

MODELO FUZZY EVOLUTIVO PARA DETECÇÃO E CLASSIFICAÇÃO EM TEMPO REAL DE DISTÚRBIOS NA QUALIDADE DE ENERGIA ELÉTRICA

EVOLVING FUZZY MODEL FOR REAL-TIME DETECTION AND CLASSIFICATION OF POWER QUALITY DISTURBANCES

Márcio Wladimir Santana¹; Danielle Abreu Fortunato²; Danton Diego Ferreira³

- 1 Mestre em Engenharia de Sistemas e Automação. UFLA, 2017. Professor do Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG. Nepomuceno, MG. marciosantana@cefetmg.br.
- 2 Graduada de bacharelado em Engenharia Elétrica. Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG. Nepomuceno, MG. danielle.afortunato@gmail.com.
- 3 Doutor em Engenharia Elétrica. UFRJ-RJ, 2010. Professor Adjunto na Universidade Federal de Lavras - UFLA, Lavras, MG. danton@deg.ufla.br.

Recebido em 03/07/2018; Aceito em 26/12/2018; Publicado em 28/12/2018

RESUMO: Os distúrbios de qualidade de energia elétrica levam a vários inconvenientes, como um aumento da tensão no sistema e nos equipamentos e consequentes perdas; limitação da capacidade de produção; temperaturas operacionais mais altas, falhas prematuras e redução da expectativa de vida das máquinas; mau funcionamento do equipamento e interrupções não planejadas. A detecção e classificação em tempo real de distúrbios são de grande importância para os sistemas de energia. Este artigo propõe o modelo fuzzy evolutivo Takagi-Sugeno (eTS) para a detecção de distúrbios combinado com um método híbrido de seleção de características utilizando o filtro Hodrick-Prescott e a Transformada Rápida de Fourier aplicados sobre uma janela deslizante de sinais de tensão. Os distúrbios spike, notch, inter-harmônico, interrupção curta e harmônico foram considerados. O desempenho de classificação em termos da raiz quadrada do erro quadrático médio (RMSE) e do índice de erro não dimensional (NDEI) mostrou resultados encorajadores. Além disso, o sistema de monitoramento de distúrbios eTS proposto, baseado em fluxo de dados, mostrou ser capaz de aprender novos padrões de distúrbios automaticamente pela adaptação on-line dos parâmetros e estrutura das regras fuzzy.

PALAVRAS-CHAVE: Qualidade de energia. Classificação de distúrbios. Takagi-Sugeno evolutivo. Detecção em tempo real.

ABSTRACT: Power quality disturbances lead to several drawbacks such as an increase in line and equipment voltage and consequent ohmic losses; limitation of the production capacity; higher operating temperatures, premature fails, and reduction of life expectancy of machines; malfunction of equipment; and unplanned outages. Real-time detection and classification of disturbances are of great importance for power systems. This paper proposes an evolving Takagi-Sugeno fuzzy model (eTS) framework for disturbance detection combined with a hybrid Hodrick-Prescott and Fast Fourier Transform feature selection method applied over a sliding window of voltage signals. The spike, notch, inter-harmonic, short interruption and harmonic disturbances were considered. Classification performance in terms of the root mean squared error (RMSE) and non-dimensional error index (NDEI) have shown encouraging results. Moreover, the proposed data stream-based eTS disturbance monitoring system has shown to be able to learn new disturbance patterns automatically by online adapting the parameters and structure of fuzzy rules.

KEYWORDS: Power quality. Disturbance classification. Evolving Takagi-Sugeno. Real time detection.

1 INTRODUÇÃO

O problema de detecção e classificação de distúrbios de qualidade de energia elétrica (QEE) tem sido considerado um problema difícil pelas comunidades de Aprendizado de Máquina, Inteligência Computacional e Reconhecimento de Padrões devido a vários fatores. Primeiramente, há um grande número de variáveis envolvidas e estas podem, potencialmente, carregar informações importantes com relação aos distúrbios. É impossível monitorar todas as possibilidades. Métodos para obtenção de atributos importantes devem ser considerados. Entretanto, em monitoramento *online* de sistemas elétricos é frequente o aparecimento de situações novas. Essas situações surgem devido à variância temporal dos sinais envolvidos e/ou sobreposição de diferentes tipos de distúrbios. Algoritmos de detecção e classificação de distúrbios devem ser aptos a lidar com a ocorrência de novidades nos padrões dos dados. Novidades devem ser detectadas e armazenadas em modelos auto ajustáveis em modo *online* (LUGHOFER; ANGELOV, 2011; LEITE *et al.*, 2016; LEITE; COSTA; GOMIDE, 2009; SILVA *et al.*, 2018).

