão testados na próxima seção. Para todas as redes neurais com a função de detecção de faltas utilizou-se cinco neurônios na camada oculta.

Fig. 5 Arquitetura de uma rede neural usada com as medições fasoriais.

3.3 Módulo Detecção da fase em curto

Para este módulo todas as informações aferidas por todos os medidores alocados no sistema são utilizadas para treinamento e teste de uma rede neural artificial que detecta a fase em que a falta ocorreu. Obviamente, se houver medição somente na subestação do sistema, somente esses dados serão utilizados para a detecção da fase sob defeito. Para todas as redes neurais com a função de detecção da fase em defeito utilizou-se dez neurônios na camada oculta.

3.4 Cálculo da eficácia de uma rede

As simulações deste trabalho foram realizadas através de bancos de dados com 5000 amostras de casos operativos (2500 casos com falta e 2500 casos sem falta). Do total de amostras, 80% (4000 amostras) são usadas para treinar as redes e outros 20% (1000 amostras) são utilizadas para testar as redes.

Então, na análise das redes neurais utilizadas para detecção de defeitos no sistema ou e áreas, quanto maior o número de acertos dessas redes, dentro do total de 1000 amostras de teste, maior a sua eficácia. Como acerto define-se a rede indicar que ocorreu defeito em determinada área quando realmente houve (verdadeiro positivo) e indicar que não ocorreu defeito quando realmente não ocorreu (verdadeiro negativo).

Já para as redes neurais utilizadas na detecção da fase em que o defeito ocorreu, são computados os resultados referentes aos casos em que um defeito de fato foi aplicado no sistema, sendo descartados os resultados quando não há defeito. Isso ocorre, porque estes resultados são indiferentes se as redes de detecção de defeitos no sistema ou em áreas não acusarem nenhum defeito.

Sendo assim, a efetividade individual das RNAs utilizadas na detecção de defeitos e a efetividade individual das RNAs utilizadas na detecção da fase em que o defeito ocorreu podem ser calculadas através de (3) e (4) respectivamente.

$$E_{DD}(\%) = \frac{VP + VN}{1000} \times 100 \quad (3)$$

$$E_{DF}(\%) = \frac{ACD}{NCD} \times 100 \quad (4)$$

Em que VP são os verdadeiros positivos, VN são os verdadeiros negativos, ACD o número de acertos em casos com defeito e NCC o número total de casos com defeito.

4. RESULTADOS

Neste trabalho, utilizou-se o sistema IEEE 34 barras conforme já mencionado. O objetivo das simulações realizadas é analisar o impacto que a quantidade de medidores e que o tipo de medição produzem nos resultados das RNAs. Para cada simulação realizada, utilizou-se como resultado a média entre os desempenhos individuais de dez redes neurais diferentes. Com isso, os resultados tornam-se mais robustos e confiáveis.

Nas seções seguintes dispõe-se os casos com determinado número de medidores alocados no sistema. Quando utiliza-se mais de um medidor, o sistema é dividido em áreas. Em cada caso analisa-se os resultados das redes neurais para as medições não-fasoriais e fasoriais respectivamente. A medição não-fasorial é o tipo mais simples e mais comum nos sistemas de distribuição atuais. Já a medição fasorial representa uma tendência para o futuro dos sistemas de distribuição, pois normalmente é mais oneroso.

4.1 Caso 1: Medição apenas na subestação

Para este caso supõe-se haver medição apenas na subestação do sistema, situação mais comum no cenário atual destes sistemas. A Fig. 6 e a Fig. 7 mostram os resultados obtidos para medições do tipo não-fasorial e fasorial respectivamente.

Fig. 6 Resultados obtidos para o caso 1 com medições não-fasoriais.

Fig. 7 Resultados obtidos para o caso 1 com medições fasoriais.

4.2 Caso 2: Medição na subestação e em uma linha

Neste caso, supõe-se haver medição em dois pontos: na subestação e na linha 858-834. A Fig. 8 e a Fig. 9 mostram os resultados obtidos para medições do tipo não-fasorial e fasorial respectivamente.

Fig. 8 Resultados obtidos para o caso 2 com medições não-fasoriais.

