

REDE NEURAL ARTMAP-FUZZY E TRANSFORMADA WAVELET PARA DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE ENERGIA ELÉTRICA

FERNANDO C. V. MALANGE, CARLOS R. MINUSSI

Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira, UNESP - Universidade Estadual Paulista "Júlio de Mesquita Filho", Avenida Brasil-Centro, 56, CEP:15385-000, Ilha Solteira, SP, Brasil

E-mails: fmalange@gmail.com, minussi@dee.feis.unesp.br

Abstract – Many efforts have been dispended to solve problems related to the Electrical Energy Quality, principally in automation of process and developing monitoring equipments that provide improvements in behavior and reliability of the electrical system. This paper presents an automatic identifier/classifier system for disturbances called Wavelet-ARTMAP-Fuzzy neural network. The basic structure of this neural network is composed of three modules: the anomaly (disturbance) detection module; the characteristics extraction module, where the wave forms are analyzed by calculating the Discrete Wavelet Transform, Multiresolution Analysis, and Entropy Norm; and the classification disturbance module which contains a Fuzzy ARTMAP neural network that shows what kind of anomaly of the signal. This study considers seven types of electrical signals, generated from the mathematical models, performing 2800 wave forms. Thus, the performance of this network in detecting and classifying correctly the several electrical disturbances was 100%, moreover the robust form and velocity in obtaining the results, allowing using in real time.

Keywords - Electrical Power Systems; Voltage Anomaly Detection and Classification; Wavelet Transform; Entropy Norm; Fuzzy ARTMAP Neural Network.

Resumo - Muitos esforços têm sido despendidos para tentar sanar problemas relacionados com Qualidade da Energia Elétrica, principalmente na automação de processos e desenvolvimento de equipamentos de monitoração que possibilitem maior desempenho e confiabilidade a todo o sistema elétrico. Este artigo apresenta um sistema identificador/classificador automático de distúrbios chamado de rede neural *Wavelet-ARTMAP-Fuzzy*. A estrutura básica dessa rede neural é composta por três módulos: o módulo de detecção de anomalias (distúrbios), o módulo de extração de características onde as formas de onda são analisadas através do cálculo da Transformada *Wavelet* Discreta, Análise Multirresolução e Norma Entropia e o módulo de classificação de distúrbios que conta com uma rede neural ARTMAP *Fuzzy* que indica qual o tipo de anomalia do sinal. Nesse estudo, foram considerados sete tipos de sinais elétricos, gerados a partir de modelos matemáticos, totalizando 2.800 formas de onda. Dessa forma, o desempenho da rede na detecção e classificação correta dos tipos de distúrbios elétricos foi de 100%, além da forma robusta e grande rapidez na obtenção dos resultados, possibilitando sua aplicação em tempo real.

Palavras-chave - Sistemas Elétricos de Potência; Detecção e Classificação de Distúrbios de tensão; Transformada *Wavelet*, Norma Entropia; Rede Neural ARTMAP *Fuzzy*.

