

DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA USANDO UMA REDE NEURAL ARTMAP EUCLIDIANA MODIFICADA COM TREINAMENTO CONTINUADO

ANA CLAUDIA BARROS¹, MAURO S. TONELLI-NETO², JOSÉ G. M. S. DECANINI³, CARLOS R. MINUSSI¹

1. *Laboratório de Sistemas Inteligentes, Departamento de Engenharia Elétrica, FEIS-UNESP
Caixa postal 56, 15385-000 Ilha Solteira, SP, BRASIL*

anaclaudiamuru@gmail.com, minussi@dee.feis.unesp.br

2. *Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campus Votuporanga
Avenida Jerônimo Figueira da Costa, 3014, 15503-110, Votuporanga, SP, BRASIL*

maurotonelli@gmail.com

3. *Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campus Presidente
Epitácio, Rua José Ramos Júnior, 27-50, 19470-000 Presidente Epitácio, SP, BRASIL*

zeguilhermel@bol.com.br

Abstract— This paper presents a methodology to detect and classify voltage disturbances in distribution electrical systems using as tool the modified Euclidian ARTMAP neural network with continuous training. This neural network conception allows the diagnosis system adaption to changes coming from the constant evolution of the electrical system. The voltage signals are extracted using the multi-resolution analysis and energy concept. Results show that the proposed methodology can be used successfully in protecting distribution electrical systems, aiding the operators in decision making in electrical energy substations.

Keywords— Wavelet Transform, Modified Euclidean ARTMAP Neural Network, Continuous Training, Disturbances Diagnosis, Intelligent Automation.

Resumo— Este artigo apresenta uma metodologia para realizar a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica, usando como ferramenta as redes neurais ARTMAP Euclidiana modificada com treinamento contínuo. Esta concepção de rede permite a adaptação do sistema de diagnóstico às mudanças advindas da constante evolução do setor elétrico. Os sinais de tensão são extraídos usando a análise multirresolução e conceito de energia. Os resultados obtidos mostram que a metodologia proposta pode ser usada com sucesso na proteção dos sistemas de distribuição de energia elétrica, auxiliando os operadores na tomada de decisão no ambiente de subestação de energia elétrica.

Palavras-chave— Transformada *Wavelet*, Rede Neural ARTMAP Euclidiana Modificada, Treinamento Contínuo, Diagnóstico de Distúrbios, Automação Inteligentes.

1 Introdução

Atualmente os consumidores vêm exigindo das concessionárias de energia elétrica um melhor fornecimento de energia. A energia fornecida aos clientes deve ser entregue com qualidade e confiabilidade, reduzindo as distorções na tensão e minimizando as interrupções causadas por distúrbios de tensão.

A ocorrência destes distúrbios degrada a qualidade da energia, ocasionando uma má operação de equipamentos ligados à rede elétrica, superaquecimento dos condutores, atuação indevida de relés e sistemas de proteção. Neste contexto, as concessionárias têm aplicado grandes investimentos visando o desenvolvimento de novas técnicas que sejam capazes de detectar e classificar tais distúrbios de forma rápida, segura e eficiente, contribuindo para a automação do sistema de distribuição de energia. Normalmente, a detecção de distúrbios é feita através da inspeção visual das oscilografias de tensão por parte dos operadores, sendo necessária uma prévia experiência em análise e a tomada de decisão. Por ser dependente de operadores humanos, a prática de diagnóstico está susceptível a erros que podem causar a interrupção do fornecimento da energia. Assim, a automação desta prática é de suma importância no contexto atual, técnicas baseadas na inteligência artificial são ferramentas disponíveis no auxílio aos operadores na identificação de anormalidades.

Este trabalho apresenta uma metodologia alternativa de diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica. Trata-se de um sistema simples, robusto e flexível, que utiliza uma rede neural da família ART, ARTMAP Euclidiana Modificada (ARTMAP-EM) com treinamento contínuo, para realizar a classificação dos distúrbios. A rede neural empregada disponibiliza uma nova concepção, na qual o desempenho da mesma é aperfeiçoado com o passar do tempo, *i.e.*, à medida que novos conhecimentos são apresentados à rede, não necessitando, desta maneira, reinicializar o processo de treinamento. O reforço deste conhecimento é feito em tempo real (*on-line*) e de maneira automática, uma vez que a rede apresenta parâmetros responsáveis em identificar a presença de novos conhecimentos e refinar o conhecimento previamente adquirido.

