

DETECÇÃO E CLASSIFICAÇÃO DE FALTAS DE CURTO-CIRCUITO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA USANDO SISTEMAS INTELIGENTES

José G. M. S. Decanini, Mauro S. Tonelli-Neto e Carlos R. Minussi

Universidade Estadual Paulista – UNESP – Departamento de Engenharia Elétrica – Campus de Ilha Solteira
zeguilherme1@bol.com.br, maurotonelli@hotmail.com, minussi@dee.feis.unesp.br

Resumo – Neste artigo apresenta-se uma metodologia alternativa para detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica. Esta ferramenta de auxílio à tomada de decisão acelera os procedimentos para restabelecimento das condições normais de operação propiciando maior segurança, confiabilidade e lucratividade às concessionárias. O processo de detecção de anormalidade é realizado através de análises estatística e direta dos sinais de corrente no domínio *wavelet*. As evidências obtidas sobre o status da rede, considerando as faixas de frequências em avaliação, são agregadas usando a teoria da evidência, a qual fornece, aos operadores, informações quantitativas relativas ao estado operativo do sistema e ao diagnóstico executado. Na etapa de classificação, emprega-se a rede neural artificial ARTMAP *Fuzzy* para o reconhecimento dos padrões. O método proposto foi avaliado por meio de simulações de um alimentador de distribuição real, composto por 134 barras, no software ATP (*Alternative Transients Program*), apresentando bons resultados.

Palavras-Chaves – Transformada *wavelet*, teoria da evidência, rede neural artificial ARTMAP *Fuzzy*, diagnóstico de distúrbio, sistemas de distribuição de energia elétrica.

1 Introdução

Os sistemas de distribuição de energia elétrica estão susceptíveis a faltas decorrentes do mau funcionamento de equipamentos, contatos de animais às partes energizadas, queimadas e fenômenos naturais. Estes distúrbios degradam os índices de qualidade de fornecimento de energia elétrica das concessionárias e elevam seus custos operacionais.

Normalmente, os alimentadores de distribuição não possuem um nível ótimo de monitoramento, controle e automação de suas operações. Os operadores avaliam o estado operativo do sistema a partir do mapeamento das reclamações realizadas via telefone pelos consumidores e por meio de inspeção visual das oscilografias de corrente e tensão. Nos últimos anos, com a crescente competitividade de mercado têm-se estimulado grandes investimentos no desenvolvimento de ferramentas, para a operação e o planejamento, capazes de propiciarem maior confiabilidade e rápido retorno de seus investimentos.

Na literatura especializada destacam-se metodologias que utilizam técnicas de inteligência artificial para realizar processos de automação de subestações [1-3]: 1) Redes neurais artificiais; 2) Lógica *Fuzzy*; 3) Algoritmos genéticos; 4) Sistemas especialistas, entre outras técnicas. Isto se deve ao fato da complexidade do problema, da ausência de formulações analíticas eficazes e da capacidade destas ferramentas integrarem a experiência dos especialistas à habilidade de se executar diagnósticos com aptidão e rapidez.

Neste artigo apresenta-se uma metodologia alternativa para realizar a detecção e classificação de curto-circuito em alimentadores de distribuição com eficiência, alto desempenho computacional e flexibilidade, características imprescindíveis para auxiliar à tomada de decisão. O processo de detecção de faltas é desenvolvido baseando-se na transformada *wavelet* e na teoria da evidência de Dempster-Shafer [4], a qual fornecerá novas informações que auxiliam o operador a inferir o grau de severidade do distúrbio e o nível de confiabilidade do diagnóstico. Na etapa de classificação, emprega-se uma rede neural da família ART (*Adaptive Resonance Theory*), ARTMAP *Fuzzy* [5], cujo treinamento dar-se-á de maneira supervisionada. Esta arquitetura apresenta duas características fundamentais para aplicação em modernos sistemas de energia elétrica: estabilidade e plasticidade, requisitos indispensáveis para a implantação do treinamento continuado. Esta nova configuração de rede, ao longo do tempo, propiciará melhora nos resultados e adaptação automática do módulo às constantes mudanças estruturais e filosóficas do setor, representando uma importante vantagem quando comparada às recentes metodologias.