Introdução

O conceito de Qualidade de Energia (QE) vem sofrendo alterações em consequência do avanço tecnológico. Há alguns anos, a principal preocupação da QE concentrava-se na qualidade de serviço, ou seja, com o intervalo de tempo em que o sistema permanece desligado e a frequência com que ocorrem tais interrupções da tensão. Atualmente, parâmetros como a amplitude e frequência da tensão, desequilíbrio de tensão e distorção harmônica assumem elevada importância no contexto da QE (Kezunovic e Abur, 2005; Allen, et al., 2005). São fenômenos que, embora sempre tenham existido, têm despertado particular interesse e estudos. Entre muitos apontamentos da literatura a definição do que seria um problema de Qualidade de Energia Elétrica. Uma delas [Bollen, 2000] diz que se pode classificar o assunto como qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulte em falha ou má operação dos equipamentos de consumidores. Um problema, dentro do contexto de QE, refere-se aos distúrbios que causam a interrupção momentânea, distorção harmônica, afundamento e elevação de tensão, dentre outros. Os distúrbios que ocorrem nos sistemas elétricos de potência podem provocar inúmeras interferências indesejáveis como acionamento indevido de relés, mau funcionamento e/ou danos de equipamentos sensíveis, distorções em equipamentos de medição, que podem resultar, até mesmo, na interrupção do fornecimento de energia elétrica. Tudo isto resulta em um efeito econômico não desprezível, acarretando prejuízos tanto às concessionárias como aos consumidores. Com o aumento crescente na utilização de equipamentos eletrônicos, exige-se cada vez mais a qualidade no sinal entregue pela concessionária. A detecção e a classificação de distúrbios são temas importantes para o desenvolvimento de equipamentos de monitoração de QE. Nesse processo devem-se usar, basicamente, técnicas de processamento de sinais para extrair característi-

cas específicas dos sinais elétricos, seguidos pelo emprego de uma técnica para classificar os distúrbios detectados. Contudo estas técnicas devem preservar aspectos como o baixo esforço computacional e eficiência de classificação para ser considerado adequado para implementação em sistemas de classificação de distúrbios trabalhando em tempo real. A partir dessas premissas desenvolveu-se um modelo moderno e eficiente de identificador e classificador automático de anomalias (distúrbios) de tensão. Trata-se de um método que combina o uso da transformada *wavelet* (Daubechies, 1992) e redes neurais artificiais (Haykin, 2008). Este método é definido como sendo uma rede que realiza a detecção de anomalias em um sinal puro, extrai as características das formas dessas ondas e classifica qual o distúrbio ou combinação de distúrbios de tensão que o sinal de entrada sofreu. Ou seja, após um sinal ser lido pela rede a mesma indicará se o sinal é puro ou se sofreu qual tipo de distúrbio. A princípio os tipos detectados incluem os distúrbios de curto prazo, como afundamento de tensão (*sag*) e elevação de tensão (*swell*), os distúrbios de longo prazo como distorção harmônica, bem como uma combinação entre eles distorção harmônica com *sag* e distorção harmônica com *swell*. Este sistema identificador/classificador automático de distúrbios é chamado de Rede Neuro-Fuzzy-Wavelet (RNFW). Neste artigo, os vetores serão representados por linha, que é a forma padrão empregado nas redes neural ART-descendentes (Carpenter e Grossberg, 1992).

1 Metodologia

A estrutura básica da RNFW é composta por três módulos principais: o módulo de detecção de anomalias (distúrbios), o módulo de extração de características onde as formas de onda são analisadas através do cálculo da Transformada Wavelet Discreta (TWD), Análise Multirresolução (AMR) e Norma Entropia (NE). O módulo de classificação de distúrbios que conta com uma rede neural ARTMAP Fuzzy que indica qual o tipo de anomalia presente no sinal. Tal estrutura é mostrada na Figura 1.