O treinamento contínuo pode ser realizado a partir dos dados destinados ao diagnóstico oriundo do sistema de aquisição de dados (SCADA) do sistema, além de bases obtidas via simulações que contemplem outras alterações na topologia da rede elétrica e outros tipos de distúrbios de tensão (característicos de distorções da forma de onda), inclusive outras anormalidades, *e.g.*, curtos-circuitos de baixa e de alta impedância.

A extração das características da forma de onda de tensão é realizada empregando-se em conjunto a transformada *wavelet* discreta (DWT), análise multir-

resolução (AMR) e o conceito energia. Estas características correspondem aos vetores de entrada da rede neural ARTMAP-EM com treinamento continuado. Como saída a rede neural fornece uma codificação binária pré-estabelecida de forma a representar o tipo de distúrbio presente no alimentador.

2 Transformada Wavelet Discreta e Análise Multirresolução

2.1 Transformada Wavelet discreta

A transformada *wavelet* é uma transformada linear que utiliza uma série de funções oscilatórias com distintas frequências como funções de janelamento. Esta função base, chamada de *wavelet* mãe, deve possuir energia finita e valor médio nulo (Eristi, 2010).

Para analisar oscilografias obtidas por equipamentos de aquisição de dados é necessária a discretização da função *wavelet*. Assim, define-se a transformada *wavelet* discreta de um sinal amostrado $f(k)$ (Mallat, 2009):

$$DWT_f = \langle f, \psi_{m,n} \rangle = \sum_k f[k] \psi_{m,n}^*[k] \quad (2)$$

sendo:

$$\psi_{m,n}^*[k] = \frac{1}{\sqrt{r_0^m}} \psi^* \left[\frac{k - ns_0 r_0^m}{r_0^m} \right] \quad (3)$$

2.2 Análise Multirresolução

A AMR consiste no cálculo dos coeficientes r e d , determinados pelas equações (4) e (5), respectivamente. Para o cálculo dos coeficientes r_{m+1} e d_{m+1} , faz-se necessário realizar a convolução discreta do sinal r_m com um filtro passa-baixa (h), *i.e.*, função escala discreta, e com um filtro passa-alta (g), *i.e.*, função *wavelet* discreta. Na saída de cada um dos filtros o sinal decomposto é subamostrado por um fator de 2 (Mallat, 2009):

$$r_{m+1}[p] = \sum_n h[n-2p] r_m[n] \quad (4)$$

$$d_{m+1}[p] = \sum_n g[n-2p] r_m[n] \quad (5)$$

Os coeficientes, obtidos na saída do filtro passa-baixa, r_{m+1} , são caracterizados por serem os componentes de alta escala e baixa frequência do sinal, denominados coeficientes de aproximação. Já os coeficientes obtidos na saída do filtro passa-alta, d_{m+1} , são os componentes de baixa escala e alta frequência, denominados coeficientes de detalhe. A figura 1 apresenta a decomposição de um sinal f em dois níveis de decomposição.

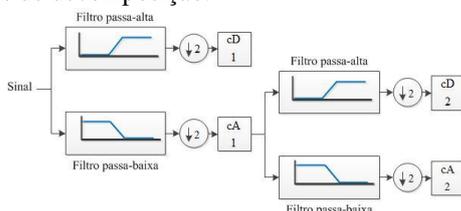


Figura 1. Análise multirresolução em dois níveis de decomposição

3 Detecção de Distúrbios de Tensão

A detecção de distúrbios é realizada pela análise das oscilografias de tensão obtidas na saída da subestação. Nesta etapa, define-se o janelamento do sinal, *i.e.*, dois ciclos, e o passo em análise, *i.e.*, um ciclo. Assim, aplica-se a AMR para decomposição do sinal das fases em dois níveis. Em seguida, calcula-se a média aritmética do valor absoluto dos coeficientes de detalhe de cada nível de decomposição da oscilografia em análise (Decanini *et al.*, 2012):

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

sendo:

i : oscilografia em análise, *i.e.*, Va , Vb , Vc ;

j : nível de decomposição, *i.e.*, 1 e 2;

N_j : número de coeficientes de detalhe do nível j ;

k : k -ésimo coeficiente de detalhe do nível j referente à oscilografia i ;

d_{ij} : média aritmética dos coeficientes de detalhe do nível j referente à oscilografia i .

