

A Method for the Approximate Location of High Impedance Faults using Neural Networks

Jorge J. Gimenez L, Leandro R. Araujo, *Senior Member, IEEE*, and Débora R. R. Penido, *Senior member, IEEE*

Abstract— This paper describes an algorithm for ground to earth high-impedance fault identification and location in medium-voltage of unbalanced distribution systems. The daily variation of the load is considered, the fault resistance variation, inaccuracy in feeders data, and errors from phasor measurement units. The method is based on artificial neural networks associated with phasor measurement units to detecting the faulty area of the distribution system. Three types of neural network structures are proposed, (i) using phasor inputs, (ii) using non-phasor inputs, and (iii) using inputs to sequence components. To test the proposed method, thousands conditions of normal operation and fault operation were simulated to assemble the database. The method uses the current data obtained from meters that can be allocated at different points of the distribution system. The IEEE 123 test system is used to validate the proposed algorithm.

Index Terms— Distribution systems, fault analysis, high impedance fault, neural networks.

I. INTRODUÇÃO

A detecção identificação e localização (DIL) de faltas de alta impedância (FAI) em sistema de distribuição (SD) são umas das tarefas mais complexas no contexto da proteção de sistemas elétricos [1]-[2]. Durante tais faltas, as variações das correntes devido à falta são geralmente pequenas em relação às correntes de carga e, com isto, as FAI podem ser confundidas com as variações típicas do carregamento do SD, posto isto, os métodos convencionais de detecção não conseguem detectar corretamente FAI. Ao longo dos anos, muitos pesquisadores e engenheiros especialistas na área publicaram diversos métodos visando a solução deste problema e progressos consideráveis foram alcançados [3]-[11]. No entanto, um método suficientemente confiável, que seja capaz de detectar e localizar FAI em SD real e com uma grande eficiência, considerando os desequilíbrios do SD e as variações diárias das cargas, ainda não foi completamente desenvolvido.

Alguns anos atrás, os pesquisadores tentaram portar métodos consagrados de detecção de FAI empregados nos sistemas de transmissão (ST) para os SD. No entanto, os SD apresentam características bastante distintas aos ST.

Os ST podem ser considerados equilibrados e com pouca assimetria entre as fases e com diversos pontos de medição. Enquanto os SD apresentam característica que geram consideráveis desequilíbrios, como ramais bifásicos e monofásicos, variação constante e considerável do carregamento, além de poucos pontos de medições. Estes fatos estão sendo estudados, e os resultados das pesquisas mostraram que diferenças significativas nos resultados são bastante comuns [12]-[17].

Dentre os principais métodos publicados para a detecção e localização de faltas em SDs destacam-se os métodos baseados em impedância, transformada *wavelets*, e métodos de inteligência artificial (MIA) como as redes neurais e a lógica *fuzzy*. Além disso, são encontrados métodos fundamentados na junção dos métodos citados acima. Os métodos prioritariamente baseados em impedância procuram estimar a DIL de faltas através do cálculo da impedância entre o local dos medidores e o ponto de falta, e com posterior comparação com os valores de impedância do sistema, em condições de pré-falta e pós-falta. Nestes métodos são empregados usualmente medições de tensões e de correntes, assim como, informações de impedâncias dos alimentadores que compõe o SD. Diversos autores propuseram melhorias nestes métodos [3], [5], [8], nas quais, em linhas gerais apresentam uma considerável eficiência quando empregado em ST, quando a detecção é feita ponta a ponta, e é realizada a medição fasorial nos dois extremos da linha. Com isto, estes métodos não apresentam os mesmos resultados alcançados em ST quando utilizado em SD com poucos pontos de medições.

Os métodos fundamentados em transformadas de *wavelet* também são bastante empregados para a solução do problema DIL de faltas em SD [7]-[9]. A transformada *wavelet* decompõe os registros dos distúrbios em sinais para que os mesmos possam ser interpretados, analisados ou reutilizados. Alguns autores utilizam os sinais de pré-falta e pós-falta em conjunto com outros métodos para a DIL de faltas, normalmente são empregados com algum MIA, proporcionando bons resultados [18]-[19].

Como já citado, os MIAs são bastante utilizados para localização de faltas, especificamente as redes neurais artificiais (RNAs). Em [1] foi desenvolvido um método híbrido de detecção e localização de faltas, onde é empregado um filtro para detectar e classificar a falta e posteriormente, são utilizadas regressões vetoriais para localizar a falta. Os autores indicam que são necessárias poucas amostras para treinar a RNA, contudo diversas condições operativas não foram contempladas. Em [20] foram utilizadas as

Este trabalho foi suportado em parte pelo CNPq, FAPEMIG e CAPES.

J. J. Gimenez L, Universidade Federal da Integração Latino Americana (UNILA), Foz do Iguaçu, Paraná, Brasil (e-mail: jorge.ledesma@unila.edu.br)
L. R. Araujo, Universidade Federal de Juiz de Fora (UFJF), Juiz de Fora, Minas Gerais, Brasil (e-mail: leandro.araujo@ufjf.edu.br).
D. R. R. Penido, Universidade Federal de Juiz de Fora (UFJF), Juiz de Fora, Minas Gerais, Brasil (e-mail: debora.rosana@ufjf.edu.br).

características da impedância de falta em combinação com as RNAs para DIL de faltas. Em [10] é apresentado um método para classificação de faltas para SD usando RNAs associadas as informações de ângulos de corrente de falta. Em [11] foi proposto a utilização de uma equação polinomial de quarta ordem para modelar a tensão no ponto de falta durante a FIA. Uma RNA foi utilizada para estimar os parâmetros desconhecidos e localizar a falta. Contudo, os métodos foram testados em apenas sistemas de pequeno porte.

Desta forma, verifica-se que os MIAs provém uma solução alternativa quando comparados aos algoritmos tradicionais, fundamentados em métodos determinísticos [17]-[21]. A principal justificativa para o uso e aplicação das RNAs é a sua possibilidade de aprendizagem, assim como sua grande eficiência em identificação de padrões.