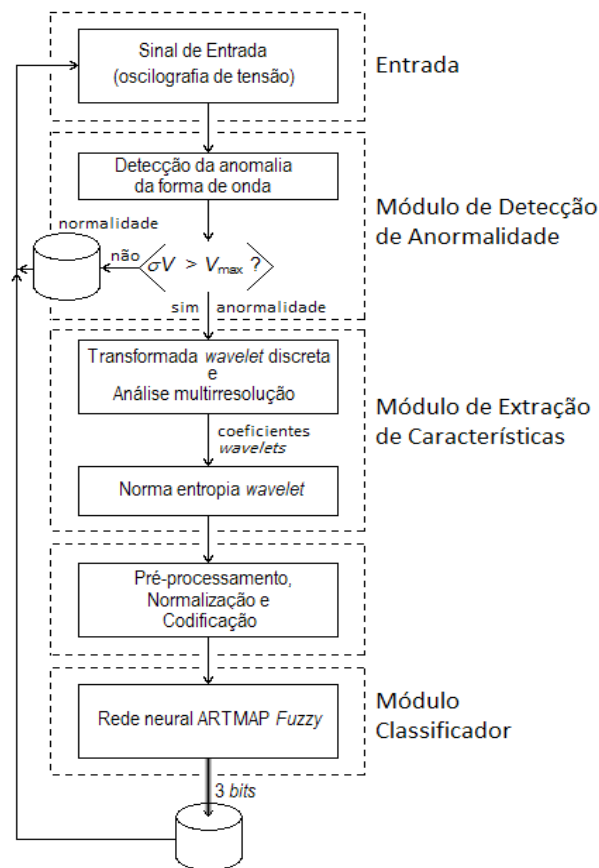


Figura 1. Estrutura da RNFW.

O processo de funcionamento da rede se resume na leitura do sinal de entrada passando pelo módulo de detecção de anomalias. Se for detectado algum distúrbio, será realizado o cálculo dos coeficientes *wavelet* e suas respectivas médias de entropia, resultando em um vetor que contém características próprias do distúrbio (assinaturas). Este vetor resultante é utilizado como entrada do módulo de classificação após ser pré-processado, via processo de normalização e codificação, visando colocá-lo num formato adequado para a rede neural ARTMAP Fuzzy. Esta rede, então, fará a classificação do tipo de anomalia que o sinal de entrada sofreu de forma rápida e precisa (camada de saída). Para representar as anomalias consideradas, neste artigo (*sag*, *swell*, *outage*, etc.), usa-se a codificação binária de 3 bits, conforme Tabela 1.

1.1 Módulo de Detecção

A forma de onda de tensão é constantemente analisada a fim de se detectar algum tipo de anormalidade na rede. Esse processo é realizado inferindo-se, de maneira aproximada, a amplitude da tensão da forma de onda (Figura 2), baseado no modelo de inferência de corrente proposto por Al-Jufout (Al-Jufout, 2006).

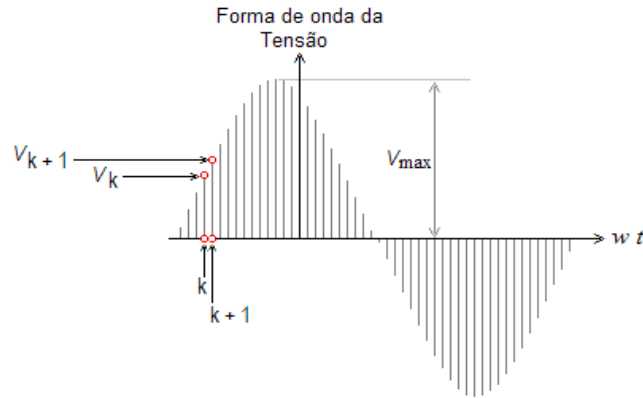


Figura 2 - Forma de onda senoidal de tensão discretizada, considerando-se uma taxa de amostragem m .

A amplitude máxima da tensão pode ser obtida através da equação:

$$V_{\max} = \left| \frac{V_k}{\text{sen} \left[\tan^{-1}(\Phi) \right]} \right| \quad (1)$$

sendo:

$$\Phi = \frac{V_k \text{sen} (w\Delta t)}{V_{k+1} - V_k \text{cos} (w\Delta t)} ;$$

onde:

$$\Delta t = t_{k+1} - t_k ;$$

w : velocidade da onda = $2 \pi f$;

k : tempo discreto;

f : frequência (Hz).

