

# DETECÇÃO E CLASSIFICAÇÃO DE FALTAS DE CURTO-CIRCUITO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM INSERÇÃO DE GERAÇÃO DISTRIBUÍDA

ANDRÉIA S. SANTOS<sup>1</sup>, HAISLAN R.S. BERNARDES<sup>3</sup>, LUCAS TELES FARIA<sup>2</sup>, MARA L.M. LOPES<sup>1</sup>, CARLOS R. MINUSSI<sup>1</sup>

<sup>1</sup>UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Ilha Solteira  
Av. Brasil, 56, 15385-000, Ilha Solteira, São Paulo, Brasil

<sup>2</sup>UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus Experimental de Rosana  
Av. dos Barrageiros, 1881, 19274-000, Rosana, São Paulo, Brasil

<sup>3</sup>IFSP – Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Câmpus Presidente Epitácio  
Rua José Ramos Junior, 27-50, 19470-000, Presidente Epitácio, São Paulo, Brasil

E-mails: santos.faria@unesp.br, haislan@ifsp.edu.br, lucas.teles@unesp.br, mara.lopes@unesp.br, carlos.minussi@unesp.br

**Abstract**— The detection, as well as the classification of faults relative to short circuits, are of fundamental importance to lessen damages to electrical equipment and prevent faults of permanent regime or blackouts in the electricity distribution system. The insertion of distributed generation in the distribution network changes the topology of the electrical system and directly affects the short-circuit current. In this context, this study proposes an alternative procedure aimed at detecting and classifying short-circuit faults in balanced three-phase power distribution systems considering the insertion of distributed generation. The detection is based on the behavioral indices of the three-phase short circuit currents that are extracted via the use of the Discrete Wavelet Transform and the Multi-Resolution Analysis. The classification of the short-circuit phases is performed using the ARTMAP-Fuzzy neural network. The various fault conditions were simulated in the modified IEEE-34-bus test system. The test system was represented in the ATPDraw software and the methodology for fault detection and classification was implemented in the MATLAB software. The detection and classification technique is robust. More than 98% of short circuits were correctly detected, while the classifier reached 100% assertiveness with just one training and test period with low computational effort.

**Keywords**—Electrical Energy Distribution Systems, Multi-Resolution Analysis, Neural Network *Fuzzy* ARTMAP, Short Circuit Fault Detection, Wavelet Transform.

**Resumo**— A detecção, assim como a classificação de faltas relativas a curtos-circuitos são de fundamental importância para minorar danos a equipamentos elétricos e prevenir faltas de regime permanente ou blecautes em sistemas de distribuição de energia elétrica. A inserção de geração distribuída na rede de distribuição altera a topologia do sistema elétrico e afeta diretamente a corrente de curto-circuito. Nesse contexto, neste estudo propõe-se uma metodologia alternativa para detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica trifásico equilibrado considerando a inserção de geração distribuída. A detecção baseia-se nos índices comportamentais das correntes de curto-circuito trifásicas que são extraídos via uso da Transformada *Wavelet* Discreta e da Análise de Multirresolução. A classificação das fases em curto-circuito é realizada via uso da rede neural *ARTMAP-Fuzzy*. As diversas condições de falta foram simuladas no sistema-teste IEEE-34 barras modificado. O sistema-teste foi modelado no *software* ATPDraw e a metodologia para detecção e classificação de faltas foi implementada no *software* MATLAB. A técnica para detecção e classificação é robusta. Foram detectados corretamente mais de 98% dos curtos-circuitos, enquanto o classificador atingiu 100% de assertividade com apenas uma época para as etapas de treinamento e teste da rede neural.

**Palavras-chave**—Análise Multirresolução, Detecção de Faltas de Curto-Circuito, Rede Neural *ARTMAP-Fuzzy*, Sistemas de Distribuição de Energia Elétrica, Transformada *Wavelet*

## 1. Introdução

Os Sistemas de Distribuição de Energia Elétrica (SDEE) estão continuamente sujeitos a ocorrências de faltas por diversos fatores como: descargas atmosféricas, falhas nos componentes do sistema em razão do envelhecimento e erro humano. A falta é caracterizada pelo desvio das condições operacionais nominais do sistema elétrico. Classificam-se as faltas em temporárias ou permanentes. A falta temporária ocorre em um curto período de tempo; após o qual, o sistema elétrico regressa ao estado normal de operação. A falta permanente requer que o curto-circuito seja identificado e removido para que o sistema elétrico volte a operar normalmente (Gururajapathy; Mokhlis; Illias, 2017).

A inserção da Geração Distribuída (GD) pode proporcionar inúmeros benefícios ao sistema elétrico: redução do carregamento da rede, minimização das perdas e a diversificação da matriz energética (ANEEL, 2018). No entanto, a inserção massiva de GD no SDEE altera a topologia do sistema elétrico e afeta diretamente o nível e as características da corrente de curto-circuito (El-Zonkoly, 2011).

Adicionalmente, com a aprovação da normativa Nº 482 da ANEEL (2012), a GD foi regulamentada no Brasil, o que potencializou a expansão significativa da mesma, com destaque para a geração solar fotovoltaica. Nesse contexto, é importante que sejam desenvolvidas metodologias com técnicas modernas para detecção e classificação de faltas considerando a inserção de GD no SDEE.