A quantidade de dados e amostras é grande. Dessa forma, por vezes, é inviável armazená-las em bases de dados para, posteriormente, empregar algoritmos e modelos convencionais, isto é, algoritmos baseados em análises estatísticas convencionais ou modelos inteligentes estáticos, pré-treinados em modo *offline*. Outra questão que dificulta o desenvolvimento de sistemas de monitoramento da qualidade de energia baseados em métodos estatísticos e métodos de inteligência computacional é o surgimento de condições de operação/distúrbios não previstas.

Uma frente de pesquisa em classificação *online* de dados sequenciais (fluxos de dados), como aqueles encontrados nos sistemas elétricos descritos

anteriormente, é denominada Sistemas Inteligentes Evolutivos (LUGHOFER, 2011; GOMIDE; PEDRYCZ, 2007). Nesse contexto, algoritmos incrementais de agrupamento, especialmente algoritmos *fuzzy*, são usados para construção de modelos classificadores capazes de, a partir de dados de entrada adquiridos em modo *online* e muitas vezes em tempo real, determinar gradualmente tanto a sua estrutura quanto seus parâmetros (ANGELOV; KASABOV, 2007; ANGELOV, 2002). É visível que o desenvolvimento e uso de sistemas inteligentes evolutivos tem crescido nos últimos anos. Muitos trabalhos na literatura apresentam aplicações bem-sucedidas de tais sistemas em problemas complexos do mundo real envolvendo modelagem, controle, classificação ou previsão (LEITE; COSTA; GOMIDE, 2009; BOUCHACHIA, 2010). Sistemas *fuzzy* evolutivos possuem vantagens sobre abordagens de modelagem diversas, e inclusive sobre redes neurais evolutivas, por serem linguisticamente interpretáveis. O aspecto *fuzzy* torna possível a extração de informação da estrutura do modelo na forma de grânulos de informação e termos linguísticos (GOMIDE; PEDRYCZ, 2007)

Atualmente é importante considerar o aumento das *smart grids* (redes inteligentes de energia) em nosso sistema elétrico de potência. As *smart grids* são uma nova arquitetura de distribuição de energia elétrica, mais segura e inteligente, que integra e possibilita ações a todos os usuários a ela conectados. A partir desse novo conceito de geração e consumo de energia elétrica podem surgir distúrbios de QEE não previstos. Modelos de detecção e classificação evolutivos são capazes de identificar novos distúrbios, pois sua base de regras ou estrutura conexionista evolui de acordo com o fluxo de dados.

O objetivo deste trabalho é apresentar o modelo inteligente *fuzzy* evolutivo do tipo Takagi-Sugeno (eTS - *evolving Takagi-Sugeno*), que pela primeira vez é

empregado neste contexto, como proposta de solução para os problemas de detecção e classificação de distúrbios em sinais de tensão. Modelos são muito importantes quanto à questão da QEE já que auxilia na tomada de decisões e possivelmente possibilitam a implementação de contramedidas, em geral, medidas de controle. Portanto, as contribuições deste trabalho são detectar e classificar distúrbios na rede elétrica em tempo real. Esse processo deve acontecer em modo *online*, em tempo real, e deve apresentar boa precisão e baixo custo computacional (FERREIRA, 2010; NAGATA *et al.*, 2018; RIBEIRO *et al.*, 2018).

2 MATERIAIS E MÉTODOS

Esta seção apresenta uma nova abordagem para obtenção de variáveis indicadoras da ocorrência de distúrbios em sinais de tensão. Essencialmente, considera-se o filtro de Hodrick-Prescott (HP) aplicado sobre uma janela deslizante. O filtro HP é pela primeira vez empregado na decomposição de sinais de tensão para extração de características de distúrbios de QEE. Para extração de características serão considerados também a Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*) e o valor eficaz da tensão.