Assim, deve-se calcular os valores de V_{\max} , usando-se a equação (1), para $i = 1, 2, \dots, L$, sendo L um número arbitrado considerando-se as amostragens de interesse (e.g., 5 vezes em 1 ciclo). Assim, tem-se:

$$V_{\text{med}} = \frac{\sum_{i=1}^L V_{\max}^i}{\sqrt{2} L} \quad (2)$$

e

$$\sigma V = \left| V_{\text{med}} - V_{\text{referência}} \right| \quad (3)$$

sendo:

V_{\max}^i = valor de V_{\max} calculado a partir da equação (1) baseando-se na onda de tensão (Figura 1);

V_{med} = média aritmética dos L valores eficazes da forma de onda de tensão;

$V_{\text{referência}}$ = valor eficaz de referência correspondente à tensão nominal;

σV = índice de normalidade de tensão da forma de onda.

As L estimativas de V_{\max} são adotadas visando reduzir a imprecisão de V_{med} , isto porque as medidas das tensões podem conter ruído. Assim, pode-se definir que para uma forma de onda perfeitamente senoidal, o valor da amplitude calculada usando-se a equação (1) é exatamente igual à tensão nominal. Porém, quando houver qualquer anormalidade na tensão, haverá um reflexo na amplitude, ou seja, uma discrepância em relação ao valor real ($V_{\text{referência}}$). Desse modo, adaptando-se as equações (2) e (3), obtém-se o resultado da normalidade do sinal traduzido no seguinte critério:

- Se $\sigma V \neq \Delta V_{\max}$, indica a existência de anormalidade na tensão;
- Se $\sigma V = \Delta V_{\max}$, indica que não existe anormalidade relevante na tensão.

Sendo:

σV = valor calculado através da equação (3) e tomando-se $V_{\text{referência}}$ como sendo a tensão nominal eficaz;

ΔV_{\max} = parâmetro empírico, nesta pesquisa foi utilizado, para estes tipos de distúrbios, o valor 0.29.

1.2 Módulo de Extração de Características

A extração de características do sinal ajuda a distinguir um tipo de anomalia de outro. É a chave para o reconhecimento de padrões, sendo o componente mais importante no desenvolvimento de sistemas de classificação inteligentes, acarretando que o melhor classificador tenha baixo desempenho se as características não forem bem escolhidas.

Nesse módulo, depois de determinado que o sinal de entrada contém algum tipo de anomalia, o mesmo é decomposto e, assim, obtido os coeficientes *wavelets* através da análise multirresolução. Desses coeficientes são calculadas as médias entropiadas *wavelet* (WEN), o que resultará em um vetor contendo as características que identificam cada distúrbio.

A decomposição *wavelet* do sinal é realizada por 12 níveis utilizando-se o filtro Daubechies de quarta ordem (*db4*) gerando os níveis de detalhe (d_1, d_2, \dots, d_{12}) que contém os coeficientes de baixa frequência e o nível de aproximação (a_{12}) com os coeficientes de alta frequência através da AMR.

Entropia é um conceito comum a várias áreas. Em termodinâmica, entropia é uma medida para quantificar o grau de desequilíbrio do estado do sistema. Em matemática, a entropia é usada para medir a incerteza de problemas. Enquanto na Ciência da Informação, entropia é a média da incerteza da fonte de informação. Assim, pode-se dizer que a entropia é uma medida de irregularidades de estados como o desequilíbrio, incerteza. Como um método para medir, a entropia aparece como uma ferramenta ideal para quantificar a ordenação dos sinais não-estacionários [Zhang et al., 2004].

A norma entropia de um sinal com distúrbio $u_j, \vec{j}=1,2, \dots, N$, pode ser obtida por:

$$NE = \sum_{j=1}^N |U_j|^P \quad (4)$$

Sendo:

j = pontos do sinal U ;

P = é o nível de energia com variação de $1 \leq P \leq 2$.