A detecção e a classificação de faltas de curto-circuito é tema central de várias publicações da literatura especializada. Ledesma *et al.* (2020) apresentaram um novo método para localização e identificação de Faltas de Alta Impedância (FAI) em redes de média tensão em SDEE desbalanceados. O método foi baseado em dois conjuntos de Redes Neurais Artificiais (RNAs), no qual aplicaram-se dados de unidades de medidas sincronizadas. Chaitanya e Yadav (2018) propuseram um esquema inteligente para detecção e classificação de faltas de Alta impedância (FAI) e derivação normal. Para isso, o Operador de Energia Teager (OET) e dois diferentes Sistemas de Inferência *Fuzzy* (SIF) foram introduzidos. Gururajapathy, Mokhlis e Ilias (2017) apresentaram uma revisão contendo as principais técnicas desenvolvidas ao longo dos anos para detecção e localização de faltas em SDEE. Decanini, Tonelli-Neto e Minussi (2012) propuseram uma metodologia para diagnóstico automático de faltas de curto-circuito. O processo de detecção baseia-se nos sinais de corrente medidos na subestação. As características de tensão e corrente foram extraídas por meio da Transformada *Wavelet* Discreta (TWD) e AMR, o sinal foi decomposto em três níveis de resolução. A rede neural ARTMAP-*Fuzzy* foi introduzida para classificar as fases envolvidas na falta. El-Zonkoly (2011) propôs um esquema baseado em multiagentes para detecção, classificação e localização de faltas em SDEE com a introdução de geradores distribuídos. Oleskovicz *et al.* (2009) desenvolveram um sistema híbrido para detectar, classificar e localizar distúrbios que afetam a qualidade de energia. A TW foi aplicada para detectar e localizar o horário da ocorrência, enquanto no processo de classificação dos distúrbios, avaliou-se a eficiência de duas redes neurais: *Perceptron* Multicamadas (PMC) e Função de Base Radial (RBF).

Neste trabalho, apresenta-se uma metodologia alternativa para detecção e classificação de faltas de curto-circuito monofásico (Figura 1), bifásico (Figura 2) e trifásico (Figura 3) em SDEE com a inserção de GD. A decomposição do sinal das correntes trifásicas medidas na saída da subestação é realizada por meio da TWD e AMR. A técnica para detecção baseia-se nas energias normalizadas do terceiro nível de resolução dos coeficientes de detalhe, enquanto a classificação das fases envolvidas é realizada por meio da Rede Neural ARTMAP-*Fuzzy*.

Este estudo segue na Seção 2 com a descrição da estratégia para a detecção de faltas de curto-circuito: Transformada *Wavelet* (Seção 2.1), Transformada *Wavelet* Discreta (Seção 2.2) e Análise Multirresolução (Seção 2.3). Na Seção 2.4 é apresentada a estratégia para detecção de faltas envolvendo: Decomposição do Sinal (Seção 2.4.1), Energia do Sinal (Seção 2.4.2), Normalização (Seção 2.4.3) e Detecção (Seção 2.4.4). Na Seção 2.5 apresenta-se o problema de curto-circuito com conexão à terra. Na Seção 3 apresenta-se a classificação das faltas de curto-circuito via rede neural ARTMAP *Fuzzy* (Seção 3.1) cujo treinamento é apresentado na Seção 3.1.1. Na Seção 4 são

apresentados os resultados e discussões a partir das simulações realizadas no sistema-teste IEEE-34 barras modificado (Seção 4.1). A detecção e a classificação de faltas de curto-circuito nesse sistema-teste são descritas nas Seções 4.2 e 4.3, respectivamente. Na Seção 5 são apresentadas as conclusões deste estudo.

## 2. Detecção de Faltas de Curto-Circuito

### 2.1 Transformada *Wavelet*

A Transformada *Wavelet* (TW) é uma ferramenta para análise de sinais similar à Transformada de Fourier (TF) (Daubechies, 1992). Por meio de uma função inicial denominada *Wavelet* mãe, é possível decompor o sinal em diferentes escalas e vários níveis de resolução. A TW fornece representações locais do sinal nos domínios do tempo e frequência, enquanto a TF produz uma representação global (Oleskovicz *et al.*, 2009).

### 2.2 Transformada *Wavelet* Discreta

A Transformada *Wavelet* Discreta (TWD) origina-se da discretização dos parâmetros  $a$  e  $b$ , sendo que a discretização do parâmetro de translação  $b$  está diretamente associada com a escala da *wavelet* mãe  $g(\cdot)$ . A TWD de um determinado sinal, pode ser obtida via (1) (Kim; Aggarwal, 2000).

$$TWD(m, k) = \frac{1}{\sqrt{a}} \sum_n x(n)g\left(\frac{k-b}{a}\right) \quad (1)$$

Sendo:  $g(\cdot)$  a *Wavelet* mãe;  $a$  parâmetros de escala;  $b$  parâmetro de translação e  $k$  é um número específico de amostras de um sinal de entrada.

Os parâmetros de escala e de translação são funções de um parâmetro inteiro  $m$  sendo:  $a = a_0^m$  e  $b = nb_0a_0^m$ .

### 2.3 Análise Multirresolução

A Análise Multirresolução (AMR) refere-se ao processo de decomposição do sinal em vários níveis de resolução, por meio dos quais, obtêm-se os coeficientes de detalhe e de aproximação (Mallat, 1989). As aproximações contêm os componentes de alta escala e baixa frequência do sinal produzido pelo processo de filtragem, realizado por meio do filtro passa-baixa. Os detalhes fornecem os componentes de baixa escala e altas frequências, produzidos pelo processo de filtragem do sinal por um filtro passa-alta (El-Zonkoly, 2011).