Fig. 9 Resultados obtidos para o caso 2 com medições fasoriais.

4.3 Caso 3: Medição na subestação e em duas linhas

Para este caso supõe-se haver medição em três pontos do sistema: na subestação e nas linhas 832-858 e 860-836. A Fig. 10 e a Fig. 11 mostram os resultados obtidos para medições do tipo não-fasorial e fasorial respectivamente.

Caso 3 - Não-fasorial

Fig. 10 Resultados obtidos para o caso 3 com medições não-fasoriais.

Caso 3 - Fasorial

Fig. 11 Resultados obtidos para o caso 3 com medições não-fasoriais.

5. CONCLUSÕES

Este trabalho abordou um método para detectar faltas de abertura em áreas entre medidores e também determinar a fase sob defeito usando redes neurais artificiais.

O principal objetivo deste trabalho foi analisar o impacto que o número de medidores e o tipo de medição causam nos resultados das RNAs.

Cada resultado obtido na simulação é uma média entre o desempenho de dez redes neurais. Boa parte dos resultados são superiores a 90% em eficácia, mostrando robustez no método.

Além disso, pode-se notar, conforme esperado, que quanto mais medidores alocados, melhores são os resultados. Os resultados obtidos com a utilização de medição fasorial também são superiores aos resultados obtidos com a utilização de medição não-fasorial, conforme o esperado.

No entanto, para definir a melhor configuração de medição para o sistema, seria necessário uma análise de custos envolvendo os tipos de medidores e a quantidade deles, porque atualmente o custo de medidores fasoriais é mais alto e, assim, o custo total do esquema de proteção pode não ser vantajoso.

AGRADECIMENTOS

Os autores gostariam de agradecer a CNPq, CAPES, FAPEMIG e UFJF pelo suporte à pesquisa.

REFERÊNCIAS

- Acácio, L. C. (2017). "Alocação ótima de medidores para fins de detecção de falhas". *Dissertação de Mestrado*. Universidade Federal de Juiz de Fora, Juiz de Fora.
- García, J., García, V. and Kagan, N. (2014) "Detection of high impedance faults in overhead multi grounded networks" in: *11th IEEE/IAS International Conference on Industry Applications*, pp. 1-6. 2014.
- Gilany, M., Al-Kandari, A. and Hassan, B. (2010). "RNA 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)*, pp. 50-54, Singapore.
- Haykin, S. (2001). "Redes neurais: princípios e prática", *Bookman*, 2.ed. Porto Alegre, RS.
- Hubana, T., Saric, M. and Avdakovic, S. (2017). "Approach for identification and classification of HIFs in medium voltage distribution networks" in *IET Gener. Transm. Distrib*, 12, issue 5, pp. 1145-1152, 2017.
- 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*. Universidade Federal de Juiz de Fora, Juiz de Fora.
- Liu Y., Sun, J., Gong, G., Zhang, X. and Zhang, I. (2018). "Open-Circuit Fault in EHV/UHV Transmission System and New Zero Sequence Over-current Protection Scheme," *International Conference on Power System Technology (POWERCON)*, pp. 3093-3098, Guangzhou.
- Moreto, M. (2005) "Localização de faltas de alta impedância em sistemas de distribuição de energia: uma metodologia baseada em redes neurais artificiais", *Dissertação de Mestrado*. Universidade Federal do Rio Grande do Sul. Rio Grande do Sul.
- Nascimento, K. B., Rodrigues, V. T. S., Cavaleri C. F., Octaviano, M. E. F., Araujo, D. R. R. P. e Araujo L. R. (2018). "Avaliação da Estrutura de Saída de Redes Neurais Artificiais Utilizadas na Detecção de Faltas de Alta Impedância em Sistemas de Distribuição" *unpublished, presented at 13th IEEE/IAS International Conference on Industry Applications*, São Paulo, Brasil.
- Shu, C., Ya-Ting, C., Tian-Jian, Y. and W. Xun. (2016). "A Novel Diagnostic Technique for Open-Circuited Faults of Inverters Based on Output Line-to-Line Voltage Model". in *IEEE Transactions on Industrial Electronics*, vol. 63, no. 7, pp. 4412-4421.