Os valores da norma entropia para coeficientes de detalhe e aproximação obtidos em cada nível de decomposição a partir da TWD e AMR de diferentes distúrbios são calculados para extração de características importantes, resultando em um nú-

mero real. As características extraídas desse processo permitem distinguir um tipo de distúrbio dos demais e podem ser calculados por

$$Wd_j = \frac{1}{N_j} \sum_n |d_j[n]|^P, \quad Wa_j = \frac{1}{N_j} \sum_n |a_j[n]|^P, \quad j = 1, 2, \dots, H \quad (5)$$

Que podem ser representadas como

$$W_{\text{sinal}} = [Wd_1 \dots Wd_H \quad Wa_H], \quad (6)$$

sendo

H : número total de níveis de decomposição;

d_H : é último nível do coeficiente detalhe;

a_H : é último nível do coeficiente aproximação.

O vetor da norma entropia *wavelet* que representa as características normalizadas de cada nível de decomposição ($d_1, \dots, d_{12}, a_{12}$), de cada sinal, é identificado por:

$$\Delta W_{\text{sinal}} = [Wd_1 \dots, Wd_{12} \quad Wa_{12}] \quad (7)$$

sendo que:

Wd_1 : média entropia do coeficiente detalhe do primeiro nível;

Wd_{12} : média entropia do último nível de detalhe;

Wa_{12} : média entropia do último nível de aproximação.

Como nos distúrbios, no contexto da QE, o valor da norma entropia é muito semelhante em alguns distúrbios como nos casos de *sag* e *outage*, então, um sinal puro é usado como referência para distinguir esses distúrbios entre si. Assim, o vetor que representa a *WEN* será dado por:

$$\Delta WEN = \Delta W_{\text{sinal}} - \Delta W_{\text{sinal puro}} \quad (8)$$

Onde o vetor que representa as características *wavelets* normalizadas do sinal puro $\Delta W_{\text{sinal puro}}$, utilizando-se a equação (7), pode ser representado por:

$$\Delta W_{\text{sinal puro}} = [Wdsp_1 \dots Wdsp_{12} \quad Wasp_{12}] \quad (9)$$

Assim, o vetor da norma entropia *wavelet* (ΔWEN) que representa a característica de cada distúrbio é usado como entrada do módulo de classificação.

2 Rede Neural ARTMAP Fuzzy

A rede neural ARTMAP Fuzzy (Carpenter et al., 1992) é uma rede supervisionada, ou seja, o treinamento é realizado baseado em estímulos de entrada e de saída. É composta por dois módulos ART Fuzzy: ART_a e ART_b interconectados através de módulo de memória associativa inter-ART, F^{ab}, que possui um mecanismo auto-regulador denominado *match tracking*. Este mecanismo possui a incumbência de realizar o “casamento” entre a entrada e a saída da rede neural.

2.1. Módulo ART Fuzzy

Na rede neural ART os dados de entrada são denotados pelo vetor $a = [a_1 \cdots a_M]$ M -dimensional, normalizado da seguinte forma:

$$\bar{a} = \frac{a}{|a|} \quad (10)$$

sendo:

\bar{a} : vetor de entrada normalizado;

$$|a| = \sum_i a_i \quad (11)$$

O vetor de entrada será um vetor $2M$ -dimensional, denotado por:

$$I = [\bar{a} \ \bar{a}^c] \equiv [\bar{a}_1 \dots \bar{a}_M \ \bar{a}_1^c \dots \bar{a}_M^c] \quad (12)$$

sendo que:

$$\bar{a}^c = \bar{a}_i^c = 1 - \bar{a}_i .$$

O vetor de atividade (saída) é simbolizado por $y = [y_1 \dots y_N]$, sendo N o número de categorias criadas. Deste modo, tem-se:

$$y = \begin{cases} 1, & \text{se o nó } J \text{ de } F_2 \text{ é ativo.} \\ 0, & \text{caso contrário.} \end{cases} \quad (13)$$

Os parâmetros utilizados no processamento da rede ART Fuzzy são: parâmetro de escolha ($\alpha > 0$), taxa de treinamento ($\beta \in [0,1]$) e parâmetro de Vigilância ($\rho \in [0,1]$). Inicialmente, todos os pesos possuem valor igual a 1, indicando assim, que não existe nenhuma categoria ativa.