2 Transformada Wavelet

A Transformada *Wavelet* (TW) é uma moderna técnica de processamento de sinais que supera as limitações encontradas nos métodos baseados na Transformada de Fourier (TF). A Transformada de Fourier Discreta (TFD) têm sido amplamente empregada para análise de sinais estacionários no domínio da frequência, enquanto a Transformada de Fourier com Janelamento (*Short Time Fourier Transform*) provê pouca flexibilidade para análise de sinais não-estacionários, visto sua resolução constante para as diferentes frequências do sinal. No entanto, a TW analisa os componentes de altas frequências em curtos intervalos de tempo e os componentes de baixas frequências em longos intervalos de tempo, tornando-se mais apropriadas para avaliação de transitórios em sistemas elétricos de potência [6].

Na Análise Multirresolução (AMR) o sinal é decomposto em diferentes níveis de resolução através de filtros passa-baixas (h) e filtros passa-altas (g). Os coeficientes de aproximação correspondem aos componentes de alta escala e baixa frequência e os de detalhe aos componentes de baixa escala e alta frequência.

3 Teoria da Evidência

Inicialmente proposta por Arthur Dempster, em 1960, e posteriormente reformulada por Glenn Shafer, em meados de 1970, a teoria da evidência baseia-se no raciocínio probabilístico e na combinação de evidências [4,7]. Evidências relevantes a uma determinada hipótese são associadas a fim de avaliar a veracidade da mesma.

Seja $\theta = \{i | 1 \leq i \leq n\}$, sendo $n = |\theta|$ o total de elementos em θ e considere $\mu_{i,j}$ a evidência j a favor da hipótese i , com $j = 1, 2, \dots, L$. A evidência acumulada a favor da hipótese i é dada por $u(\{i\})$. Similarmente, seja $\omega_{i,k}$ a evidência k contra a hipótese i , com $k = 1, 2, \dots, M$. A evidência acumulada contra a hipótese i é definida é dada por $u^*(\{i\})$.

$$u(\{i\}) = 1 - \prod_{j=1}^L (1 - \mu_{i,j}(\{i\})) \quad u^*(\{i\}) = 1 - \prod_{k=1}^M (1 - \omega_{i,k}(\{i\})) \quad (1)$$

A evidência a favor da hipótese i , $u(\{i\})$, e contra a hipótese i , $u^*(\{i\})$, são combinadas para obter $m(\{i\})$ [4]:

$$m(\{i\}) = K \left[p_i \prod_{q \neq i} d_q + r_i \prod_{q \neq i} c_q \right] \quad (2)$$

sendo:

$$p_i = \frac{u(\{i\})(1 - u^*(\{i\}))}{1 - u(\{i\})u^*(\{i\})}, \quad c_i = \frac{u^*(\{i\})(1 - u(\{i\}))}{1 - u(\{i\})u^*(\{i\})}, \quad r_i = 1 - (p_i + c_i), \quad d_i = c_i + r_i, \quad K^{-1} = \left[\prod_{q=1}^n d_q \right] \left[1 + \sum_{q=1}^n \frac{p_q}{d_q} \right] - \prod_{q=1}^n c_q$$

Para efetuar o cálculo da quantidade probabilística superior, $\mathfrak{B}^*(\{i\})$, primeiramente computa-se o valor da função de dúvida da hipótese i , $\mathfrak{D}ou(\{i\}) = \mathfrak{B}el(\{Z\})$, com $Z = i^c = \theta - i$, como segue [4]:

$$\mathfrak{B}el(\{Z\}) = K \left(\left[\prod_{q=1}^n d_q \right] \left[\sum_{q \in Z} \frac{p_q}{d_q} \right] + \left[\prod_{q \notin Z} c_q \right] \left[\prod_{q \in Z} d_q \right] - \prod_{q=1}^n c_q \right) \quad (3)$$

Tem-se que $\mathfrak{B}^*(\{i\}) = 1 - \mathfrak{B}el(\{Z\})$. Portanto, obtém-se o intervalo de confiança $[m(\{i\}), \mathfrak{B}^*(\{i\})]$, sendo $m(\{i\})$ o valor probabilístico da hipótese i estar correta e $\mathfrak{B}^*(\{i\})$ o valor da chance de falhar ao duvidar da veracidade da hipótese i .