Nos últimos anos, a eficácia das medições sincronizada, em especial os *Phasor Measurement Units* (PMUs), tem sido demonstrada através do desenvolvimento de várias aplicações, que auxiliam e aprimoram o funcionamento do sistema elétrico de potência [22]. À vista disso, vários autores desenvolveram métodos de DIL de FAI que utilizam medições sincronizadas das grandezas elétricas em diferentes pontos do sistema atingindo resultados satisfatórios [23], [24].

Três estruturas de RNAs para a DIL de FAI em SD são propostas neste trabalho. Em dois tipos de estruturas são utilizadas medições sincronizadas e na última estrutura são utilizadas medições não sincronizadas. Ressalta-se que o custo associado aos equipamentos não-fasoriais são baixos e, com isto, diversas concessionárias já os possuem instalados na rede de média tensão. Desta forma, o objetivo principal do método proposto é indicar a existência de FAI e fornecer a localização aproximada da falta, sendo que, a localização da FAI é informada indicando as áreas defeituosas. Quando empregado equipamentos de baixo custo (medições apenas não-fasorial), a detecção e a localização aproximada é alcançada com uma ótima relação custo/benefício.

As principais contribuições deste trabalho são: (i) um método que representa os principais aspectos de DSs reais, importantes para a localização de HIFs, como a variação da carga e DG, a variação da resistência a falhas, a imprecisão nos dados do alimentador ou a falta de informações precisas, (ii) uma nova estrutura de rede neural que considere os componentes da fase, bem como as sequências negativa e zero, (iii) comparação de desempenho entre os diversos tipos de medição em relação a eficácia na detecção da HIFs.

II. MÉTODO PROPOSTO

O objetivo principal do método proposto neste trabalho é a DIL por área de FAI em redes de média tensão.

O desequilíbrio e a variação do carregamento em um SD afeta diretamente as correntes de operação e muitas vezes, a variação da magnitude das correntes oriundas das FAI é menor que a variação da corrente devido às alterações do carregamento do SD. Este fato, na maioria das vezes, impossibilita a detecção e a identificação de FAI por métodos tradicionais, uma vez que o sistema de proteção pode confundir a variação das correntes de carga com a variação de

correntes oriundas de uma FAI.

A. Definição da Área de Observação dos Medidores (AOM)

Neste trabalho, uma área é definida como uma porção do SD, delimitada entre dois ou mais equipamentos de chaveamento que possuam medições de corrente (CMC) ou entre um CMC e o final do alimentador. Esta área é denominada como área de observação dos medidores (AOM), como é apresentada na Fig. 1. Neste trabalho considerou-se que estes medidores podem possuir ou não medições fasoriais de corrente. O método proposto visa identificar se uma determinada AOM possui FAI.

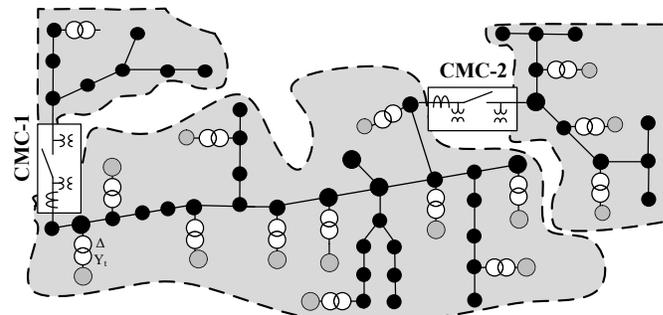


Fig. 1. Áreas entre medidores - AOM

B. Fluxograma Proposto

O fluxograma do método proposto é composto por sete módulos como apresentado na Fig. 2. Os módulos serão descritos sucintamente nas próximas subseções.

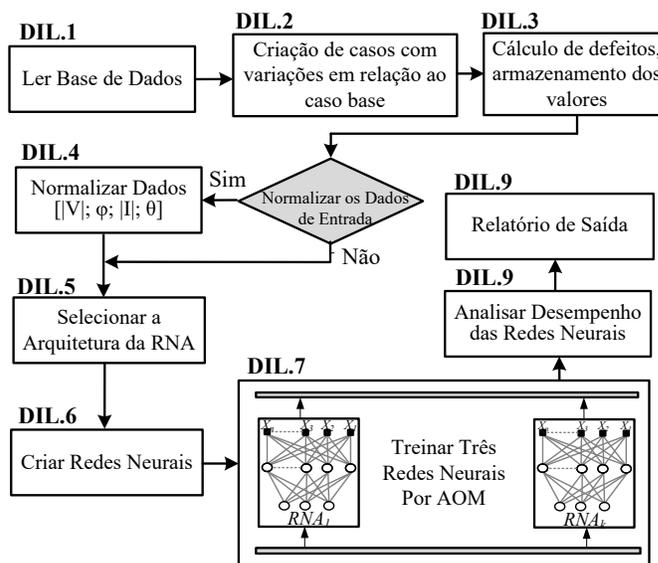


Fig. 2. Fluxograma proposto

DIL.1– Neste módulo são carregados as correntes nos medidores (CMCs) referente as operações normais e as operações em condições de falta do SD. Estes dados são simulados previamente utilizando rotinas de fluxo de potência e de cálculo de defeitos conforme apresentado em [16].