### 2.4 Metodologia para Detecção de Faltas

A detecção de faltas baseia-se na aquisição dos sinais das correntes trifásicas medidas na saída da subestação. Aplica-se a TWD e AMR utilizando o filtro de quarta ordem da família Daubechies (db4) para decomposição do sinal em três níveis de resolução.

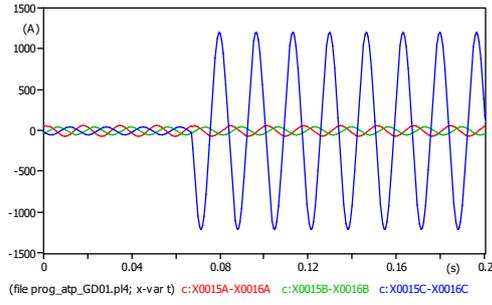


Figura 1. Curto-Circuito Monofásico.

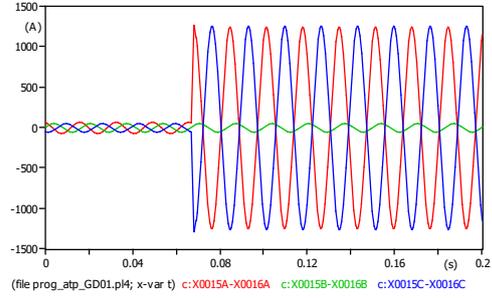


Figura 2. Curto-Circuito Bifásico.

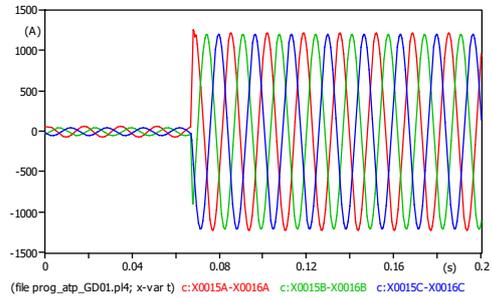


Figura 3. Curto-Circuito Trifásico.

Nesse processo, obtêm-se os coeficientes de detalhe ( $d_i^n$ ) que são aplicados no cálculo do valor da energia do sinal. O estado operativo do sistema é determinado por meio das energias normalizadas e o máximo valor dos coeficientes de detalhe do terceiro nível de resolução ( $d_{i,N_3}^n$ ).

A taxa de amostragem utilizada é de 10,8 kHz produzindo 180 amostras por ciclo. O tempo de simulação total compreende 200 ms que corresponde a 12 ciclos e 2.160 sinais de amostras. Para a análise, as amostras são separadas em 4 lotes; cada lote contém 3 ciclos e 540 sinais de amostras.

#### 2.4.1 Decomposição do Sinal

Os sinais de entrada são analisados de acordo com uma janela fixa de 540 amostras de sinais (3 ciclos) com passo de 3 ciclos. Esta janela de dados é decomposta conforme as seguintes etapas:

1. Aplica-se a Transformada *Wavelet* Discreta de sobreposição máxima (MODWT) utilizando o filtro de quarta ordem da família Daubechies (db4). Os sinais são decompostos em três níveis:  $N_1$ ,  $N_2$  e  $N_3$ ;
2. aplica-se a AMR que fornece os coeficientes de detalhe dos três níveis de resolução:  $d_1$ ,  $d_2$  e  $d_3$ .

#### 2.4.2 Energia do Sinal

Calcula-se o valor da energia dos sinais conforme o teorema de Parseval (Oppenheim; Schafer; Buck, 1998). A energia de um sinal discreto é dado por (2). São aplicados nos cálculos das energias somente os coeficientes de detalhe do terceiro nível de resolução de acordo com (3):

$$E_i = \sum_{n=1}^{N_i} |x[n]|^2 \quad (2)$$

$$E_{i,N_3} = \sum_{n=1}^{N_3} |d_{i,N_3}^n|^2 \quad (3)$$

Sendo:

$E_{i,N_3}$ : valor da energia dos coeficientes de detalhe do sinal de corrente da fase  $i$ ;

$d_{i,N_3}^n$ :  $n$ -ésima amostra do coeficiente de detalhe ou aproximação do sinal de corrente da fase  $i$  no terceiro nível de decomposição do sinal.

O vetor de energia é formado pelas energias das correntes trifásicas  $I_a$ ,  $I_b$  e  $I_c$  de acordo com (4):

$$E = [E_{aN_3} \ E_{bN_3} \ E_{cN_3}] \quad (4)$$

#### 2.4.3 Normalização

A normalização das energias dos sinais é realizada em (5).

$$\bar{E}_i = \frac{E_{iN_3}}{\sqrt{(E_{aN_3})^2 + (E_{bN_3})^2 + (E_{cN_3})^2}} \quad (5)$$

#### 2.4.4 Detecção

No processo de detecção, comparam-se as energias normalizadas e o valor máximo do coeficiente de detalhe ( $d_{iN_3}$ ) com o limite de variação estabelecido para cada fase ( $l_i$ ). O estado operativo do sistema é definido como “sistema com anomalia” se as condições em (6) forem satisfeitas; caso contrário, é definido como “sistema operando normalmente” se as condições em (7) forem satisfeitas.

$$\text{Se } \max[\bar{E}_i] > l_i \text{ e } \max|d_{iN_3}| > l_i \quad (6)$$

$$\text{Se } \max[\bar{E}_i] \leq l_i \text{ ou } \max|d_{iN_3}| \leq l_i \quad (7)$$

Sendo:

$\bar{E}_i$ : valor da energia normalizada da fase  $i$ ;

$l_i$ : limite das correntes da fase  $i$  (estabelecido pelo engenheiro de proteção);

$d_{iN_3}$ : coeficiente de detalhe do terceiro nível de resolução da fase  $i$ .