Posteriormente, calcula-se a variação em relação à média aritmética obtida para cada coeficiente de detalhe, através da equação 7 (Decanini *et al.*, 2012):

$$var_{ij}^k = \left| |d_{ij}^k| - \bar{d}_{ij} \right| \quad (7)$$

sendo var_{ij}^k a variação do k -ésimo coeficiente de detalhe em relação à média aritmética destes coeficientes para o nível j referente à oscilografia i .

Concomitantemente, obtém-se o desvio padrão do valor absoluto dos coeficientes de detalhe sob avaliação (Decanini *et al.*, 2012):

$$\sigma_{ij} = \sqrt{\frac{\sum_{k=1}^{N_j} (|d_{ij}^k| - \bar{d}_{ij})^2}{N_j - 1}} \quad (8)$$

sendo σ_{ij} o desvio padrão dos coeficientes de detalhe do nível j referente à oscilografia i .

O processo de detecção de distúrbios de tensão é baseado em dois conjuntos de regras apresentados nas equações (9) e (10), correspondendo a: macroanálise e microanálise. Através da macroanálise compara-se a máxima variação dos coeficientes de detalhe a um percentual do desvio padrão, proporcionando maior imunidade à presença de ruídos nas oscilografias. Já a microanálise permite realizar uma análise ponto-a-ponto, confrontando o maior coeficiente de detalhe com o limite preestabelecido pelo operador (Decanini *et al.*, 2012):

$$\bullet \quad \max[var_{ij}] > 1,25\sigma_{ij} \text{ e } \max[d_{ij}] > \mu_{ij} \rightarrow \tau_{ij} = 1 \quad (9)$$

Indica a operação anormal do sistema.

$$\bullet \quad \max[var_{ij}] \leq 1,25\sigma_{ij} \text{ e } \max[d_{ij}] \leq \mu_{ij} \rightarrow \tau_{ij} = 0 \quad (10)$$

Indica operação normal do sistema.

sendo μ_{ij} o parâmetro a ser especificado baseando-se na filosofia de proteção do sistema e experiência do operador, e τ_{ij} o índice indicativo do estado de operação do sistema.

4 Classificação de Distúrbios

4.1 Conceito Energia

O conceito de energia corresponde a uma ferramenta de *data fusion* que pode ser utilizada para agregar as informações extraídas de um sinal por meio de algum tipo de transformada. A energia pode ser calculada através da seguinte equação (Oppenheim, 1975):

$$E = \sum_{n=1}^N |x[n]|^2 \quad (11)$$

sendo $x[n]$ a amostras do sinal e N o número de pontos do sinal analisado.

4.2 Extração das Características

Detectada qualquer anormalidade no sistema, ativa-se a etapa de classificação. A extração dos índices característicos representativos do distúrbio é realizada por meio da TWD, AMR e conceito energia. Estes índices comportamentais compõem o vetor de entrada da rede ARTMAP-EMTC, responsável pela classificação do distúrbio.

O módulo de classificação seleciona dois ciclos pré-distúrbio e em distúrbio das oscilografias de tensão a partir do instante de ocorrência determinado no processo de detecção. Estes ciclos são decompostos pela AMR em quatro níveis de resolução.