DIL.2– Durante a criação de casos para o treinamento das redes neurais diversas características típicas do SD são

considerados como os (i) desequilíbrios, (ii) os aterramentos, (iii) a variação da carga e a (iv) variação do local e do valor da impedância de falta. São simulados todos os tipos de falta com contato ao solo. Para retratar as variações do carregamento, utilizou-se uma variável aleatória k_L com distribuição uniforme. Desta forma, cada carga em cada caso é individualmente multiplicada por um valor randômico k_L , permitindo a variação individual de cada carga entre [80 120]% do valor nominal. É possível desprezar a variação das cargas ($k_L = 1$) ou desprezar completamente as cargas ($k_L = 0$). Indica-se que as representações das cargas impactam diretamente na eficiência de métodos de DIL de FAI, à vista disso, considerar cargas constantes ou desprezá-las torna a DIL de FAI um problema de fácil solução, mas as aplicações destes métodos (que não representam de forma realista as cargas) em sistemas reais implicam em uma considerável perda de acurácia. Para mitigar a perda de acurácia, os métodos devem considerar os efeitos comuns aos sistemas de distribuição, como por exemplo, a variação do carregamento e a inserção das GDs, contudo esta representação aumenta o grau de dificuldade do problema. É importante destacar que tanto a localização das faltas como os valores das impedâncias de falta variam também de forma aleatória dentro do método proposto.

DLI.3– Os casos criados no passo DLI.2 são calculados em um programa de cálculo de defeitos [13]. O objetivo deste módulo é fornecer uma quantidade razoável de amostras para o treinamento e o teste das RNAs. Cada registro na base de dados guarda as informações completas de uma condição de operação do SD. Neste trabalho a base de dados é composta de 2000 condições.

DLI.4– Neste passo é realizada a normalização dos dados da base de dados caso seja solicitada pelo usuário. Para realizar a normalização, todas as grandezas obtidas por um determinado medidor foram divididas pelo valor máximo encontrado no mesmo medidor, separando por grupo, os valores de corrente e ângulo.

DLI.5– Neste passo é definido a arquitetura e a topologia da RNA, foram utilizadas as redes *Feedforward* de camadas múltiplas com uma camada oculta. Esta arquitetura foi escolhida por ser umas das melhores arquiteturas para a resolução de problemas de reconhecimentos de padrões, como é o caso de DIL de FAI. Contudo, outros tipos de rede foram testados e resultados melhores não foram encontrados com as considerações utilizadas neste trabalho. No presente trabalho verificou-se ainda que o número ideal de neurônios da camada interna (camada interna são os responsáveis por padronizar os diferentes tipos de entradas até uma determinada saída) é altamente depende das características do SD em estudo. Sendo assim, para cada sistema ou AOM, foram realizadas várias simulações para verificar qual o número de neurônios que maximiza o desempenho da RNA. Verificou-se também que a utilização da função de ativação Logística *Sigmoidal* apresentou os melhores resultados nos sistemas testados. Para realizar o treinamento foi utilizado o método de *Levenberg-Marquardt*.

DLI.6– A RNA proposta é criada e treinada conforme

indicações anteriores. Na Fig. 3 é apresentado o diagrama estrutural e topológico das entradas e saída da RNA. Para cada AOM é criada uma RNA e são informados os valores de correntes e dos ângulos advindos dos equipamentos de medições que limitam a AOM. No caso de medições não fasoriais os valores dos ângulos das correntes são desconsiderados. Nota-se que também é informado para a RNA os somatórios das correntes de sequência zero e negativa, ressalta-se que esta informação é uma contribuição relevante e melhorou, em média, a qualidade dos resultados em 2 pontos percentuais. A saída da RNA é do tipo binário, indicando (1) se existe defeito na AOM ou (0) se não existe defeito dentro da AOM representada pela RNA.

DLI.7– Neste passo são realizados os treinamentos e os testes das RNAs de acordo com o cenário de operação do SD e o tipo de entrada indicada. Os valores informados são sempre valores eficazes (*rms*) e amostrados em determinados intervalos de tempo. Considerações entre equipamentos de medição e o sistema SCADA não fazem parte do escopo deste trabalho. Salienta-se, três tipos de estrutura de RNA foram utilizados neste trabalho e são apresentados a seguir:

- (i) **RN_DD_NF** (*entradas não-fasoriais*): As entradas desta RNA são do tipo não fasoriais, sendo baseada apenas nas informações dos módulos das corrente, amostrados pelos equipamentos de medições;
- (ii) **RN_DD_F** (*entradas fasoriais*): As entradas desta RNA são do tipo fasoriais, compostos por amostras dos módulos das correntes com seus respectivos valores de ângulo;
- (iii) **RN_DD_FS** (*entradas em componentes de sequência*): As entradas desta RNA são em componente de sequência. Desta forma, as medições de corrente são calculadas e transformadas para componentes de sequência.

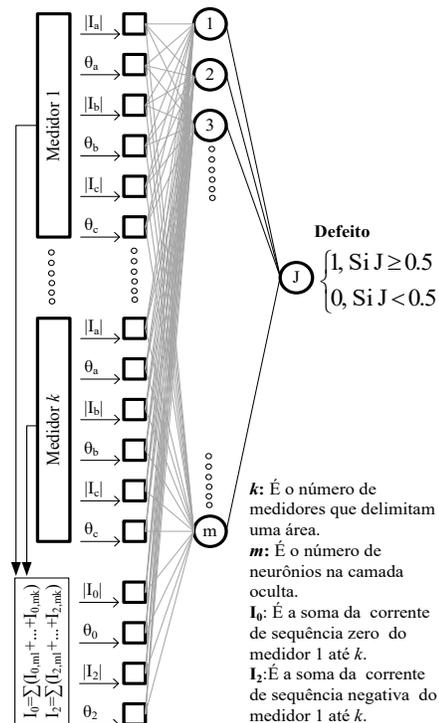


Fig. 3. Rede neural artificial proposta.

Neste ponto, dois métodos de treinamento podem ser escolhidos: (i) Para cada AOM será treinada apenas uma RNA, tendo como objetivo verificar se a área encontra-se em falta. (ii) Para cada AOM serão treinadas três RNAs por área, onde cada RNA identifica a fase defeituosa dentro da área de defeito. Estes métodos são apresentado na seção III.