#### 2.5 Curto-Circuito com Conexão à Terra

Para curtos-circuitos bifásicos e trifásicos é preciso verificar a existência de conexão à terra. Quando o curto-circuito possui conexão com à terra,

as amplitudes das correntes atingem valores elevados quando comparado com curto-circuito sem conexão. A verificação é realizada de acordo com (Decanini; Tonelli-Neto; Minussi, 2012). Primeiramente, calcula-se a corrente total em (8).

$$I_{total} = \max(I_a) + \max(I_b) + \max(I_c) \quad (8)$$

O valor obtido é comparado com a corrente máxima estabelecida. O estado de conexão é determinado por meio de (9) e (10). Se (9) for satisfeita, então, existe um curto-circuito *sem* conexão à terra; caso contrário, se (10) for satisfeita, existe um curto-circuito *com* conexão à terra.

$$\text{Se } I_{total} < I_{max}, \text{ então, } \eta = 1 \quad (9)$$

$$\text{Se } I_{total} > I_{max}, \text{ então, } \eta = 0 \quad (10)$$

### 3. Classificação de Falhas de Curto-Circuito

O processo de classificação é ativado após o estado de falta ser confirmado pelo algoritmo de detecção. Neste processo, identificam-se as fases envolvidas no curto-circuito usando a Rede Neural ARTMAP-Fuzzy. Uma rede neural específica foi introduzida para cada tipo de curto. O padrão de entrada é composto pelo vetor de energia normalizado das correntes trifásicas que estão compreendidos no intervalo entre [0,1].

#### 3.1 Rede Neural ARTMAP-Fuzzy

A rede neural ARTMAP-Fuzzy (Carpenter *et al.*, 1992) emprega em seus operadores os cálculos dos conjuntos Fuzzy (Zadeh, 1965). Essa topologia possui um sistema de aprendizagem supervisionado e características importantes como: plasticidade e estabilidade. A plasticidade permite a inclusão de novos padrões sem destruir o conhecimento adquirido anteriormente, enquanto a estabilidade refere-se ao agrupamento de padrões similares na mesma categoria de reconhecimento que assegura a preservação do conhecimento (Carpenter; Grossberg, 1992).

A estrutura da rede é composta por dois módulos ART:  $ART_a$  e  $ART_b$  que estão conectados por meio de um terceiro módulo denominado módulo inter-ART. Quando uma previsão realizada em  $ART_a$  não é confirmada pelo módulo  $ART_b$ , o processo *match tracking* é ativado por meio da inibição da memória associativa inter-ART. O parâmetro de vigilância do módulo  $ART_a$  tem seu valor aumentado em uma quantidade mínima necessária via processo *match tracking* para que a categoria incompatível seja totalmente excluída.

O sistema iniciará uma nova busca em  $ART_a$  que levará a ativação de uma categoria que prediz corretamente a saída representada em  $ART_b$ . Esse processo permite maximizar a generalização do código e minimizar o erro preditivo (Carpenter *et al.*, 1992; Lopes; Minussi; Lotufo, 2005).

#### 3.1.1 Algoritmo de Treinamento ARTMAP-Fuzzy

O algoritmo de treinamento é apresentado de acordo com (Carpenter; Grossberg, 1992; Decanini; Tonelli-Neto; Minussi, 2012).

*Etapa 1: Dados de treinamento.* Os dados de entradas são normalizados por meio de (11) para impedir a proliferação de categorias:

$$\bar{a} = \frac{a}{|a|} \quad (11)$$

Sendo  $\bar{a}$  o vetor de entrada normalizado e  $|a| = \sum a_i$ .

Em seguida, realiza-se a codificação de complemento por meio de (12) cuja finalidade é preservar a amplitude dos dados:

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (12)$$

O vetor de entrada torna-se  $2M$ -dimensional conforme mostrado em (13):

$$I = [\bar{a} \ \bar{a}^c] = [\bar{a}_1 \dots \bar{a}_M \ \bar{a}_1^c \dots \bar{a}_M^c] \quad (13)$$

*Etapa 2: Inicialização dos pesos.* As matrizes de pesos dos módulos  $ART_a$ ,  $ART_b$  e Inter-ART são denotadas por (14), (15) e (16) respectivamente.

$$W_j^a = (W_{j1}^a, W_{j2}^a \dots W_{j,2Ma}^a) \quad (14)$$

$$W_k^b = (W_{k1}^b, W_{k2}^b \dots W_{k,2Mb}^b) \quad (15)$$

$$W_{jk}^{ab} = (W_{j1}^{ab}, W_{j2}^{ab} \dots W_{j,2Nb}^{ab}) \quad (16)$$

Inicialmente, todos os vetores possuem valores iguais a um, indicando que não existem categorias ativas.

*Etapa 3: Escolha de categorias.* A escolha de categorias dos módulos  $ART_a$  e  $ART_b$  é obtida via (17) e (18).

$$T_j^a = \frac{|I^a \wedge W_j^a|}{\alpha + |W_j^a|} \quad (17)$$

$$T_k^b = \frac{|I^b \wedge W_k^b|}{\alpha + |W_k^b|} \quad (18)$$

A escolha das categorias ativas é executada conforme (19) e (20):

$$J = \arg \{ \max T_j^a \}, \text{ para } j = 1, 2, \dots, N \quad (19)$$

$$K = \arg \{ \max T_k^b \}, \text{ para } k = 1, 2, \dots, N \quad (20)$$

Caso exista mais de uma categoria ativa, deve-se escolher aquela que possuir o menor índice.