O vetor de entrada da rede ART_a é representado pelo vetor $a = [a_1 \dots a_{M_a}]$, M_a -dimensional, e o vetor de entrada da rede ART_b (que corresponde à saída desejada, referente ao padrão de entrada da rede ART_a) é representado pelo vetor $b = [b_1 \dots b_{M_b}]$ M_b -dimensional (Carpenter et al., 1992).

Os parâmetros usados na rede ARTMAP Fuzzy são os mesmos usados na rede ART Fuzzy. A diferença da rede neural ART Fuzzy é o parâmetro de vigilância do módulo inter-ART, ρ_{ab} ($\rho_{ab} \in [0,1]$).

A rede ARTMAP realiza o processamento de duas redes ART (ART_a e ART_b), sendo que após a ressonância ser confirmada em cada módulo ART, tem-se:

- J : categoria ativa para a rede ART_a;
- K : categoria ativa para a rede ART_b.

Através do processo *match tracking* verifica-se se a categoria ativa no ART_a corresponde ao vetor de saída desejada apresentado no ART_b. O critério de vigilância é dado por (Carpenter et al., 1992):

$$\frac{|y^b \wedge w_{jk}^{ab}|}{|y^b|} \geq \rho_{ab} \quad (14)$$

sendo:

$$y^b = \text{vetor saída do ART}_b \text{ (padrão de atividade } F_2^b \text{)}.$$

Se (14) não for satisfeita, é feito um incremento mínimo no parâmetro de vigilância ART_a, suficiente apenas para excluir a atual categoria e selecionar outra categoria, que se tornará ativa e entrará novamente no processo até que a equação (14) seja obedecida. Com a ressonância confirmada, os pesos dos módulos ART_a e ART_b, são atualizados utilizando o mesmo critério da rede neural ART nebulosa. A adaptação para o módulo inter-ART é efetuada da seguinte forma:

$$w_{jk}^{ab} = 0, \text{ para } k \neq K$$

$$w_{jk}^{ab} = 1, \text{ para } k = K$$

3 Estímulos de Entrada-Saída da Rede Neural ARTMAP Fuzzy

Os vetores de entrada e de saída devem ser pré-processados, normalizados e codificados visando atender a formatação exigida pela rede neural ARTMAP Fuzzy, ou seja, o valor de cada componente de tais vetores deve atender o intervalo [0, 1].

Assim, os vetores de entrada \bar{a} podem ser expressos por:

$$\bar{a} = [\mathbf{A} \ \mathbf{\Omega}] \quad (15)$$

Sendo:

$$\mathbf{A} = [\lambda_1 \ \lambda_2 \ \dots \ \lambda_M];$$

$$\lambda_i = \left| \frac{WEN_i}{WEN_{max}} \right|;$$

$$WEN_{max} = \max\{|WEN_1| \ |WEN_2| \ \dots \ |WEN_M|\}.$$

e:

$$\mathbf{\Omega} = [0 \ \dots \ 1 \ \dots \ 0] \text{ (codificação binária)}.$$

Os componentes de $\mathbf{\Omega}$ são assim definidos:

- se $sgn(WEN_i)$ for “-”, então, $\Omega_i = 0$;
- se $sgn(WEN_i)$ for “+”, então, $\Omega_i = 1$;

sendo:

$$sgn = \text{função sinal.}$$

Os vetores de saída \bar{b} , codificação binária em 3 bits, são definidos na Tabela 1.

Tabela 1. Codificação binária dos vetores de saída da rede neural.

Sinal de Entrada	Classe	Vetor de Saída \bar{b}
Sinal Puro	S_1	–
<i>Sag</i>	S_2	[0 0 1]
<i>Swell</i>	S_3	[0 1 0]
<i>Outage</i>	S_4	[0 1 1]
Harmônico	S_5	[1 0 0]
Harmônico e <i>Sag</i>	S_6	[1 0 1]
Harmônico e <i>Swell</i>	S_7	[1 1 1]

O sinal puro é identificado no “Módulo de Detecção de Anormalidade”, ou seja, quando $\sigma V \neq \Delta V_{\max}$.