DLI.8– São analisados os resultados da cada RNA. É calculada a acurácia conforme (1).

$$ACC = \frac{\sum VP + \sum VN}{\sum VP + \sum FN + \sum FP + \sum VN} \quad (1)$$

Onde:

Verdadeiro Positivo (VP): é o número de registros de previsões corretas;

Verdadeiro Negativo (VN): é o número de registros negativos que foram classificados corretamente;

Falso Positivo (FP): é a número de registros negativos que foram incorretamente classificados como positivo;

Falso Negativo (FN): é ao número de registros positivos que foram incorretamente classificados como negativo.

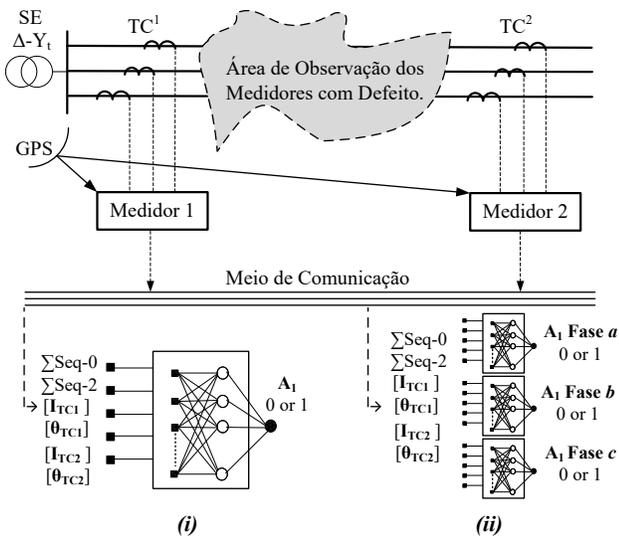


Fig. 4. Uma RNA vs Três RNAs por AOM.

DLI.9– É gerado um arquivo de saída, especificando (i) o alimentador, (ii) o tipo e a localização do defeito e (iii) a acurácia da RNA.

C. Exemplo de Aplicação das RNAs Propostas em Sistemas de Distribuição

Na Fig. 5 são apresentadas as propostas dos tipos de entrada de redes neurais; (i) *RN_DD_NF*, (ii) *RN_DD_F* e (iii) *RN_DD_FS*. É importante destacar que, as entradas das redes neurais, para cada AOM, dependem da quantidade de medidores e do tipo de medição realizada.

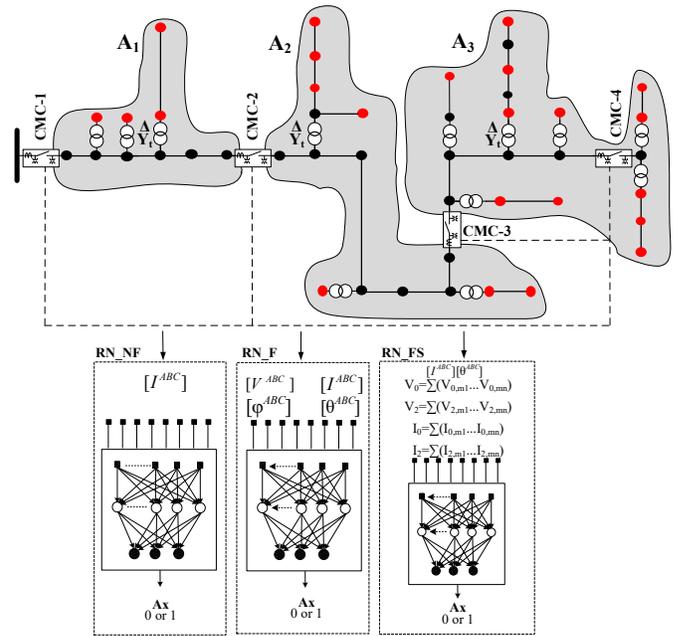


Fig. 5. Conexões e estruturas propostas para as RNAs.

III. ESTUDO DE CASOS

Para validar o método proposto foi utilizado o sistema IEEE 123 barras [25] modificado, conforme apresentado na Fig. 6. As modificações realizadas foram a inserção de transformadores de distribuição delta-estrela aterrada e as redes de baixa tensão para melhorar a representação do SD e assemelhar aos sistemas de distribuição brasileiros. Todas as cargas foram alocadas na rede de baixa tensão e foram considerados onze medidores, indicados pela letra M.

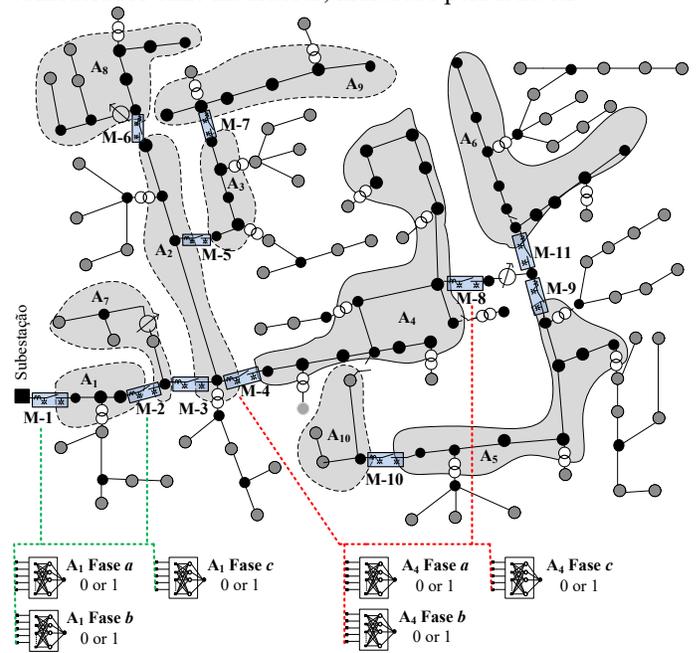


Fig. 6. IEEE 123 barras modificado

Todos os equipamentos de medição possuem unidade fasorial. Para exemplificar, na Fig. 6, Nas áreas A1 (linha verde) e A4 (linha vermelha), são apresentadas as conexões

realizadas para informar quais medidores serão considerados para informar os dados de corrente para as redes neurais de localização de defeitos. Foram utilizadas as três estruturas de RNAs por AOM em todas as simulações realizadas nesta seção.