4 Detecção de Anormalidades

Nesta seção apresenta-se um método para detecção de distúrbios em sistemas de distribuição de energia elétrica utilizando os conceitos da transformada *wavelet* e da teoria da evidência de Dempster-Shafer. Este módulo é concebido levando-se em consideração a permanente evolução das tecnologias empregadas nas subestações, o dinamismo inerente aos sistemas de energia elétrica e a presença de ruídos na oscilografias, a fim de se obter robustez e flexibilidade. O processo de detecção de faltas de curto-circuito é executado, permanentemente, baseando-se nos sinais de corrente advindos do sistema de medição presente na saída do alimentador da subestação. Estas informações são pré-processadas, etapa na qual se define o janelamento dos sinais, *e.g.*, três ciclos, e o passo de análise, *e.g.*, meio ciclo, e decompostas em três níveis por meio da AMR. Em seguida, os coeficientes de detalhe são avaliados, nível a nível, utilizando-se dois critérios: (1) análise estatística, e (2) comparação direta com um valor limite preestabelecido pelo engenheiro de proteção. Por fim, aplica-se a teoria da evidência para que se obtenham informações adicionais do estado operativo do alimentador e da confiabilidade do diagnóstico.

4.1 Análise Multiníveis

Dispondo das oscilografias de corrente registradas na saída do alimentador, realiza-se a decomposição em três níveis por meio da AMR. Assim, calcula-se a média aritmética dos valores absolutos dos coeficientes de detalhe para cada nível de decomposição da fase em análise:

$$\overline{d_{ij}} = \frac{\sum_{k=1}^{N_j} d_{ij}^k}{N_j} \quad (4)$$

sendo:

- i : oscilografia em questão, *i.e.*, I_a , I_b e I_c ;
- j : nível de decomposição, *i.e.*, 1, 2 e 3;
- N_j : número de coeficientes de detalhe do nível de decomposição j ;
- d_{ij}^k : coeficiente de detalhe k do nível j referente a oscilografia i .

Para cada coeficiente de detalhe (absoluto), calcula-se sua variação com relação à média obtida:

$$var_{ij}^k = |d_{ij}^k - \bar{d}_{ij}| \quad (5)$$

Posteriormente, obtém-se o desvio padrão dos valores absolutos dos coeficientes de detalhe sob avaliação:

$$\sigma_{ij} = \sqrt{\frac{\sum_{k=1}^{N_j} (d_{ij}^k - \bar{d}_{ij})^2}{N_j - 1}} \quad (6)$$

A detecção de distúrbio baseia-se no conjunto de regras apresentado nas equações (7) e (8), que correspondem a: (A) macroanálise, e (B) microanálise. Por meio de (A) busca-se conhecer o comportamento geral do sinal e compara-se a máxima variação dos coeficientes de detalhe a um percentual do desvio padrão propiciando maior imunidade à presença de ruídos nas oscilografias; em (2) realiza-se uma análise ponto a ponto, onde se confronta o maior coeficiente de detalhe com o limite preestabelecido pelo operador. Detectada anormalidade no sistema, identifica-se o instante de sua ocorrência.

- se $\max[var_{ij}] > 2,5\sigma_{ij}$ e $\max[|d_{ij}|] > \gamma_j \rightarrow \lambda_{ij} = 1$ (7)

indica existência de anormalidade no sistema;

- se $\max[var_{ij}] \leq 2,5\sigma_{ij}$ ou $\max[|d_{ij}|] \leq \gamma_j \rightarrow \lambda_{ij} = 0$ (8)

indica operação normal do sistema.

sendo:

γ_j : parâmetros especificados baseando-se na experiência do engenheiro de proteção e na filosofia de proteção do sistema.

4.2 Aplicação da Teoria da Evidência

Efetuada a análise das oscilografias de corrente para os três níveis de decomposição, conforme disposto nas equações (4)-(8), dispõe-se os resultados na Tabela 1 (exemplo hipotético).

Tabela 1 - Evidências relativas ao estado operativo do sistema.