4 Fase de treinamento

O treinamento da rede neural é realizado considerando-se dados gerados a partir de duas fontes:

1. Usando-se o modelo, de sinais de tensões com distúrbios, proposto por Abdel-Galil et al. (2005). Trata-se de um modelo que, por meio da variação de poucos parâmetros, é possível gerar uma grande variedade de sinais de tensão com distúrbio;

2. Via simulação usando o aplicativo ATP. Este procedimento é bastante importante para a fase treinamento, pois podem-se gerar casos mais realistas.

Neste artigo, preliminarmente, usou-se a fonte descrita no item 1 como forma de testar a metodologia proposta. Na sequência da pesquisa, a base de dados será complementada com outras simulações.

5 Experimento

As formas de ondas dos sinais puros e com distúrbios foram geradas por um algoritmo desenvolvido no programa *MATLAB*. A vantagem na geração dessas ondas é enorme em relação a outros métodos como a utilização de uma base de dados de distúrbios. Pois é perfeitamente possível selecionar quantos e quais os melhores dados (forma de onda e coeficientes) que irão representar um tipo de sinal. Os dados de entrada da RNFV serão gerados baseados no modelo de equação de Abdel-Galil et al. (2005) e He et al. (2006), onde sete classes (S_1 a S_7) identificam os diferentes tipos de sinal com distúrbios de QE a serem analisados (*sag*, *swell*, *outage*, harmônico, harmônico com *sag* e harmônico com *swell*) e também o sinal puro.

No algoritmo desenvolvido é plausível a seleção das melhores formas de ondas sendo possível a escolha do tipo de onda a ser gerada, ou seja, variação entre as 7 classes (S_1 a S_7), variação nos distúrbios, tais como a definição da amplitude entre 0.1 até 0.9 pu para *sag* e entre 0.1 até 0.8 pu para *swell* além do tempo de suas respectivas durações em ciclos.

Das formas de ondas geradas, foram utilizadas 200 das melhores amostras para treinamento da rede e outras 200 para a fase de testes. As amostras possuem 256 pontos/ciclo e frequência nominal de 60 Hz, que é o padrão brasileiro, com isso, é possível o cálculo de até a 127ª ordem dos harmônicos.

Para efeitos didáticos, nessa pesquisa, foram consideradas as harmônicas fundamentais, as de 3ª, 5ª e 7ª ordem; e para a combinação dos distúrbios “*sag* e harmônico” e “*swell* e harmônico” foi considerado até o harmônico de 5ª ordem.

No módulo de detecção, foram testadas, outras taxas de amostragens (maiores e menores), porém observou-se que a taxa de amostragem utilizada (cinco amostras/ciclo) é a mais eficiente, evidenciando que a metodologia proposta é robusta neste sentido.

No cálculo da *TWD*, *AMR* e da *WEN* também foi utilizado o programa *MATLAB* (*wavelet toolbox*). Cada um dos sinais escolhido foi decomposto com o filtro *Wavelet Daubechies (db4)* por 12 níveis. Então, baseado nas características extraídas através da equação (8), um conjunto de 13 componentes de características é obtido. Porém, como muitos dos coeficientes de decomposição apresentam características semelhantes em todos os tipos de distúrbios, definiu-se que os vetores característicos dos distúrbios (ΔWEN), de cada sinal, apenas com os valores da *WEN* dos coeficientes d_5 , d_6 , d_7 , d_8 e a_{12} , resultando em um vetor com 5 componentes. Essa dimensão descreve diferentes características resultantes da *TWD*.