Para verificar o desempenho da rede neural proposta foi utilizada a validação cruzada do tipo *k-folder*, onde o intervalo de divisão de dados foi 10, conforme apresentado na Fig. 7, sendo que cada teste foi repetido 10 vezes. Maiores detalhes deste método são apresentados em [26].

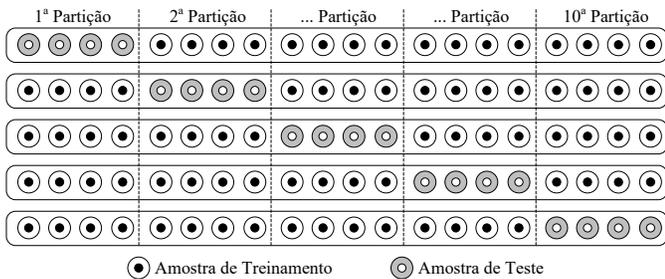


Fig. 7. Validação cruzada *k-folder*

As seguintes variações paramétricas na estrutura da RNA e nos SDs foram feitas para verificar o impacto nos resultados: (i) a variação dos números de neurônios na camada oculta, (ii) teste dos diferentes tipos de entrada da rede neural (*RN_DD_NF*, *RN_DD_F*, *RN_DD_FS*), (iii) variação aleatória no carregamento do sistema de distribuição, e (iv) as variações dos valores de impedância de falta.

Na Tabela I são apresentados os casos que foram testados e analisados nesta seção. O valor da impedância de falta não é um conceito fixo. Diversos autores indicam diferentes valores para caracterizar o que é uma FAI. Dependendo do nível tensão do sistema, do carregamento, da localização da falta e do valor das impedâncias dos alimentadores, um mesmo valor de impedância de falta pode ser considerado baixa impedância em um SD e alta impedância em outro SD. No caso em questão, foi considerado que FAI quando o valor da impedância de uma falta no meio do alimentador principal cause uma variação de corrente similar a uma variação de 10% no carregamento do sistema. No sistema estudado, o valor foi aproximadamente 120 Ω e com isto a variação 80-200 Ω foi utilizada.

TABELA I
SISTEMA IEEE 123 BARRAS -CASOS

Simulação	Impedância de Falta	Variação da Carga
1	Baixa (0-20 Ω)	Não
2	Baixa (0-20 Ω)	Sim
3	Alta (80-200 Ω)	Não
4	Alta (80-200 Ω)	Sim

Os parâmetros da base de dados criados para as simulações dos cenários propostos são apresentados na Tabela II, onde 70% dos casos foram utilizados para o treinamento e 30% para validação.

Simulação 1 - Baixa impedância

Nesta simulação, o objetivo é detectar e localizar faltas de baixa impedância com os valores das impedâncias de falta variando de 0 até 20 Ω . Ressalta-se que não é o objetivo principal deste trabalho, mas esta simulação foi utilizada para verificar o desempenho do método proposto na identificação e localização por área de falta. Para cada AOM (A₁-A₁₀) foram criadas RNAs conforme apresentado na seção II e III. Apenas alguns resultados serão apresentados por questão de espaço.

TABELA II
PARÂMETROS DAS SIMULAÇÕES DO SISTEMA IEEE 123 BARRAS

Número de defeito	2000 casos aleatórios de diferentes tipos de falta e condições normais de operação
Número de CMC	Onze unidades
Número de áreas	Dez áreas
Probabilidade de falta	80 %
Número de execuções	Cinco execuções por caso
Número de neurônios	1 a 50 neurônios na camada oculta
Impedância de falta	Definida em cada simulação
Variação da carga	Definida em cada simulação

Na Fig. 8 é apresentada a acurácia do melhor resultado correspondente a cinco execuções das três estruturas de RNA proposta: *RR_DD_NF*, *RN_DD_F* e *RD_DD_FS*. Onde, N1 indica 1 neurônio, N5 indica cinco neurônios, N15 indica quinze neurônios e assim sucessivamente na camada oculta. O valor 1,00 indica 100% de acerto.

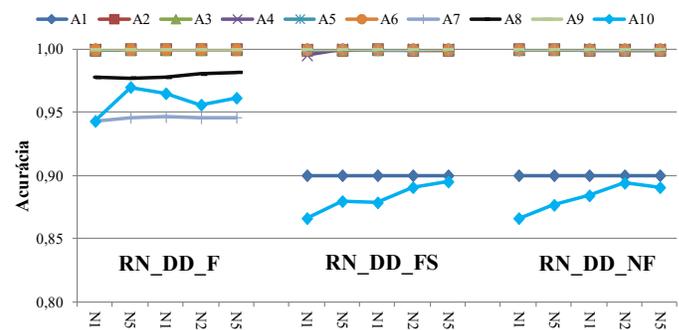


Fig. 8. Simulação de baixa impedância.

Destaca-se que a configuração *RN_DD_F* com 5 neurônios na camada oculta foi a RNA indicada para a maioria das dez áreas. A área 10 é a que se encontra mais longe da subestação, logo há uma maior impedância entre a fonte e o local da falta, e ainda, existe apenas um ponto de medição. Nota-se que esta área apresentou os piores resultados em todas as simulações e foi necessário um maior número de neurônios na camada oculta para atingir melhores resultados. Ressalta-se que utilizando medição fasorial, em todos os casos obteve-se uma acurácia maior que 94%, que é um resultado bom. As outras áreas tiveram pelo menos uma RNA com eficácia de 100%. Quando utilizada medições não fasorial, algumas AOM apresentaram um desempenho menor do que 90%, contudo a maioria das AOM apresentaram uma alta acurácia.