Decomposição	Sinais do Sistema			Anormalidade	Normalidade
	<i>Ia</i>	<i>Ib</i>	<i>Ic</i>		
Nível 1	1	0	1	2/3	1/3
Nível 2	0	1	0	1/3	2/3
Nível 3	0	1	1	2/3	1/3

Tomando como referência a linha destacada em cinza na Tabela 1, tem-se: evidência de anormalidade nas oscilografias *Ib* e *Ic*; e evidência de normalidade na oscilografia *Ia*. Então, a análise de informações do sistema, sob a faixa de frequência de 1,92 a 0,96 kHz (nível 3), apresentou índice de anormalidade de 2/3 e de normalidade de 1/3.

O intervalo de confiança para os possíveis estados operativos do sistema, anormal e normal, é obtido aplicando os conceitos da teoria da evidência. Calcula-se o valor de $u(\{anormal\}) = 0,9259$. A seguir, calculam-se os índices $p(\{anormal\}) = 0,9259$, $c(\{anormal\}) = 0$, $r(\{anormal\}) = 0,0740$, $d(\{anormal\}) = 0,0740$ e $K^{-1}(\{anormal\}) = 0,2112$. Observa-se que para este caso hipotético não existe contra evidência, a qual pode ser incluída a qualquer instante no procedimento, o que representa vantagem em relação aos métodos clássicos, e.g., esquema de votação. Determina-se o valor de $m(\{anormal\}) = 64,94\%$ (vide equação (2)) e da função de dúvida $\text{Bel}(\{anormal\}) = 29,87\%$, conseqüentemente $\text{B}^*(\{anormal\}) = 70,13\%$. Portanto, o intervalo de confiança para anormalidade foi de $[64,94\%, 70,13\%]$. A inclusão deste procedimento fornece informações quantitativas aos operadores, que o auxiliam a inferir o grau de severidade do distúrbio no sistema de distribuição de energia elétrica (64,94%) e a confiabilidade do diagnóstico (70,13%).

5 Classificação de Anormalidades

A etapa de classificação de faltas é ativada após a identificação de distúrbios no alimentador. As características (*assinatura*) dos sinais de corrente são extraídas empregando-se a AMR e o conceito de energia. Estes índices comportamentais buscam caracterizar, de forma plena, o evento ocorrido no sistema e correspondem ao vetor de entrada da rede neural ARTMAP *Fuzzy*.

5.1 Energia

A energia corresponde a uma ferramenta de *data fusion* que permite caracterizar o comportamento de sinais não-estacionários. Este conceito é utilizado para agregação das informações presentes nos coeficientes de detalhe e aproximação.

O cálculo da energia é definido na equação (9):

$$E_j = \sum_{n=1}^{N_j} |x[n]|^2 \quad (9)$$

sendo:

N_j : número de coeficientes do nível j ;

$x[n]$: coeficientes de detalhe ou aproximação.

5.2 Extração da Assinatura do Sistema

Selecionam-se três ciclos pré-falta e três ciclos em falta dos sinais de corrente, a partir do instante da falta, que são submetidos à AMR com três níveis de decomposição. A extração das características do estado operativo do sistema baseia-se nos coeficientes de detalhe de primeiro nível e de aproximação de terceiro nível. Este conjunto de informações possibilita ampla representação dos possíveis distúrbios, *e.g.*, as singularidades das faltas de alta impedância, que são fortemente caracterizadas por não-linearidades, são plenamente evidenciadas por meio dos coeficientes de detalhe; já os coeficientes de aproximação caracterizam adequadamente as faltas sólidas. Desta maneira, calcula-se a grandeza energia para os respectivos coeficientes.

Por conseguinte, calcula-se a razão entre os índices comportamentais em falta e pré-falta com intuito de incorporar na metodologia uma característica operativa comumente encontrada em sistemas de distribuição de energia elétrica: desequilíbrio entre fases. Esta representação é apresentada na equação (10):

$$\Gamma_{ij} = \frac{E_{ij}^e}{E_{ij}^p} \quad (10)$$

sendo:

i : sinal analisado, *i.e.*, I_a , I_b e I_c ;

j : nível de decomposição em análise, *i.e.*, primeiro nível de detalhe e terceiro de nível de aproximação;

E_{ij}^e : energia do período em falta para o sinal i referente à decomposição j ;

E_{ij}^p : energia do período pré-falta para o sinal i referente à decomposição j .