O vetor de atividade do módulo  $ART_b$  é representado por  $Y = [Y_1^b, \dots, Y_N^b]$  e é obtido por meio de (21).

$$Y_K^b = 1 \text{ e } Y_k^b = 0 \text{ para } k \neq K \quad (21)$$

*Etapa 4: Ressonância ou Reset.* O processo de ressonância ocorrerá se (22) e (23) forem satisfeitas; caso contrário, ocorre o processo de *Reset*.

$$\frac{|I^a \wedge W_J^a|}{|I^a|} \geq \rho_a \quad (22)$$

$$\frac{|I^b \wedge W_K^b|}{|I^b|} \geq \rho_b \quad (23)$$

Quando ocorre o *reset* inicia-se a busca por uma nova categoria ativa nos módulos  $ART_a$  e  $ART_b$  usando-se (19) e (20), respectivamente. Os nós  $J$  e  $K$  são excluídos. Os valores de  $T_J^a$  e  $T_K^b$  são fixados em 0 ( $T_J^a = 0; T_K^b = 0$ ) para que sejam eliminados do processo de busca. Esse processo é repetido até que seja encontrada uma categoria que satisfaça (22) e (23).

*Etapa 5: Match-Tracking.* Esse processo é utilizado para verificar se a categoria escolhida no módulo  $ART_a$  é compatível com a saída desejada apresentada no módulo  $ART_b$ ; para isso, (24) deve ser satisfeita.

$$\frac{|Y^b \wedge W_J^{ab}|}{|Y^b|} \geq \rho_{ab} \quad (24)$$

Se o critério de vigilância for satisfeito, o processo de ressonância no módulo  $ART_a$  é confirmado e os pesos são atualizados; caso contrário, é realizado um pequeno acréscimo  $\epsilon$  em  $\rho_a$  conforme (25).

$$\rho_a = \frac{|I^a \wedge W_J^a|}{|I^a|} + \epsilon \quad (25)$$

Atribui-se  $T_J^a = 0$  e uma nova categoria deve ser encontrada no módulo  $ART_a$  por meio de (19).

Após a confirmação da categoria vencedora no módulo  $ART_a$ , via ação do dispositivo *Match-Tracking*, define-se o vetor de atividade do módulo  $ART_a$ ,  $Y = [Y_1^a, \dots, Y_N^a]$  que é obtido por meio de (26).

$$Y_j^a = 1 \text{ e } Y_j^a = 0 \text{ para } j \neq J \quad (26)$$

*Etapa 6: Aprendizado.* O aprendizado ocorre quando o critério de vigilância no módulo inter-ART é satisfeito. Os pesos são atualizados por meio de (27), (28) e (29).

$$W_J^{a(novo)} = \beta(I^a \wedge W_J^{(velho)}) + (1 - \beta)W_J^{(velho)} \quad (27)$$

$$W_K^{b(novo)} = \beta(I^b \wedge W_K^{(velho)}) + (1 - \beta)W_K^{(velho)} \quad (28)$$

$$W_{JK}^{ab(novo)} = 1 \text{ e } W_{jk}^{ab(novo)} = 0 \text{ se } j \neq J \text{ e } k \neq K \quad (29)$$

As etapas da estratégia para detecção e classificação das faltas de curto-circuito descritas nas Seções 2 e 3, respectivamente, estão resumidas na Figura 4.

## 4. Resultados e Discussões

Neste trabalho, aplica-se uma estratégia para detecção e classificação de faltas de curto-circuito com o emprego do sistema-teste IEEE-34 barras modificado com e sem a inserção de GD conforme Figuras 5 e 6, respectivamente.

O sistema foi modelado no *software* livre ATPDraw. As diversas condições de faltas foram realizadas a uma taxa de amostragem de 10,8 kHz. O algoritmo de detecção, no qual foram aplicadas as funções *modwt(.), modwtmra(.),* e o classificador de faltas foram desenvolvidos no ambiente do *software* MATLAB®.

Todas as simulações foram executadas em um computador pessoal com processador Intel Core i7; 1,8–1,99 GHz e 8 GB de memória RAM.

### 4.1 Sistema-Teste IEEE-34 Barras Modificado

O sistema-teste IEEE 34 barras (IEEE PES, 2010) é um alimentador real localizado no Estado do Arizona, EUA, com tensão nominal de 24,9 kV e 34 nós. O sistema original possui ramos trifásicos, monofásicos, cargas concentradas e cargas distribuídas desbalanceadas. Neste trabalho, considera-se o sistema composto somente por barras trifásicas e cargas concentradas devidamente equilibradas.