Simulação 2 - Baixa impedância + Variação de carga

Na simulação 2 foram realizadas as mesmas considerações da simulação 1 com a variação de carregamento do sistema na qual cada carga pode variar de forma independente e aleatória, entre 80% ($k_L=0,80$) a 120% ($k_L=1,20$) do valor base informado. O objetivo neste caso foi realizar uma simulação mais próxima da realidade.

A Fig. 9 apresenta os resultados e como era de se esperar é possível perceber que a RNA apresentou ligeiramente maior dificuldade nas identificações de faltas, uma vez que foi considerado a variação do carregamento do sistema.

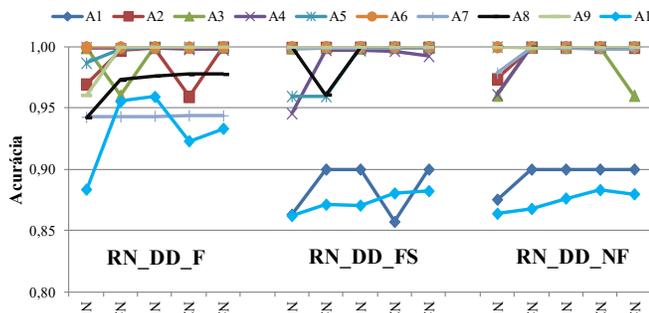


Fig. 9. Simulação de baixa impedância com variação de carga.

Na simulação 2, os melhores resultados indicam que a configuração *RN_DD_F* com 15 neurônios foi a ideal para as dez áreas, atingindo uma acurácia média considerando todas as áreas maior que 98,8%. A rede *RN_DD_F* obteve o melhor desempenho, destacando-se que esta topologia teve menores dificuldades em DIL em todas as áreas quando comparada às demais topologias, contudo a *RR_DD_NF* apresentou resultados interessantes.

Na Tabela III é apresentada qual estrutura de RNA apresentou os melhores resultados em cada simulação.

Simulação 3 - Alta impedância

A simulação 1 e a simulação 2 são consideradas por muitos pesquisadores como um problema de fácil solução. Na simulação 3 foram realizadas as mesmas considerações, porém a impedância de falta variou de 80 até 200 Ω de forma aleatória e com carga constante ($k_L=1$). Deste modo, é importante analisar que o incremento de corrente causado pela falta está na mesma ordem de grandeza das variações usuais do valor da corrente de carga, dificultando a detecção e localização da falta.

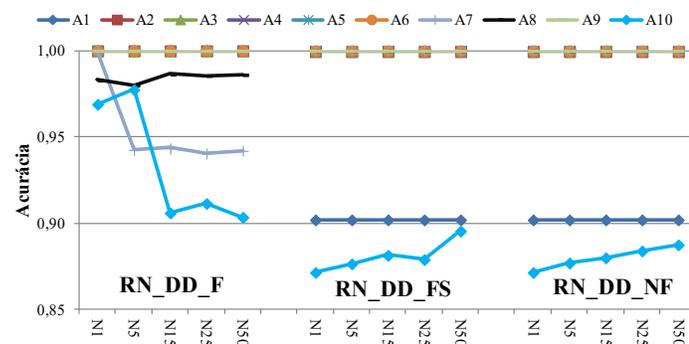


Fig. 10. Simulação de alta impedância.

No entanto, o método obteve um desempenho satisfatório. A topologia *RN_DD_F* com 1 neurônio obteve o melhor desempenho com uma acurácia média de 99%, considerando a análise de todas as áreas. A Fig. 10 apresenta de forma gráfica a acurácia.

Nota-se também, que conforme esperado, os resultados obtidos são ligeiramente piores aos resultados obtidos na simulação 1 e 2, contudo, excluído a AOM A10, sempre houve uma RNA com alta eficácia em cada área.

TABELA III
REDES NEURAIS INDICADAS – SIMULAÇÕES 1 E 2

Simul.	Impedância de Falta (Ω)	Variação da Carga	Área	RNA Indicada
1	$0 \leq Z_F \leq 20$	$k_L = 0$	A1	<i>RN_DD_F</i>
			A2	<i>RN_DD_F</i>
			A3	<i>RN_DD_NF</i>
			A4	<i>RN_DD_NF</i>
			A5	<i>RN_DD_FS</i>
			A6	<i>RN_DD_NF</i>
			A7	<i>RN_DD_NF</i>
			A8	<i>RN_DD_NF</i>
			A9	<i>RN_DD_NF</i>
			A10	<i>RN_DD_F</i>
2	$0 \leq Z_F \leq 20$	$0,8 \leq k_L \leq 1,2$	A1	<i>RN_DD_F</i>
			A2	<i>RN_DD_FS</i>
			A3	<i>RN_DD_NF</i>
			A4	<i>RN_DD_NF</i>
			A5	<i>RN_DD_NF</i>
			A6	<i>RN_DD_FS</i>
			A7	<i>RN_DD_FS</i>
			A8	<i>RN_DD_FS</i>
			A9	<i>RN_DD_NF</i>
			A10	<i>RN_DD_F</i>

Simulação 4 - Alta impedância + Variação de Carga

A simulação 4 considera a variação do carregamento do sistema, reiterando que isto é importante, pois tornar a simulação mais próxima da realidade, destacando que as cargas no sistema de distribuição variam continuamente e isto deve ser considerado em caso de defeitos de alta impedância.

Logo, o método proposto quando aplicado a este sistema e em condição de FAI com a variação da carga, apresentou resultados satisfatórios, conforme apresentado na Fig. 11.

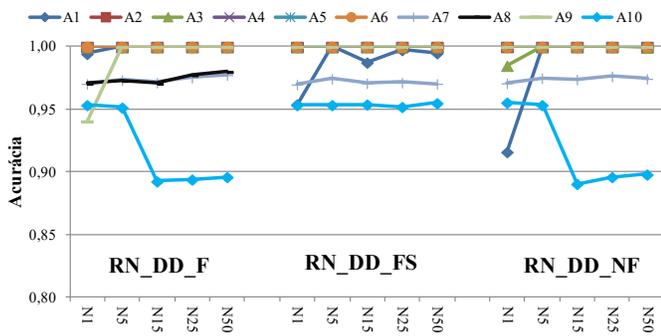


Fig. 11. Simulação de alta impedância + variação de Carga.