As características do estado de operação do sistema são baseadas nos coeficientes de detalhe do terceiro e quarto nível, e nos coeficientes de aproximação do quarto nível. Logo, a energia dos coeficientes de detalhe e aproximação dos ciclos pré-distúrbios, considerando cada uma das fases, é calculada conforme as equações (12) e (13):

$$Eca_j^{f,pré} = \sum_{n=1}^{N_j} |ca_j^{f,pré}[n]|^2 \quad (12)$$

$$Ecd_j^{f,pré} = \sum_{n=1}^{N_j} |cd_j^{f,pré}[n]|^2 \quad (13)$$

Similarmente, aplica-se o mesmo procedimento para os coeficientes dos ciclos em distúrbio:

$$Eca_j^f = \sum_{n=1}^{N_j} |ca_j^f[n]|^2 \quad (14)$$

$$Ecd_j^f = \sum_{n=1}^{N_j} |cd_j^f[n]|^2 \quad (15)$$

sendo:

j : nível de decomposição, *i.e.*, terceiro e quarto nível de detalhe, e quarto nível de aproximação;

f : fase da oscilografia analisada;

N_j : número de coeficiente do nível j ;

$ca^{pré}[n]$: valor do n -ésimo coeficiente de aproximação dos ciclos pré-distúrbio;

$cd^{pré}[n]$: valor do n -ésimo coeficiente de detalhe dos ciclos pré-distúrbio.

$ca[n]$: valor do n -ésimo coeficiente de aproximação dos ciclos em distúrbio;

$cd[n]$: valor do n -ésimo coeficiente de detalhe dos ciclos em distúrbio.

Com isso, definem-se os vetores característicos pré e em distúrbio (Decanini *et al.*, 2011).

$$\mathbf{A}_{dis}^p = [E_{d_3}^{Va,p} E_{d_4}^{Va,p} E_{a_4}^{Va,p} E_{d_4}^{Vb,p} E_{d_5}^{Vb,p} E_{a_4}^{Vb,p} E_{d_3}^{Vc,p} E_{d_5}^{Vc,p} E_{a_4}^{Vc,p}] \quad (16)$$

$$\mathbf{A}_{dis} = [E_{d_3}^{Va} E_{d_4}^{Va} E_{a_4}^{Va} E_{d_4}^{Vb} E_{d_5}^{Vb} E_{a_4}^{Vb} E_{d_3}^{Vc} E_{d_5}^{Vc} E_{a_4}^{Vc}] \quad (17)$$

Em seguida, do vetor característico em distúrbio subtrai-se o vetor característico pré-distúrbio. Isto se faz necessário para incorporar na metodologia uma referência de operação do sistema, *i.e.*, operação normal (Decanini *et al.*, 2011; Uyar *et al.*, 2008).

$$\mathbf{\Gamma} = \mathbf{A}_{dis} - \mathbf{A}_{dis}^p \quad (18)$$

Após a análise do tipo de distúrbio, o vetor $\mathbf{\Gamma}$ é normalizado e codificado para se obter maior generalização de projeto e manutenção da informação do sinal (positivo e negativo). Logo, o vetor de entrada da rede ARTMAP-EMTC (\mathbf{Ea}) é definido por (Decanini *et al.*, 2011):

$$\mathbf{Ea} = [\mathbf{\Psi} \ \mathbf{\Phi}] \quad (19)$$

sendo:

$$\mathbf{\Psi} = [\Psi_1 \ \Psi_2 \ \dots \ \Psi_9] \quad (20)$$

com:

$$\Psi_i = \frac{|\Gamma_i|}{\Gamma_{max}} \quad (21)$$

$$|\Gamma_{max}| = \max\{|\Gamma_i|\}, \quad i = 1, \dots, 9 \quad (22)$$

Os componentes do vetor $\mathbf{\Phi}$ são:

$$\begin{cases} \Psi_i > 0 \rightarrow \Phi_i = 1 \\ \Psi_i \leq 0 \rightarrow \Phi_i = 0 \end{cases}, \quad i = 1, \dots, 9 \quad (23)$$

sendo $\mathbf{\Psi}$ o vetor das características normalizadas e $\mathbf{\Phi}$ o sinal de cada característica normalizada.

A saída da rede neural, definida pelo vetor (\mathbf{Eb}), fornece o tipo de distúrbio de tensão presente no sistema. Esta saída é codificada como mostra a Tabela 1.

Tabela 1. Codificação de Saída.