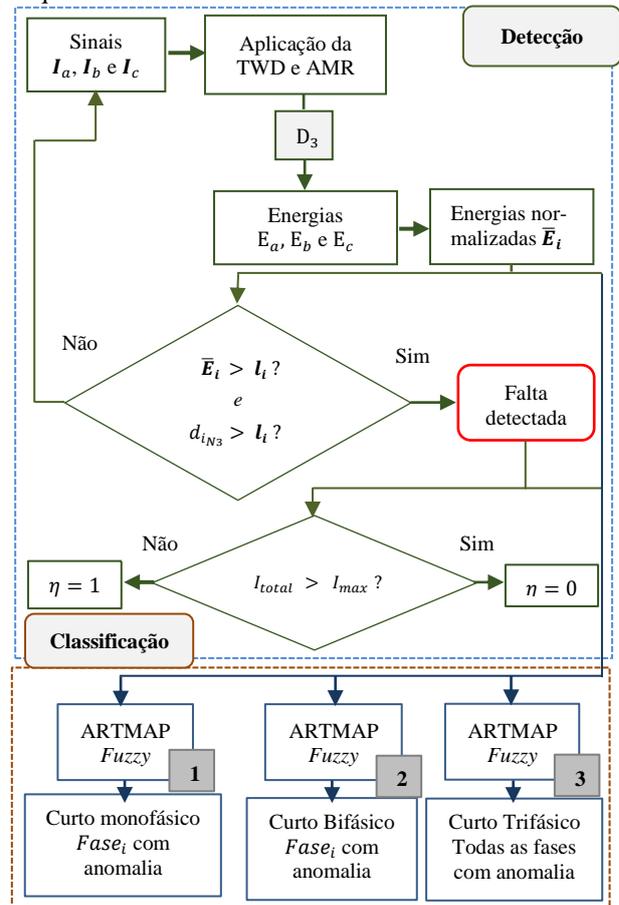


Figura 4. Fluxograma da metodologia para detecção e classificação de faltas de curto-circuito.

As cargas foram modeladas ao longo do alimentador com um modelo de impedância constante. Os religadores de tensão foram removidos.

As simulações de curto-circuito foram realizadas considerando dois cenários: no primeiro cenário, as diversas condições de faltas são simuladas no sistema IEEE-34 barras modificado sem GD conforme Figura

5. No segundo cenário, foi inserida GD a partir de dois geradores síncronos de acordo com (Motter e Vieira (2018)). Nas barras 822 e 848 foram introduzidos geradores com tensões nominais de 220V e 480 V conforme apresentado na Figura 6.

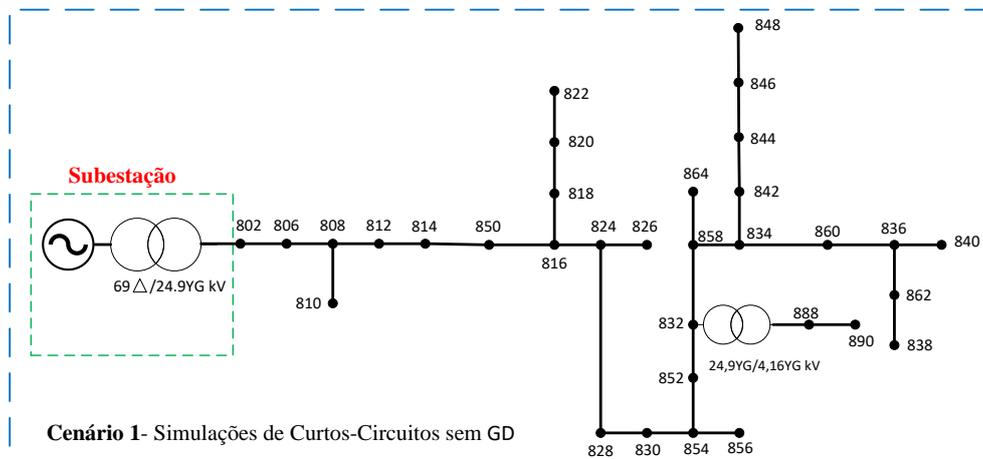


Figura 5. Sistema IEEE 34 barras modificado *sem* GD.

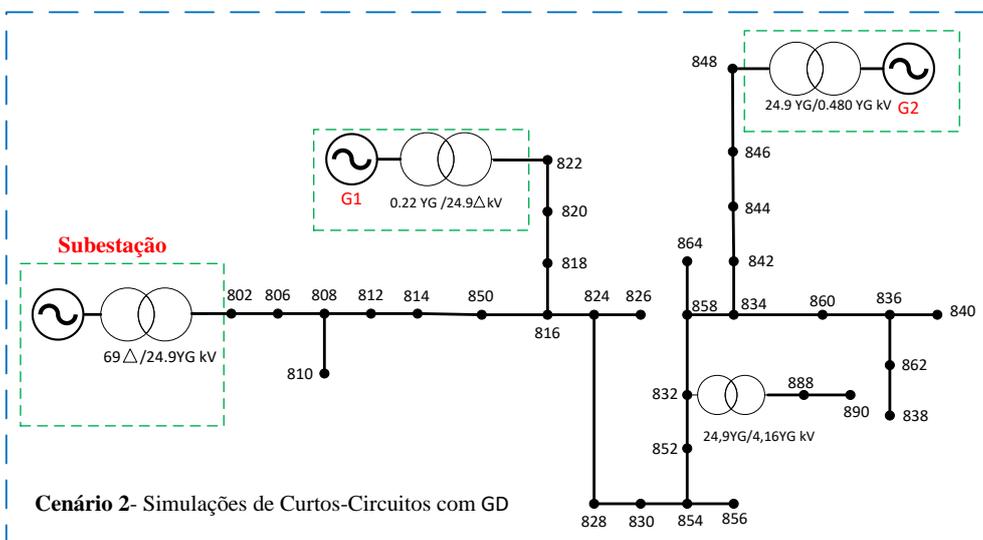


Figura 6. Sistema IEEE 34 barras modificado *com* GD.

Tabela 1. Parâmetros das simulações com o sistema-teste IEEE 34 barras modificado para os cenários 1 e 2.