TABELA IV
REDES NEURAIS INDICADAS – SIMULAÇÕES 3 E 4

Simul.	Impedância de Falta (Ω)	Varição da Carga	Área	RNA Indicada
3	$80 \leq Z_F \leq 200$	$k_L = 0$	A1	RN_DD_F
			A2	RN_DD_FS
			A3	RN_DD_FS
			A4	RN_DD_FS
			A5	RN_DD_FS
			A6	RN_DD_FS
			A7	RN_DD_FS
			A8	RN_DD_FS
			A9	RN_DD_FS
			A10	RN_DD_FS
4	$80 \leq Z_F \leq 200$	$0,8 \leq k_L \leq 1,2$	A1	RN_DD_FS
			A2	RN_DD_FS
			A3	RN_DD_FS
			A4	RN_DD_FS
			A5	RN_DD_FS
			A6	RN_DD_FS
			A7	RN_DD_FS
			A8	RN_DD_FS
			A9	RN_DD_FS
			A10	RN_DD_FS

Analisando os resultados, nota-se que a topologia *RN_DD_FS* com 15 neurônios é a que apresentou melhor desempenho considerando todas as áreas, com uma acurácia média de 98%. Ressalta-se que, em todas as AOMs teve uma RNA com eficácia igual 1,00 exceto as AOMs A7 e A10. Mesmo assim pode ser considerado um bom resultado.

Nesta análise é possível perceber que (i) a topologia *RN_DD_F* teve maior dificuldade nas áreas que se encontram

no fim dos alimentadores (área 8 e área 10), (ii) o aumento do número de neurônios não influenciou fortemente nos resultados (não apresentou um padrão de comportamento), (iii) A rede *RN_DD_FS* apresentou bons resultados e com isto apresenta interessante relação custo benefício. Na Tabela IV é apresentada qual estrutura de RNA apresentou os melhores resultados para as simulações três e quatro.

IV. CONCLUSÕES

O presente artigo apresenta um método baseado em RNAs para a detecção e localização de falta de baixa e alta impedância em sistemas de distribuição, considerando a variação diária do carregamento do sistema, utilizando medições fasoriais ou não fasoriais. A detecção e localização das faltas é feita por áreas delimitadas por medidores.

As correntes de falta de alta impedância se assemelham com as variações normais das correntes operacionais do sistema. Esta particularidade faz com que a detecção e localização de faltas de alta impedância seja consideravelmente mais difícil que a detecção e localização de faltas de baixa impedância.

Os resultados obtidos demonstram que o método apresentou resultados de alta acurácia na detecção de faltas de alta impedância em sistemas de distribuição. Verificou-se que a localização da área da falta (AOM) também apresentou bons resultados. Um fato importante consiste que não existe uma topologia de rede neural ou um tipo de entrada que apresente o melhor desempenho em todos os sistemas de distribuição e AOMS. Desta forma, deve ser pesquisada qual a melhor topologia para cada AOM de cada sistemas de distribuição, pois a acurácia da topologias de RNAs (neurônios na camada oculta e tipo de entrada de dados) é dependente das características do sistemas de distribuição, assim, não é possível saber a priori qual a melhor topologia. É indicado testar todas as topologias para verificar qual é a mais adequada para cada caso.

Como pode ser notado nos resultados, em alguns casos, medições não fasoriais (mais baratas) podem apresentar resultados melhores que as medições fasoriais no método proposto. Novamente, o melhor tipo de medição só pode ser analisado realizando simulações.

Por fim, indica-se, que a grande maioria das cargas nos sistemas de distribuição bem como a geração distribuída solar são conectadas nos ramais de baixa tensão (isolado da média tensão por transformadores delta-estrela aterrada, que funciona como um filtro de sequência zero). Consumidores primários são conectados na média tensão, mas em sua grande maioria, através de transformadores do tipo delta-estrela aterrada, com isto a característica do isolamento/filtro de sequência zero da rede de média por transformadores delta-estrela aterrada se mantém. Contudo, alguns locais podem ocorrer conexões distintas, então, nesta AOM (não no alimentador inteiro) o método proposto pode não apresentar bons resultados nestes casos.