Distúrbios de tensão	Codificação de saída
Elevação (<i>Swell</i>)	[0 0 0 1]
Afundamento (<i>Sag</i>)	[0 0 1 0]
Interrupção (<i>Outage</i>)	[0 0 1 1]
Harmônico	[0 1 0 0]
Elevação com harmônico	[0 1 0 1]
Afundamento com harmônico	[0 1 1 0]
Transitório oscilatório	[0 1 1 1]

5.3 Rede Neural ARTMAP Euclidiana Modificada

A rede neural ARTMAP-EM é um sistema de aprendizado auto-organizável composto por um par de módulos ART euclidiano, ARTa e ARTb, interconectados por um módulo de memória associativa inter-ART. Esta rede utiliza em seus cálculos a distância euclidiana, permitindo, assim, o aprendizado do sistema neural em resposta a padrões de entrada binários ou analógico, pertencentes ao \mathbb{R}^+ ($[0, +\infty[$).

O módulo inter-ART possui um mecanismo autorregulador interno, denominado *match-tracking*, que utiliza o operador AND *fuzzy* (\wedge) para verificar se ocorre ou não o casamento da informação presente na entrada e na saída da rede (Carpenter *et al.*, 1992). Caso não haja casamento deverá ocorrer o dispositivo *reset*. No *reset*, uma nova categoria do módulo ARTa é escolhida para ser introduzida no processo de ressonância. Além disso, um decremento no parâmetro ρ_a é feito. Nesta rede, o critério de vigilância do módulo inter-ART somente é ativado quando nenhuma categoria for criada, tanto em ARTa como em ARTb. Ela é inicializada com apenas um neurônio ativo, *i.e.*, primeiro padrão apresentado à rede ($\mathbf{W}_1^a = \mathbf{a}_1$ e $\mathbf{W}_1^b = \mathbf{b}_1$). Os pesos do módulo inter-ART são definidos da seguinte forma: $W_{1,1}^{ab} = 1$ e $W_{1,n}^{ab} = 0$, sendo $n = 2, 3, \dots, N$. Os demais pesos \mathbf{W}^{ab} são fixados em 1. Os vetores de entrada e saída da rede são representados por a e b, respectivamente, e definidos acordo com as equações (24) e (25).

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{Ma}] \quad (24)$$

$$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{Mb}] \quad (25)$$

sendo:

$$a_i \in [0,1], \ i = 1, 2, \dots, Ma \quad (26)$$

$$b_j \in [0,1], \ j = 1, 2, \dots, Mb \quad (27)$$

Ma : número de componentes do vetor a (entrada);

Mb : número de componentes do vetor b (saída);

N : número de padrões de entrada e saída.

Sua aprendizagem depende basicamente da escolha dos parâmetros de vigilância (ρ_a , ρ_b e ρ_{ab}), da taxa de treinamento (β) e do parâmetro de incremento (ϵ).

A rede neural ARTMAP-EM é uma concepção que visa proporcionar soluções com qualidade, precisão e rapidez. Uma vantagem desta rede refere-se a não necessidade da normalização e codificação complementar dos padrões de entrada, que duplica a dimensão do vetor de entrada. Além disso, como usa uma geometria quadrática, a formação de classes é mais precisa se comparada à formulação convencional da rede neural ARTMAP *fuzzy* (geometria retangular) (Marchiori *et al.*, 2011).

5.4 Rede Neural ARTMAP Euclidiana Modificada com Treinamento Continuado

A seguir apresenta-se a idealização do treinamento continuado a ser incorporado na rede neural ARTMAP-EM. Trata-se do desenvolvimento de um sistema que contempla o treinamento de forma contínua, ou seja, havendo a disponibilidade de novos padrões, o treinamento não necessita ser reinicializado, diferente de como é abordado em outras redes neurais conhecidas na literatura. Na rede ARTMAP-EM, bem como em outras redes da família ART, a incorporação do módulo de treinamento continuado é possível por causa das características de estabilidade e plasticidade que ela possui, constituindo um sistema neural aperfeiçoado quando comparado à rede ARTMAP com treinamento incremental.