A fim de obter maior generalização de projeto normalizam-se as grandezas Γ_{ij} conforme disposto na equação (11).

$$X_{ij} = \frac{\Gamma_{ij}}{\Gamma_j^{m\acute{a}x}} \quad (11)$$

sendo:

$\Gamma_j^{m\acute{a}x}$: representa o valor máximo de Γ para cada nível de decomposição, *i.e.*, $\Gamma_j^{m\acute{a}x} = \max\{\Gamma_{Ia,j}, \Gamma_{Ib,j}, \Gamma_{Ic,j}\}$.

Por fim, emprega-se uma representação relativa entre as fases [8]:

$$Y_{1,j} = X_{Ia,j} - X_{Ib,j} \quad Y_{2,j} = X_{Ib,j} - X_{Ic,j} \quad Y_{3,j} = X_{Ic,j} - X_{Ia,j} \quad (12)$$

Os valores dos índices presentes na equação (12) estão compreendidos entre -1 e +1.

A identificação da presença ou ausência da terra em curtos-circuitos bifásicos é realizada pelo índice Z , o qual se baseia nos conceitos da corrente de sequência zero:

$$Z = \max\{Ia + Ib + Ic\} \quad (13)$$

Havendo faltas com conexão à terra, este índice apresentará valores muito superiores aos apresentados em faltas sem conexão à terra. Logo, utiliza-se o seguinte critério:

- se $Z > Z_{m\acute{a}x} \rightarrow \eta = 1$ (14)

indica faltas com conexão à terra;

- se $Z \leq Z_{m\acute{a}x} \rightarrow \eta = 0$ (15)

indica faltas sem conexão à terra.

sendo:

$Z_{m\acute{a}x}$: valor estabelecido baseando-se na experiência do engenheiro de proteção.

5.3 Pré-Processamento e Codificação

Os índices Y_{ij} são transladados para o domínio $\Omega = [0, +1]$ a fim de comporem o vetor de entrada da rede neural ARTMAP *Fuzzy*. Este pré-processamento dar-se-á da seguinte maneira:

$$Y_{ij}^t = \frac{Y_{ij} + 1}{2} \quad (16)$$

Assim, a rede neural ARTMAP *Fuzzy* tem como estímulos de entrada vetores linha (\mathbf{a}) compostos pelos índices comportamentais Y_{ij}^t , os quais caracterizam com exatidão as fases envolvidas no distúrbio. Os estímulos de saída (\mathbf{b}) consistem na codificação das fases envolvidas no curto-circuito, conforme apresentado na Tabela 2.

Tabela 2 - Estímulos de saída da rede neural ARTMAP *Fuzzy*.

Fases Envolvidas	Diagnóstico da rede neural ARTMAP <i>Fuzzy</i>						
	a	b	c	ab	ac	bc	abc
Fase a	1	0	0	1	1	0	1
Fase b	0	1	0	1	0	1	1
Fase c	0	0	1	0	1	1	1

sendo:

- 0 : indica ausência da fase na falta;
- 1 : indica presença da fase na falta.

O cálculo de η só é necessário quando a rede neural apresenta como diagnósticos curtos-circuitos bifásicos. Com isso, tem-se uma redução da complexidade no módulo de classificação de eventos, e consequente aumento da eficiência.

5.4 Rede Neural ARTMAP *Fuzzy*

A rede neural ARTMAP *Fuzzy* consiste em um sistema de aprendizado supervisionado composto por um par de módulos da teoria da ressonância adaptativa, ART_a *Fuzzy* e ART_b *Fuzzy*, conectados pelo módulo de memória associativa inter-ART. Esta rede incorpora a teoria dos conjuntos *fuzzy*, operador AND (\wedge) *fuzzy*, capacitando o aprendizado do sistema neural em resposta a padrões de entrada binários e analógicos, pertencentes ao intervalo $[0, +1]$ [5].