2.1 FILTRO DE HODRICK-PRESCOTT

O filtro HP decompõe um sinal em suas componentes de tendência e cíclica/aleatória. Em essência, removem-se as flutuações de baixa frequência de sinais ou séries. A hipótese é que, nessa separação de componentes, as componentes de baixa frequência representam a tendência de longo prazo, e as componentes de alta frequência representam os fenômenos mais rápidos e/ou aleatórios (HODRICK; PRESCOTT, 1997).

O filtro HP busca extrair a tendência, que é considerada estocástica, mas com variações suaves

ao longo do tempo e não correlacionadas com o ciclo, através da minimização com respeito à τ_t do funcional (Equação 1)

$$J = \sum_{n=1}^N c_t^2 + \lambda \sum_{n=3}^N (\Delta^2 \tau_t)^2, \quad (1)$$

em que $c_t \triangleq y_t - \tau_t$; e $\Delta^2 \triangleq (1 - L)^2$; L é operador defasagem, e.g., $Lx_t = x_{t-1}$; N é a quantidade de amostras de dados em questão; e λ é um parâmetro que penaliza a variabilidade da tendência.

O parâmetro λ é o parâmetro de suavidade com o qual se controla a aceleração da componente de tendência, isto é, a variação da taxa de crescimento da componente de tendência. O primeiro termo da Equação 1 é a soma dos desvios da série com respeito à tendência ao quadrado, e é uma medida do grau de ajuste. O segundo termo é a soma dos quadrados das segundas diferenças das componentes de tendência, e é uma medida do grau de suavidade.

2.2 TRANSFORMADA RÁPIDA DE FOURIER

A Transformada de Fourier é uma das ferramentas mais utilizadas na análise de sinais no domínio da frequência. Existem duas abordagens quando é necessária a análise do espectro de frequências: a análise é feita de posse da função analítica e contínua e somente se dispõe dos dados coletados em medições, isto é, uma função discreta. Para esses casos, pode-se utilizar a Transformada de Fourier Contínua e Discreta, respectivamente. As Equações 2 e 3 representam as definições clássicas da Transformada de Fourier Contínua e sua inversa. Já as Equações 4 e 5 representam as definições da Transformada de Fourier Discreta e sua inversa (GAO; YAN, 2011).

$$F(j\omega) = \int_0^{\infty} f(t) e^{-j\omega t} dt \quad (2)$$

$$F(j\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(j\omega) e^{j\omega t} d\omega \quad (3)$$

$$TFD(f_n) = \frac{1}{N} \sum_{k=0}^{N-1} x_k e^{-j2\pi f_n k \Delta t} \quad (4)$$

$$x_k = \frac{1}{\Delta t} \sum_{f_n=0}^{(1-N)/T} TFD(f_n) e^{j2\pi f_n k \Delta t} \quad (5)$$

nas quais ω é a frequência angular, x_k é o sinal discreto, T é o intervalo de tempo total medido, ΔT corresponde aos intervalos discretos de tempo, $N=T/\Delta T$ é o número de amostras e $f_n = n/T$, $n = 0, 1, 2, \dots, N-1$ são as componentes discretas de frequência.

2.3 VALOR EFICAZ DA TENSÃO

A raiz do valor quadrático médio (RMS - *root mean square*) ou valor eficaz é uma medida estatística da magnitude de uma quantidade variável. O valor pode ser calculado para uma série de valores discretos ou para uma função variável contínua. O nome deriva do fato de que é a raiz quadrada da média aritmética dos quadrados dos valores. O valor eficaz para uma coleção de N valores $\{x_1, x_2, \dots, x_N\}$ é dado pela Equação 6.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2} \quad (6)$$

Para uma função variável contínua $f(t)$ definida no intervalo $T_1 \leq t \leq T_2$ o RMS é dado pela Equação 7.

$$x_{RMS} = \sqrt{\frac{1}{T_2 - T_1} \int_{T_1}^{T_2} [f(t)]^2 dt} \quad (7)$$

3 SISTEMAS INTELIGENTES EVOLUTIVOS

Mais recentemente, pesquisadores do campo de Inteligência Computacional perceberam que as

soluções de problemas complexos em tempo real exigiam um aspecto dos sistemas inteligentes ainda não explorado: a adaptabilidade. Com tal característica, os sistemas inteligentes seriam capazes de resolver problemas em ambientes dinâmicos, e não estacionários, como os tipicamente encontrados no mundo real. Por exemplo, sistemas encontrados na indústria, nos campos militar, aeroespacial, médico, social, biológico, meteorológico, entre outros, estão continuamente sujeitos a mudanças.