O treinamento continuado possibilita a inclusão de novos padrões à memória da rede de forma permanente. Deste modo, o treinamento e a análise (diagnóstico) se tornam procedimentos mais rápidos e eficientes. Para que este mecanismo funcione, de forma correta, foram adicionados alguns elementos no algoritmo de treinamento da rede neural ARTMAP-EM (Barros, 2012). A primeira modificação a ser feita é a inclusão de pesos temporários e definitivos no módulo ARTa. Isto se faz necessário para evitar a presença de categorias semelhantes na memória da rede. Sendo assim, no processo de escolha das categorias, existem categorias temporárias e categorias definitivas. Logo, definem-se duas funções de ativação, uma para as categorias temporárias (\mathbf{T}_v^t), e outra para as categorias definitivas (\mathbf{T}_i^d).

Na inicialização da rede a categoria temporária é iniciada com apenas um neurônio ativo, *i.e.*, o primeiro padrão apresentado à rede ($\mathbf{W}_1^{at} = \mathbf{a}_1$), e os pesos do módulo inter-ART temporário, \mathbf{W}^{abt} , são fixados em 1. Já os pesos definitivos \mathbf{W}^{ad} , \mathbf{W}^{bd} e \mathbf{W}^{abd} dos módulos ARTa, ARTb e inter-ART são iguais aos pesos \mathbf{W}^a , \mathbf{W}^b e \mathbf{W}^{ab} da rede ARTMAP-EM treinada de modo *off-line*, respectivamente.

A segunda modificação foi a inclusão de dois novos parâmetros: $NMIN$ e η . O parâmetro $NMIN$ ($NMIN \in \mathbb{N}$, com $NMIN > 1$) se refere ao número de padrões necessários para que um peso temporário se torne definitivo. Durante o treinamento da rede os padrões temporários semelhantes são contados e armazenados no vetor \mathbf{ContT} , e quando atingem o valor $NMIN$ tornam-se definitivos. O parâmetro η ($\eta > 0$) é responsável em verificar se há ou não a necessidade de atualização dos pesos da categoria definitiva vencedora, *i.e.*, informações redundantes apresentadas à rede são descartadas. Desta forma, evita-se que classes de padrões semelhantes sejam alocadas em categorias distintas, evitando, assim, o sobrecarregamento da memória da rede (Moreno, 2010).

5 Banco de Dados

5.1 Sistema Teste

Normalmente, os centros de pesquisas e as concessionárias não possuem um banco de dados representativos do sistema de distribuição operando na presença de distúrbios. Em consequência da escassez destes registros, torna-se necessário a utilização de sistemas teste para a simulação de distúrbios, possibilitando a extração de informações pertinentes e validação de metodologias de diagnóstico de distúrbios. Assim, neste trabalho, utilizou-se o alimentador de 134 barras de uma concessionária brasileira. O alimentador de distribuição de energia elétrica real possui as seguintes características: sistema aéreo, trifásico, ramificado, 13,8 kV, 7,065 MVA, fator de potência das cargas igual a 0,92 e mutuamente acoplado. O diagrama unifilar e respectivos dados são encontrados em LaPSEE (2011).

5.2 Treinamento e Conjunto de Teste

Para obtenção dos dados de distúrbios de tensão, o alimentador, mencionado anteriormente, foi modelado com auxílio do software ATP (*Alternative Transients Program*) (ATP, *RuleBook*). As simulações dos distúrbios de tensão foram realizadas por meio da rotina *models* do ATP, na qual foram implementadas fontes de alimentação com os distúrbios abordados neste trabalho. Em cada simulação utilizou-se uma frequência de amostragem de 15,36 kHz, correspondente a 256 amostras por ciclo.

6 Resultados

No processo de detecção de distúrbios empregou-se a *wavelet* mãe Daubechies com um filtro de quarta (db4) na aplicação da AMR. Os valores dos parâmetros limite utilizados pelo operador para verificação do estado operativo do sistema são apresentados na tabela 2. Este módulo apresentou um desempenho de 100% de acerto na identificação de situações anormais, caracterizadas por distúrbios de tensão, com alto desempenho computacional.

Tabela 2. Parâmetros para detecção de distúrbio de tensão.