Um mecanismo interno, denominado *match-tracking*, é responsável pelo processo auto-regulador da rede, no qual se maximiza a generalização e minimiza o erro. Sempre que a rede realiza um prognóstico errado, através de uma conexão associativa instruída, o parâmetro de vigilância ρ_a do módulo ART_a *Fuzzy* é incrementado em uma quantidade mínima necessária (ϵ) para corrigir o erro no módulo ART_b *Fuzzy*.

Existem três parâmetros fundamentais no desenvolvimento da rede neural ARTMAP *Fuzzy* [5], são eles:

- Parâmetro de escolha α ($\alpha > 0$) : atua na seleção de categorias;
- Taxa de treinamento β ($\beta \in [0, +1]$) : controla a velocidade de adaptação da rede;
- Parâmetro de vigilância ρ ($\rho \in [0, +1]$) : responsável pelo número de categorias criadas.

Inicialmente todos os elementos das matrizes de pesos da rede $\{W_{(Nx2Ma)}^a, W_{(Nx2Mb)}^b \text{ e } W_{(NxN)}^{ab}\}$ são iguais a 1, mostrando que não existe categoria ativa. Os vetores de entrada e saída são expressos por I^a e I^b , respectivamente.

$$I^a = [\mathbf{a} \ \mathbf{a}^c] = [a_1 \ a_2 \ \dots \ a_{Ma} \ a_1^c \ a_2^c \ \dots \ a_{Ma}^c] \quad (17)$$

$$I^b = [\mathbf{b} \ \mathbf{b}^c] = [b_1 \ b_2 \ \dots \ b_{Mb} \ b_1^c \ b_2^c \ \dots \ b_{Mb}^c] \quad (18)$$

sendo:

$$a_i \in [0, +1], i = 1, 2, \dots, Ma;$$

$$b_i \in [0, +1], i = 1, 2, \dots, Mb;$$

$$a_i^c = 1 - a_i \text{ (complemento de } a_i);$$

$$b_i^c = 1 - b_i \text{ (complemento de } b_i);$$

Ma : número de componentes do vetor \mathbf{a} (entrada);

Mb : número de componentes do vetor \mathbf{b} (saída);

N : número de padrões de treinamento, *i.e.*, número de pares de vetores $\{\mathbf{a}, \mathbf{b}\}$.

A codificação do complemento, a_i^c e b_i^c , é realizada para preservar a amplitude da informação. Analisando as equações (17) e (18) tem-se que $|I^a| = Ma$ e $|I^b| = Mb$ utilizando-se a norma 1, *i.e.*, $|x| = |x_1| + |x_2| + \dots + |x_H|$, para $x = [x_1 \ x_2 \ \dots \ x_H]$.

5.4.1 Etapa de Treinamento

O treinamento da rede neural ARTMAP *Fuzzy* pode ser efetuado de duas formas, dependendo do valor de β :

- Treinamento rápido : $\beta = 1$, permite a adaptação rápida do sistema;
- Treinamento lento : $0 < \beta < 1$, os pesos do sistema são adaptados lentamente.

A Figura 1, disposta no apêndice, apresenta o fluxograma empregado para treinamento da rede neural.

5.4.2 Etapa de Teste

A etapa de teste é realizada usando o procedimento descrito a seguir.

- Passo 1. A partir dos índices comportamentais a serem analisados compõem-se os vetores de teste a e I^a , denotados \underline{a} e \underline{I}^a , respectivamente;
- Passo 2. Identifica-se o neurônio vencedor na rede neural ART_a *Fuzzy* (j_v), sem realizar adaptação de pesos.
- Passo 3. Calcula-se \underline{I}^b e conseqüentemente \underline{b} :

$$\begin{aligned} \underline{I}^b &\equiv W_{j_v}^{ab} W_b \\ &= [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb} \ \underline{b}_1^c \ \underline{b}_2^c \ \dots \ \underline{b}_{Mb}^c] \\ \underline{b} &= [\underline{b}_1 \ \underline{b}_2 \ \dots \ \underline{b}_{Mb}] \text{ (tipo de distúrbio codificado)} \end{aligned}$$