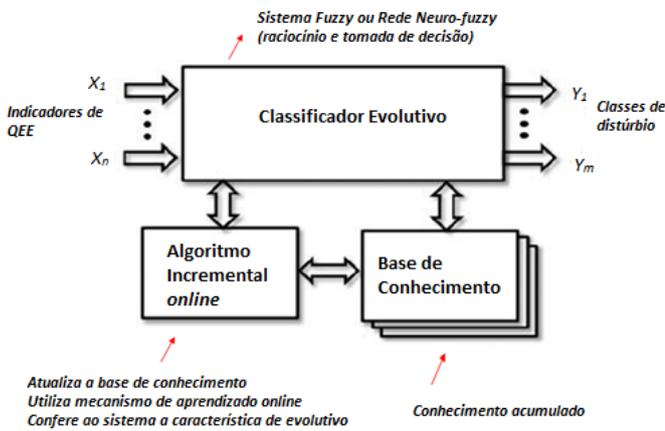
Sistemas inteligentes evolutivos surgiram exatamente com o propósito de equipar modelos neurais, *fuzzy* e *neuro-fuzzy* de procedimentos de adaptação de parâmetros e de flexibilidade estrutural, tal que os modelos fossem capazes de acompanhar variações de sistemas físicos. Um aspecto importante de sistemas inteligentes evolutivos é que há diferentes abordagens teóricas e práticas que podem ser utilizadas para a sua implementação, tais como os sistemas baseados em redes neurais artificiais, em regras *fuzzy*, em agentes inteligentes ou ainda sistemas híbridos (ANGELOV, 2002; LEITE; COSTA; GOMIDE, 2009). Independentemente da abordagem a ser utilizada, as principais características de modelos evolutivos são:

1. A sua estrutura não é fixa e não é definida a *priori*: ela se desenvolve (expande ou retrai) naturalmente à medida que o sistema evolui;
2. Os seus parâmetros são ajustados conforme o sistema se desenvolve;
3. O seu funcionamento é contínuo, ocorrendo aprendizado em modo *online* e, muitas vezes, em tempo real.

A Figura 1 ilustra de forma genérica o esquema de um sistema evolutivo utilizado para classificação de distúrbios de QEE. O principal componente da estrutura é o sistema inteligente. O sistema é responsável pelas tarefas de raciocínio e tomada de

decisão. Essas tarefas são realizadas a partir dos dados de entrada e utilizando o conhecimento acumulado na base de conhecimento. Para atualizar a base de conhecimento, é utilizado um mecanismo de aprendizado *online*, o que confere ao sistema a característica de evolutivo e capacidade de resolver novos problemas.

Figura 1 - Esquema de um sistema inteligente evolutivo



Fonte - Próprio autor.

Pode-se afirmar que os principais objetivos a serem alcançados na implementação de sistemas evolutivos são o aprendizado contínuo, a capacidade de auto-adaptação e auto-organização (evolução da estrutura do sistema) de forma que tais sistemas possam se adaptar a ambientes dinâmicos, não estacionários, complexos e/ou desconhecidos.

3.1 SISTEMA FUZZY EVOLUTIVO DO TIPO

TADAKI-SUGENO

Sistemas *fuzzy* evolutivos (eFS, *evolving Fuzzy Systems*) (ANGELOV; KASABOV, 2007; LEITE, 2012) são sistemas adaptativos que modificam tanto sua estrutura como seus parâmetros, conforme um fluxo de dados é processado, ou seja, a base de regras de

um sistema *fuzzy* evolutivo pode ser reduzida ou expandida de modo a refletir a situação atual do processo ou fenômeno que gera os dados.