Parâmetro	Nível de Decomposição	
	Primeiro	Segundo
μ	0,005	0,07

Detectada qualquer operação anormal no sistema de distribuição, e após ser identificado o instante no qual iniciou o distúrbio, são selecionados dois ciclos em distúrbio e dois ciclos pré-distúrbio. Estes são analisados em quatro níveis de resolução por meio da AMR e agregados através do conceito energia. Nesta etapa, também foi empregada a *wavelet* mãe Daubechies com um filtro de quarta ordem (db4).

Na etapa de classificação de distúrbios, do total de 3024 vetores de distúrbios de tensão, foram selecionados 524 padrões para treinamento do módulo

ARTMAP-EM e 2500 para teste. Deve-se ressaltar que esta seleção foi realizada de forma pseudo-aleatória. Além disso, os distúrbios da classe “harmônico” foram todos incluídos no conjunto de padrões para teste. Deste modo é possível visualizar a capacidade do módulo de treinamento continuado em adquirir novos conhecimentos, mostrando a melhora nos resultados com o passar do tempo. A tabela 3 apresenta a taxa de acerto do módulo ARTMAP-EM.

Tabela 3. Percentual de acerto sem treinamento continuado.

Distúrbios de tensão	Padrões de teste	Acerto (%)
Elevação (<i>Swell</i>)	346	83,51
Afundamento (<i>Sag</i>)	338	54,73
Interrupção (<i>Outage</i>)	338	81,95
Harmônico	432	0
Elevação com harmônico	359	93,31
Afundamento com harmônico	346	54,33
Transitório oscilatório	341	99,70
Total	2500	64,56

Analisando a taxa de acerto referente ao distúrbio harmônico observa-se que ela foi zero. Isto se deve ao fato de que este distúrbio não possui nenhum padrão no conjunto de padrões de treinamento, *i.e.*, a rede ARTMAP-EM treinada não conhece o distúrbio harmônico.

Além disso, obteve-se uma taxa de acerto baixa para os distúrbios *sag* e *sag* com harmônico. Os erros na classificação destes distúrbios são ocasionados pelo comportamento dos índices característicos, já que para os distúrbios *sag*, *outage* e *sag* com harmônico eles se distinguem somente em amplitude. Desta forma, os distúrbios *sag* e *sag* com harmônico são classificados como *outage* pelo módulo de classificação.

Posteriormente a etapa de treinamento off-line, ativa-se o módulo de treinamento continuado. Cada um dos padrões de teste utilizados na ARTMAP-EM são apresentados separadamente, *i.e.*, um a um, para a rede ARTMAP-EMTC. Como resultado a rede ARTMAP-EMTC fornece um novo diagnóstico à medida que novos padrões são apresentados a rede. Então, considerando todos os padrões de teste, a rede fornecerá ao operador 2500 distintos diagnósticos.

Tabela 4. Percentual de acerto com treinamento continuado.

Distúrbios de tensão	Padrões de teste	Acerto (%)
Elevação (<i>Swell</i>)	346	100
Afundamento (<i>Sag</i>)	338	72,18
Interrupção (<i>Outage</i>)	338	97,33
Harmônico	432	99,53
Elevação com harmônico	359	98,32
Afundamento com harmônico	346	71,38
Transitório oscilatório	341	99,70
Total	2500	91,56

Comparando as tabelas 3 e 4 observa-se que houve uma melhoria na etapa de classificação, ou

seja, a rede neural com a inclusão do treinamento continuado foi capaz de classificar de forma correta distúrbios que anteriormente ela classificava erroneamente. Também se observa que o distúrbio harmônico, de zero, atingiu 99,53% de acerto, o que mostra a eficiência e a robustez ao dinamismo inerente ao sistema de energia elétrica, já que os distúrbios foram detectados e classificados em diversos níveis de carregamento do sistema de distribuição. Este processo de melhoria é observado à medida que a rede neural executa o diagnóstico de maneira simultânea ao treinamento continuado. Os parâmetros utilizados nas fases de treinamento e teste da rede foram: $\beta = 1$; $\rho_a = 0,15$, $\rho_b = 0$, $\rho_{ab} = 0,95$, $\varepsilon = 0,0000001$, $\eta = 2$ e $MNIN = 2$.