Parâmetros do sistema	Cenário 1	Cenário 2
Resistência de falta ( $\Omega$ )	10, 20, 50, 70 e 100	1, 5, 10, 20, 50, 70 e 100
Ângulo de Inserção	$0^\circ$ e $90^\circ$	$0^\circ$ , $45^\circ$ e $90^\circ$
Tipos de Curtos-Circuitos	$A_g$ , $B_g$ , $C_g$ , AB, AC, BC, $AB_g$ , $AC_g$ , $BC_g$ , ABC, $ABC_g$	$A_g$ , $B_g$ , $C_g$ , AB, AC, BC, $AB_g$ , $AC_g$ , $BC_g$ , ABC, $ABC_g$
Carregamento (%)	40, 60, 80 e 100	40, 60, 80 e 100
Localização das barras em Falta	806, 810, 820, 828 e 840	806, 810, 820 e 828

Ag, Bg, Cg: Curto-circuito fase-terra. AB, BC, CA: Curto-circuito fase-fase. ABC: Curto-circuito trifásico. ABCg: Curto-circuito trifásico com terra.

Tabela 2. Limites das variações das correntes da fase  $i$ .

Parâmetro	Fase A	Fase B	Fase C
$l (\times 10^{-3})$	1 – 200	2 – 200	1 – 200



Figura 7- Resultados das simulações para detecção de faltas de curto-circuito para os cenários 1 e 2.

#### 4.2 Detecção de Faltas de Curto-Circuito para o Sistema-Teste IEEE 34 Barras Modificado

Para o cenário 1, foram geradas 660 simulações para o curto-circuito monofásico (1φ) e 600 simulações para o curto bifásico (2φ) e trifásico (3φ) totalizando 1.860 simulações. No cenário 2, foram executadas 500 simulações para cada tipo de curto, totalizando 1.500 simulações.

Os parâmetros do sistema para ambos os cenários estão apresentados na Tabela 1. As simulações foram realizadas variando a resistência de falta, carregamento, localização da falta e ângulo de inserção.

Os parâmetros adotados para detecção dos curtos-circuitos são mostrados na Tabela 2. Adota-se um limite de variação em cada fase. Por exemplo, para a Fase A, o limite inferior e superior é de  $1^{-3}$  e  $200^{-3}$ , respectivamente.

Na Figura 7 são apresentados os resultados das simulações para detecção de curtos-circuitos dos cenários 1 e 2. No cenário 1, observa-se que foram detectados corretamente 100% dos curtos-circuitos bifásicos e trifásicos, enquanto o percentual dos curtos monofásicos atingiu mais de 98% de acertos. As detecções errôneas ocorreram principalmente nas combinações de carregamento leve (40%) e resistência de falta elevada –  $100\Omega$  (falta de alta impedância). Já para o cenário 2, a metodologia apresentou resultados eficientes, embora a topologia do SDEE tenha sofrido alterações em razão da inserção de GD nas barras 822 e 848. Foram detectados corretamente 100% dos curtos-circuitos

Tabela 5. Classificação de curtos-circuitos para os cenários de simulações: cenários 1 e 2.

CENÁRIO 1					CENÁRIO 2			
Tipos de Curtos-Circuitos	Padrões de Treinamento	Padrões de Teste	Acertos %	Tempo (s)	Padrões de Treinamento	Padrões de Teste	Acertos %	Tempo (s)
$A_g$	158	70	100%	0,83	126	49	100%	0,87
$B_g$	144	58	100%	0,73	112	52	100%	0,82
$C_g$	160	70	100%	0,84	112	50	100%	0,81
$AB/AB_g$	152	48	100%	1,13	124	44	100%	0,86
$AC/AC_g$	136	64	100%	1,13	114	52	100%	0,79
$BC/BC_g$	132	68	100%	1,13	114	54	100%	0,81
$ABC/ABC_g$	420	180	100%	2,30	350	150	100%	2,40

Ag, Bg, Cg: Curto-circuito fase-terra. AB, BC, CA: Curto fase-fase. ABC: Curto-circuito trifásico. ABCg: Curto-circuito trifásico com conexão à terra.

bifásicos, enquanto o percentual dos curtos monofásicos e trifásicos atingiu mais de 98% de acertos.

#### 4.3 Classificação de Faltas de Curto-Circuito para o Sistema-Teste IEEE 34 Barras Modificado

No processo de classificação, três redes neurais ARTMAP-Fuzzy distintas são ativadas. Essas redes fornecem em seu vetor de saída as respectivas fases envolvidas no curto-circuito monofásico, bifásico e trifásico. A codificação de saída para cada tipo de curto é apresentada na Tabela 3.

Na Tabela 4 são apresentados os parâmetros adotados nas simulações de classificação de distúrbios para ambos cenários.

Na Tabela 5, tem-se os resultados obtidos na etapa de classificação. O classificador apresentou um desempenho robusto, classificando corretamente 100% dos padrões apresentados na fase de teste dos cenários 1 e 2. As três redes neurais ARTMAP-Fuzzy alcançaram os resultados em apenas uma época para as etapas de treinamento e teste.

Tabela 3. Codificação da saída da rede ARTMAP-Fuzzy.

Tipo de Curto-Circuito	Saída das Fases Envolvidas		
	Fase A	Fase B	Fase C
Sistema normal	1	1	1
Ag	0	1	1
Bg	1	0	1
Cg	1	1	0
AB	0	0	1
BC	1	0	0
CA	0	1	0
ABC	0	0	0

Ag, Bg, Cg: Curto-circuito fase-terra. AB, BC, CA: Curto fase-fase. ABC: Curto-circuito trifásico.