O tamanho total do conjunto entrada é 5×1.400 , sendo 5 a quantidade dos coeficientes de decomposição referentes aos detalhes (d_1, \dots, d_8), mais o de aproximação (a_{12}) enquanto que 1.400 são os 200 casos de cada uma das 7 classes de distúrbio.

A arquitetura ARTMAP *Fuzzy*, além da obtenção de respostas rápidas e precisas, permite que se formatem os dados de entrada e de saída para conter a maior diversidade possível. Contendo, assim, uma estrutura com capacidade de realizar análise de sinais considerando-se um grande número de distúrbios de tensão.

6 Conclusão

Nessa pesquisa é proposto um modelo moderno e eficiente de classificador automático de anomalias de tensão através de uma RNFV. A principal vantagem desse método é a redução do tamanho dos dados a serem analisados, a descoberta das principais características do sinal sem perder as características do sinal original, a redução do espaço alocado em memória, já que serão analisados apenas os sinais comprovadamente com distúrbio e a pequena necessidade de pré-processamento, que propiciam um rápido resultado ao problema. Mencionando, ainda, a absoluta eficiência na classificação das anomalias, com 100% de acerto nos testes realizados, ínfimo tempo despendido com o treinamento da rede e a alta velocidade de processamento, inerentes ao uso do algoritmo ARTMAP *Fuzzy*. Os resultados dos testes apontam para o enorme potencial na implementação dessa rede em um sistema de monitoramento de distúrbios. Tratando-se de um assunto de grande relevância no contexto dos sistemas elétricos de potência, tendo em vista a carência de resultados concretos neste sentido.

Assim, a concepção desse sistema de inferência (*neuro-fuzzy-wavelet*) permite realizar a classificação de distúrbios de forma robusta e com grande rapidez na obtenção do resultado, possibilitando sua aplicação em um sistema de tempo real, visto que todo esforço computacional (muito pequeno) é alocado, basicamente, na fase de treinamento. Somente uma pequena parcela de tempo computacional é necessária para a efetivação das análises. Além do mais, a metodologia proposta pode ser estendida para tarefas mais complexas como, por exemplo, a localização das fontes geradoras do distúrbio de tensão.

7 Referências Bibliográficas

- Abdel-Galil, T.K. Kamel, M. Youssef, A.M. El-Saadany, E.F. Salama, M.M.A. (2004) Power quality disturbance classification using the inductive inference approach, IEEE Trans. Power Delivery. 19 (4) 1812–1818.
- Al-Jafout, S. A. (2006). On-line condition-monitoring of electrical power system unbalance, *Internacional Journal of Energy Technology and Policy*, 9p.
- Allen, D.E.; Apostolov, A. And Kreiss, D. (2005). Automated analysis of power system events. *IEEE Power & Energy Magazine*, pp. 48-55.
- Bollen, M. H. J. (2000). *Understanding Power Quality Problems*, Piscataway, NJ, IEEE Press.
- Carpenter, G. A. and Grossberg, S. (1992). A self-organizing neural network for supervised learning, recognition and prediction," *IEEE Com.Magazine*, Vol. 30, No. 9, pp. 38-49.
- Daubechies I. (1992). *Ten lectures on wavelets*. N.York, Academic.
- Haykin, S. (2008). *Neural networks and learning machines*, Prentice Hall, Third Edition.
- He, H. Starzyk, J.A. (2006). A self-organizing learning array system for power quality classification based on wavelet transform, *IEEE Trans. Power Delivery*. 21 (1), pp. 286–295.
- Kezunovic, M. and Abur, A. (2005). Merging the temporal and spatial aspects of data and information for improved power system monitoring applications. *Proceedings of the IEEE*, Vol. 93, No. 11, pp. 1909-1119.
- MATLAB – *The Language of Technical Computing*, Version 7.2.
- Zhang, G. Rong, H. He, L. Jin, W. (2004). Entropy feature extraction approach for radar emitter signals, *Int. Conference on Intelligent Mechatronics and Automation*, pp. 621–625.