6 Base de Dados

O sistema teste consiste em um alimentador de distribuição de energia elétrica real, com as seguintes características: aéreo, trifásico, ramificado, composto por 134 barras, 13,8 kV, 7,065 MVA com fator de potência igual a 0,92 e mutuamente acoplado [9]. Sob uma frequência de amostragem comumente disponibilizada nos equipamentos de medição, 15,36 KHz, realizaram-se 1440 simulações de curto-circuito no software ATP [10]. Destas, 720 compõem o conjunto de treinamento e 720 compõem o conjunto de teste, as quais foram obtidas combinando os valores dos parâmetros influentes no processo de diagnóstico: resistência de falta (R_f : 0,1; 2; 10; 40; 80 e 100 Ω), carregamento do sistema (S : 50, 60, 70, 80, 90, 100, 110 e 120%), localização da falta ($Barras$: 7, 23, 60, 71, 115 e 119) e ângulo de inserção da falta (θ_f : 0, 45 e 90°).

7 Resultados

O método proposto para detecção e classificação automática de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando técnicas de processamento de sinais e sistemas inteligentes apresentou robustez às dificuldades comumente encontradas em processos de automação de subestações.

O procedimento contínuo de detecção de anomalias é realizado empregando-se a *mother wavelet Daubechies* com filtro de quarta ordem ($db4$) na AMR. Este módulo obteve 100% de acerto nos diagnósticos executados com alto desempenho computacional. Os valores dos parâmetros limite para averiguação do estado operativo do sistema considerando o primeiro, segundo e terceiro nível de decomposição são: 0,01, 0,20 e 4,4, respectivamente.

O desenvolvimento de um eficiente sistema de classificação de eventos contempla duas etapas fundamentais: extração das principais características dos sinais (*assinatura*) e utilização de modernas ferramentas para análise de dados. Na primeira etapa, por meio da AMR e da técnica de *data fusion* ‘energia’ obtém-se os índices comportamentais pré-falta e em falta do sistema, então, calcula-se a razão entre estes índices, tornando a metodologia mais robusta à operação desequilibrada. Por fim, estas características são normalizadas e representadas de forma relativa entre as fases, o que propicia uniformização, *i.e.*, havendo reconfigurações do sistema ou aplicação da metodologia em outros alimentadores, ter-se-á o mesmo comportamento obtido para este caso teste. Na segunda etapa, empregou-se uma rede neural da família ART, ARTMAP *Fuzzy*. Esta arquitetura provê maior desempenho computacional do que as técnicas tradicionais utilizadas na literatura [5], *e.g.*, o algoritmo *backpropagation*; sua eficiência está diretamente relacionada à realização de um treinamento adequado e à correta especificações de seus parâmetros. Assim, foram avaliadas diferentes topologias de rede. Na Tabela 3 são apresentados os valores dos parâmetros utilizados em cada topologia, o tempo de treinamento e o percentual de acerto obtido.

Tabela 3 - Resultados referentes à variação dos parâmetros da rede neural ARTMAP *Fuzzy*.

Topologia da rede neural ARTMAP <i>Fuzzy</i>	Parâmetros					Tempo de treinamento (s)	Acerto (%)
	α	β	ρ_a	ρ_b	ρ_{ab}		
1	0,10	1,00	0,80	1,00	0,95	2,58	100,00
2	0,10	1,00	0,85	1,00	0,95	2,58	100,00
3	0,10	1,00	0,90	1,00	0,95	2,59	90,28

Analisando a Tabela 3 verifica-se que pequenos valores de ρ_a propiciaram maior generalização para o sistema (alto índice de acerto), enquanto grandes valores de ρ_a tornam a rede mais seletiva, *i.e.*, o sistema não é capaz de distinguir um mesmo tipo de distúrbio quando estes apresentam variações relevantes de seus coeficientes característicos.

Diagnosticada a presença de falta bifásica no sistema de distribuição de energia elétrica, calcula-se o índice Z , o qual irá discernir o curto-circuito bifásico com conexão à terra do curto-circuito bifásico sem conexão à terra. Logo, tem-se um aumento da eficiência e rapidez de diagnóstico. Dentro deste contexto, o valor limite estabelecido para constatação da conexão à terra foi $Z_{máx} = 10$. Todas as simulações foram realizadas utilizando o *software* Matlab [11] em um computador Intel Core 2 Duo, 2,93 GHz com 4-GB de memória RAM.