7 Conclusão

O trabalho desenvolvido consiste de uma estrutura neural com treinamento continuado, aplicada à classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. O módulo de diagnóstico de distúrbios de tensão foi projetado com o objetivo de atender as necessidades das concessionárias, levando em consideração a situação econômica atual do setor elétrico.

Através do uso combinado de técnicas de processamento de sinais e metodologias baseadas na inteligência artificial, o sistema de diagnóstico apresentou alta capacidade de generalização, flexibilidade e eficiência, características imprescindíveis no auxílio à tomada de decisão no ambiente das subestações de energia elétrica. O processo de detecção foi capaz de identificar todas as situações anormais de operação. Assim, identificada a presença de distúrbios de tensão, as oscilografias de tensão são analisadas por meio da AMR e do conceito energia, gerando índices característicos representativos dos distúrbios detectados. Por conseguinte, estes índices são apresentados à rede neural ARTMAP-EMTC, fornecendo ao operador o tipo de distúrbio de tensão. Além disso, por utilizar uma concepção de treinamento diferente, o módulo neural, a cada diagnóstico, melhora ou adquire novos conhecimentos.

Então, a vantagem da rede ARTMAP-EMTC em relação às outras redes neurais encontradas na literatura especializada, é que esta permite o aperfeiçoamento contínuo das categorias existentes de modo que o aprendizado seja realizado permanentemente sem a necessidade de reinicialização do processo de treinamento. Esta importante característica permite a aplicação da rede neural em questão em modernos sistemas de energia elétrica, *e.g.*, *smart grids*, pois, tem a capacidade de aprender em tempo real, produzindo resultados mais precisos com baixo tempo de execução.

Agradecimentos

Os autores agradecem a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e à

FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) pelo apoio financeiro de pesquisa.

Referências Bibliográficas

- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. e Rosen, D. B. (1992). Fuzzy ARTMAP: A Neural Network Architecture For Incremental Supervised Learning of Analog Multidimensional Maps. *IEEE Transactions on Neural Networks*, Vol. 3, No. 5, pp. 698-713.
- Decanini, J. G. M. S., Tonelli-Neto, M. S. e Minussi, C. R. (2011). Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. *IET Generation, Transmission & Distribution*, Vol. 6, No. 11, pp. 1112-1120.
- Decanini, J. G. M. S.; Tonelli-Neto, M. S.; Malange, F. C. V. e Minussi, C. R. (2011). Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. *Electric Power Systems Research*, Vol. 81, No. 12, pp. 2057-2065.
- Barros, A. C.; Tonelli-Neto, M. S.; Decanini, J. G. M. S. e Minussi, C. R. (2012). Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando uma rede neural artmap euclidiana modificada com treinamento continuado. *XIX Congresso Brasileiro de automática*. Campina Grande – PB. pp. 1-8.
- Eristi, H., Uçar, A. e Demir, Y. (2010). Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. *Electric Power System Research*, Vol. 80, No. 7, pp. 743-752.
- LaPSEE (2011). Practical 134 bus feeder data.
- Mallat, S. (2009). *A Wavelet Tour of Signal Processing: The Sparse Way*. Academic Press.
- Marchiori, S. C.; Silveira, M. C. G.; Lotufo, A. D. P.; Minussi, C. R. e Lopes, M. L. M. (2011). Neural Network Based on Adaptive Resonance Theory With Continuous Training For Multi-Configuration Transient Stability Analysis of Electric Power Systems. *Applied Soft Computing*, Vol. 11, pp. 706-715.
- Meyer, W. S. e Liu, T. H. (2000). *Alternative Transients Program (ATP): Rule Book*.
- Moreno, L. A. (2010). *Análise da Estabilidade Transitória via Rede Neural ART-ARTMAP Fuzzy Euclidiana Modificada com Treinamento Continuado* (Tese (Doutorado), Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia Elétrica de Ilha Solteira).
- Oppenheim, A.V. e Schaffer, R.W. (1975). *Digital signal processing*. Prentice-Hall.
- Uyar, M.; Yildirim, S. e Gencoglu, M. T. (2008). An effective wavelet-based feature extraction method classification of power quality disturbance signals. *Electric Power System. Research*, Vol. 78, No. 10, pp. 1747-1755, 2008.