REFERÊNCIAS

- [1] H. Fathabadi, "Novel filter based ANN approach for short-circuit faults detection, classification and location in power transmission lines," *Int. J. Electr. Power Energy Syst.*, vol. 74, pp. 374–383, Jan. 2016.
- [2] A. Ghaderi, H. L. Ginn, and H. A. Mohammadpour, "High impedance fault detection: A review," *Electr. Power Syst. Res.*, vol. 143, pp. 376–388, Feb. 2017.
- [3] R. Krishnathavar and E. E. Ngu, "Generalized impedance-based fault location for distribution systems," *IEEE Trans. Power Deliv.*, vol. 27, no. 1, pp. 449–451, 2012.
- [4] S. Das, N. Karnik, and S. Santoso, "Distribution fault-locating algorithms using current only," *IEEE Trans. Power Deliv.*, vol. 27, no. 3, pp. 1144–1153, Jul. 2012.
- [5] G. D. Ferreira, D. S. Gazzana, A. S. Bretas, and A. S. Netto, "A unified impedance-based fault location method for generalized distribution systems," in *2012 IEEE Power and Energy Society General Meeting*, San Diego, CA, USA, pp. 1–8, 2012.
- [6] L. Iurinic, A.H. Orozco, R.G. Ferraz, and A. Bretas, "Distribution systems high impedance fault location: a parameter estimation approach," *IEEE Trans. Power Deliv.*, vol. 31, pp. 1806–1814, 2015.
- [7] M.-R. Mosavi and A. Tabatabaei, "Traveling-wave fault location techniques in power system based on wavelet analysis and neural network using GPS timing," *Wirel. Pers. Commun.*, vol. 86, no. 2, pp. 835–850, 2016.
- [8] J. T. A. Vianna, L. R. Araujo, and D. R. R. Penido, "High Impedance Fault Area Location in Distribution Systems Based on Current Zero Sequence Component," *IEEE Latin America Transactions*, vol. 14, pp. 759–766, 2016.
- [9] S. Silva, P. Costa, M. Gouvea, A. Lacerda, F. Alves, and D. Leite, "High impedance fault detection in power distribution systems using wavelet transform and evolving neural network," *Electr. Power Syst. Res.*, vol. 154, pp. 474–483, Jan. 2018.
- [10] A. R. Oliveira, P. A. N. Garcia, L. W. Oliveira, E. J. Oliveira, and H. A. Silva, "Fault Classification in Distribution Systems Based on Fault Current Angles," *IEEE Latin America Transactions*, vol. 14, pp. 199–205, 2016.
- [11] P. E. Farias, A. P. de Moraes, J. P. Rossini, and G. Cardoso, "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, 2018.
- [12] M. Michalik, M. Łukowicz, W. Rebizant, S.-J. Lee, and S.-H. Kang, "New ann-based algorithms for detecting hifs in multigrounded mv networks," *IEEE Trans. Power Deliv.*, vol. 23, no. 1, pp. 58–66, Jan. 2008.
- [13] D. R. R. Penido, L. R. Araujo, and M. F. Carvalho, "A fault analysis algorithm for unbalanced distribution systems," *IEEE Latin America Transactions*, vol. 13, no. 1, pp. 107–115, Jan. 2015.
- [14] J. J. G. Ledesma, L. R. Araujo, and D. R. R. Penido, "A method for evaluation of overcurrent protection in unbalanced distribution systems," *Int. Trans. Electr. Energy Syst.*, May 2015.
- [15] W. S. Gongora, A. Goedtel, S. A. O. da Silva, and C. L. Graciola, "Neural approach to fault detection in three-phase induction motors," *IEEE Lat. Am. Trans.*, vol. 14, no. 3, pp. 1279–1288, Mar. 2016.
- [16] D. R. R. Penido, L. R. Araujo, and M. F. Carvalho, "An enhanced tool for fault analysis in multiphase electrical systems," *International Journal of Electrical Power & Energy Systems*, vol. 75, pp. 215–225, 2016.
- [17] S. S. Gururajapathy, H. Mokhlis, and H. A. Illias, "Fault location and detection techniques in power distribution systems with distributed generation: A review," *Renew. Sustain. Energy Rev.*, vol. 74, pp. 949–958, Jul. 2017.
- [18] S. Gautam and S. M. Brahma, "Detection of High Impedance Fault in Power Distribution Systems Using Mathematical Morphology," *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 1226–1234, May 2013.
- [19] A. C. Adewole, R. Tzoneva, and S. Behardien, "Distribution network fault section identification and fault location using wavelet entropy and neural networks," *Appl. Soft Comput.*, vol. 46, pp. 296–306, Sep. 2016.
- [20] M. Sarlak and S. M. Shahrtash, "High impedance fault detection using combination of multi-layer perceptron neural networks based on multi-resolution morphological gradient features of current waveform," *IET Gener. Transm. Distrib.*, vol. 5, no. 5, pp. 588–595, May 2011.
- [21] L. I. Silva, E. A. Belati, and I. C. S. Junior, "Heuristic algorithm for electrical distribution systems reconfiguration based on firefly movement equation," *IEEE Lat. Am. Trans.*, vol. 14, no. 2, pp. 752–758, 2016.
- [22] T. Routtenberg, Y. Xie, R. M. Willett, and L. Tong, "PMU-Based detection of imbalance in three-phase power systems," *IEEE Trans. Power Syst.*, vol. 30, no. 4, pp. 1966–1976, Jul. 2015.
- [23] J. Ren, S. S. Venkata, and E. Sortomme, "An Accurate Synchrophasor Based Fault Location Method for Emerging Distribution Systems," *IEEE Trans. Power Deliv.*, vol. 29, no. 1, pp. 297–298, Feb. 2014.
- [24] M. Kezunovic, "Smart Fault Location for Smart Grids," *IEEE Trans. Smart Grid*, vol. 2, no. 1, pp. 11–22, Mar. 2011.
- [25] K. P. Schneider et al., "Analytic Considerations and Design Basis for the IEEE Distribution Test Feeders," *IEEE Trans. Power Syst.*, vol. 33, no. 3, pp. 3181–3188, May. 2018.
- [26] S. Haykin, *Redes Neurais - Princípios e Prática*, 2a edição. Bookman, 2001.



Jorge Javier Gimenez Ledesma possui graduação em Engenharia Eletromecânica pela Universidad Nuestra Señora de la Asunción (2009), mestrado (2012), e doutorado (2017) em Engenharia Elétrica pela Universidade Federal de Juiz de Fora Professor adjunto da Universidade Federal de Integração Latino-Americana. Atua nos seguintes temas: Análise do sistema de proteção em sistemas de distribuição e programação computacional.



Leandro Ramos de Araujo (M'2009; SM'2015) possui graduação em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (1993), mestrado em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (2000) e doutorado em Engenharia Elétrica pela Universidade Federal do Rio de Janeiro/COPPE (2005). Professor associado da Universidade Federal de Juiz de Fora. Atua nos seguintes temas: Metodologias de análise e síntese de sistemas de distribuição e industriais e programação computacional.



Debora Rosana Ribeiro Penido (S'1999; M'2009; SM'2013) possui graduação em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (2002), mestrado em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (2004) e doutorado em Engenharia Elétrica pela Universidade Federal do Rio de Janeiro/COPPE (2010). Professora associada da Universidade Federal de Juiz de Fora. Atua nos seguintes temas: Modelos de componentes, metodologias de análise de sistemas de distribuição e planejamento de sistemas de transmissão.