8 Conclusão

Neste artigo foi apresentada uma metodologia rápida e eficiente para detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica. Este procedimento para automação de subestação foi desenvolvido focando no compromisso existente entre as necessidades das concessionárias de energia elétrica e suas condições técnicas e econômicas.

O diagnóstico de faltas é realizado através da análise automática dos registros oscilográficos, via transformada *wavelet*, teoria da evidência de Dempster-Shafer e redes neurais artificiais. Na etapa de detecção de falta avalia-se o comportamento dos sinais de corrente no domínio *wavelet*. Constatada anormalidade no sistema, aplica-se a teoria da evidência para obtenção de informações quantitativas que auxiliam o operador a inferir sobre a severidade do distúrbio e a veracidade do diagnóstico. Esta análise permite incorporar, com facilidade, outros dados advindos de IED's (*Intelligent Electronic Devices*) distribuídos, por exemplo, em *smart grids*. Na etapa de classificação de faltas, emprega-se a rede neural ARTMAP *Fuzzy*, cuja inclusão do treinamento continuado representa outra vantagem em relação às técnicas tradicionais apresentadas na literatura. Nestas redes neurais, a inserção de um novo padrão para treinamento requer a reinicialização deste processo, enquanto que na rede ARTMAP *Fuzzy* este reforço pode ser realizado continuamente sem perda do conhecimento previamente adquirido [12]. Esta concepção de rede provê melhora contínua na qualidade dos resultados e adaptação automática do sistema de diagnóstico às constantes evoluções do setor elétrico. O alto desempenho computacional consiste em um diferencial desta arquitetura para aplicações em sistemas de energia elétrica de grande porte.

Por fim, a integração de técnicas de processamento de sinais ao algoritmo de inteligência artificial proporcionou alta capacidade de generalização, eficiência e rapidez de resposta, características essenciais para auxiliar a tomada de decisão.

9 Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo suporte financeiro.

10 Referências

- [1] M. Kezunovic, Intelligent applications in substations: disturbance analysis, **IEEE Power Engineering Society General Meeting**, 1 (2004), 719-723.
- [2] R. H. Salim, K. R. C. Oliveira, A. D. Filomena, M. Resener, A. S. Bretas, Hybrid fault diagnosis scheme implementation for power distribution systems automation, **IEEE Transactions on Power Delivery**, 23 (2008), 1846-1856.
- [3] O. A. S. Youssef, Combined fuzzy-logic wavelet-based fault classification technique for power system relaying, **IEEE Transactions on Power Delivery**, 19 (2004), 582-589.
- [4] J. A. Barnett, Computational methods for a mathematical theory of evidence, **Classic Works of the Dempster-Shafer Theory of Belief Functions**, (2008), 197-216.
- [5] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, D. B. Rosen, Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps, **IEEE Transactions on Neural Networks**, 3 (1992), 698-713.
- [6] S. K. Meher, A. K. Pradhan, Fuzzy classifiers for power quality events analysis, **Electric Power Systems Research**, 80 (2010), 71-76
- [7] S. Santoso, E. J. Powers, W. M. Grady, A. C. Parsons, Power quality waveform recognition using wavelet-based neural classifier-Part 1: theoretical foundation, **IEEE Transactions on Power Delivery**, 15 (2000), 222-228.
- [8] R. N. Mahanty, P. B. D. Gupta, A Fuzzy logic based fault classification approach using current samples only, **Electric Power Systems Research**, 77 (2007), 501-507.
- [9] LaPSEE, Practical 134 bus feeder data, available: http://www.dee.feis.unesp.br/lapsee/TestSystems/135_bus_feeder.pdf, **Laboratório de Planejamento de Sistemas de Energia Elétrica (LaPSEE)**, (2010).
- [10] Alternative Transients Program (ATP), RuleBook - EMTP-ATP Users Group, **SINTEF Energy Research**, (2007).
- [11] Matlab 7.8 version, **MathWorks Company**.
- [12] S. C. Marchiori, M. C. G. Silveira, A. D. P. Lotufo, C. R. Minussi, M. L. M. Lopes, Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems, **Applied Soft Computing**, 11 (2011), 706-715.

Apêndice

Figura 1 – Fluxograma da rede neural ARTMAP Fuzzy.