Tabela 4. Parâmetros da rede ARTMAP-Fuzzy para cada tipo de curto-circuito.

Param.	Cenário 1			Cenário 2		
	1φ	2φ	3φ	1φ	2φ	3φ
$\alpha$	0,1	0,1	0,1	0,1	0,1	0,1
$\beta$	1	1	1	1	1	1
$\rho_a$	0,65	0,45	0,45	0,45	0,55	0,45
$\rho_b$	0,75	0,45	0,75	0,75	0,65	0,45
$\rho_{ab}$	0,65	0,55	0,65	0,65	0,55	0,65
$\epsilon$	$10^{-5}$	$20^{-5}$	$10^{-5}$	$4^{-3}$	$10^{-5}$	$10^{-5}$

1φ: Monofásico. 2φ: Bifásico. 3φ: Trifásico. Param: Parâmetros

No Cenário 1, foram apresentados 1.860 padrões para rede neural ARTMAP-Fuzzy realizar as respectivas classificações. O processo foi dividido em duas etapas: treinamento e teste. Na fase de treinamento foram apresentados 1.302 (70% dos padrões) e 558 (30% dos padrões) foram apresentados na fase de teste. No Cenário 2, foram apresentados 1.500 padrões, sendo 1.050 para treinamento e 450 para teste. A eficiência da rede é medida de acordo com o percentual de acertos obtidos nas fases de testes para os dois cenários de simulações.

## 5 Conclusão

Neste estudo foi apresentado um procedimento alternativo para a detecção e classificação de faltas de curto-circuito em sistema de distribuição com geração distribuída. A detecção baseia-se nos sinais das correntes trifásicas medidas na saída da subestação. Na sequência, aplicam-se a MODWT e a AMR visando obter a decomposição dos sinais em três níveis de resolução. A rede neural ARTMAP-Fuzzy foi implementada com vistas à classificação do tipo de curto-circuito e o fornecimento das respectivas fases envolvidas na falta.

Conclui-se que o método proposto apresentou resultados robustos para os dois cenários adotados: com e sem GD. O acerto apurado foi superior a 98% no processo de detecção, enquanto a fase de classificação atingiu 100% de acertos com apenas uma época para as etapas de treinamento e teste da rede neural; portanto, a técnica apresenta baixo esforço computacional.

## Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de financiamento 001.

## Referências Bibliográficas

- Agência Nacional de Energia Elétrica – ANEEL (2012). Resolução Normativa Nº 482, de 17 de abril de 2012. Brasília, DF.
- Agência Nacional de Energia Elétrica – ANEEL (2018). Geração Distribuída. Disponível em: <<https://www.aneel.gov.br>>.
- Chaitanya, B. K., & Yadav, A. (2018). An intelligent fault detection and classification scheme for distribution lines integrated with distributed generators. *Computers & Electrical Engineering*, 69, 28-40.
- Carpenter, G.A.; Grossberg, S.; Markuzon, N.; Reynolds, J.H.; Rosen, D.B. (1992). Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, v. 3, p. 698-713.
- Carpenter, G.A.; Grossberg, S. (1992). A self-organizing neural network for supervised learning, recognition and prediction. *IEEE Communications Magazine*, v. 30, n. 9, p.38-49, 1992.
- Daubechies, I. (1992). Ten lectures on wavelets. Society for Industrial and Applied Mathematics, first edition.
- Decanini, J.G.M.S.; Tonelli-Neto, M.S.; Minussi, C.R. (2012). Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. *IET Generation, Transmission & Distribution*, v. 6, p. 1112-1120.
- El-Zonkoly; Amany M. (2011). Fault diagnosis in distribution networks with distributed generation. *Electric Power Systems Research*, v. 81, n. 7, p. 1482-1490.
- Gururajapathy, S.S.; Mokhlis, H.; Illias, H.A. (2017). Fault location and detection techniques in power distribution systems with distributed generation: A review. *Renewable and Sustainable Energy Reviews*, v. 74, p. 949-958.
- IEEE Power & Energy Society-PES. IEEE PES Distribution System Analysis (2010). Distribution System Analysis Subcommittee. Disponível em: <<https://site.ieee.org/pes-testfeeders/resources>>.
- Kim, C.H.; Aggarwal, R. (2000). Wavelet transforms in power systems. Part 1: General introduction to the wavelet transforms. *Power Engineering Journal*, v. 14, n. 2, p. 81-87.
- 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, 106576.
- Lopes, M.L.M.; Minussi, C.R.; Lotufo, A.D.P. (2005). Electric load forecasting using a fuzzy ART&ARTMAP neural network. *Applied soft computing*, v. 5, p. 235-244.
- Mallat, S. G. (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 11(7), 674-693.
- Motter, D.; Melo, V.J.C. (2018). The setting map methodology for adjusting the DG anti-islanding protection considering multiple events. *IEEE Transactions on Power Delivery*, v. 33, p. 2755-2764.
- Oleskovicz, M.; Coury, D.V.; Felho, O.D.; Usida, W. F.; Carneiro, A.A.; Pires, L.R. (2009). Power quality analysis applying a hybrid methodology with wavelet transforms and neural networks. *International Journal of Electrical Power & Energy Systems*, v. 31, p. 206-212.
- Oppenheim, A.V.; Schafer, R.W.; Buck, J.R. (1998) Discrete-Time Signal Processing. Prentice-Hall, Upper Saddle River, NY, USA.
- Zadeh, L.A. (1965). Fuzzy sets. *Information and Control*, v. 8, p. 338-353.