Sistemas *fuzzy* evolutivos podem ser vistos como uma combinação de regras de inferência *fuzzy*, um mecanismo para representação e compactação dos dados de entrada e um método incremental de aprendizado de máquina (KASABOV, 2007). Sistemas *fuzzy* evolutivos surgiram em razão da necessidade de abordagens de modelagem computacional que levassem em conta a complexidade, incerteza e variância temporal de sistemas físicos. No cenário atual, dados são obtidos em grandes quantidades, dinamicamente e usualmente são apresentados na forma de um fluxo (ANGELOV; KASABOV, 2007). Para processar esses dados, novas metodologias foram propostas, principalmente, na linha modelagem *fuzzy* funcional do tipo Takagi-Sugeno (eTS). Essas metodologias são, fundamentalmente, capazes de extrair parâmetros e determinar a estrutura de modelos *fuzzy* autonomamente, a partir dos dados, em tempo real (KASABOV, 1998; GOMIDE; PEDRYCZ, 2007).

A estrutura do modelo eTS é flexível, ou seja, a cada novo dado de entrada deve-se decidir como a base de regras é atualizada, ajustando o número de regras e os parâmetros dos antecedentes conforme o caso (ANGELOV, 2002). Um modelo eTS é formado por um conjunto de regras do tipo Se-Então, semelhante ao modelo homólogo não evolutivo, da seguinte forma:

$$R_i : \text{SE } x_1 \text{ é } A_{i1} \text{ E } \dots \text{ E } x_m \text{ é } A_{im} \text{ ENTÃO } y_i \\ = a_{i0} + a_{i1}x_1 + \dots + a_{im}x_m$$

em que R_i é a i -ésima regra *fuzzy*, $i = 1, \dots, g^k$; g^k é o número de regras na iteração k ; x_j ; $j = 1, \dots, m$ são as m variáveis de entrada, A_{ij} são os conjuntos *fuzzy* do antecedente, y_i é a saída do modelo linear presente no conseqüente e a_{ij} os parâmetros do modelo linear da regra i .

Em cada regra R_i descrevem-se comportamentos locais do conjunto de dados de entrada, aproximando estes comportamentos por modelos lineares. Um sistema não linear é formado pela agregação das contribuições dos modelos lineares, que fazem parte dos consequentes das regras (ANGELOV; FILEV, 2004). O grau de ativação de cada regra pondera a participação que o modelo linear local terá na saída global. Os antecedentes das regras *fuzzy* são definidos por funções de pertinência Gaussianas, conforme Angelov e Filev (2004), de acordo com a Equação 8.

$$\mu_{ij} = \exp\left(-\frac{4}{r^2} \|x_j - \check{x}_{ij}\|^2\right) \quad (8)$$

sendo r um parâmetro do algoritmo que define o espalhamento da função de pertinência e a zona de influência do modelo presente na regra i , $\|\cdot\|$ a norma euclidiana e \check{x}_{ij} o ponto focal do conjunto *fuzzy*.

O grau de ativação da regra *fuzzy* R_i é definido pela agregação dos graus de pertinência dos dados de entrada nos conjuntos *fuzzy* dos antecedentes desta regra, $\mu_{ij}(x_j)$, como indica a Equação 9.

$$\tau_i = \prod_{j=1}^n \mu_{ij}(x_j) = \mu_{i_1}(x_1) \times \dots \times \mu_{i_n}(x_n), i = 1, \dots, g^k \quad (9)$$

A saída do modelo é definida como a média ponderada da saída de cada regra (Equação 10).

$$y = \sum_{i=1}^{g^k} \lambda_i y_i, \quad (10)$$

em que $\lambda_i = \tau_i / \sum_{j=1}^{g^k} \tau_j$ é o grau de ativação normalizado de cada regra i .

Para atualizar a base de regras, adicionando ou modificando regras eTS existentes, o modelo utiliza-se de um algoritmo de agrupamento recursivo. O agrupamento é realizado, no espaço de entrada-saída, $z = [x^T, y]^T$, e a estrutura do modelo pode ser atualizada a cada iteração. A base do algoritmo de

agrupamento está na ideia de representatividade de cada uma das novas entradas, calculada a partir de um potencial (YAGER; FILEV, 1994).

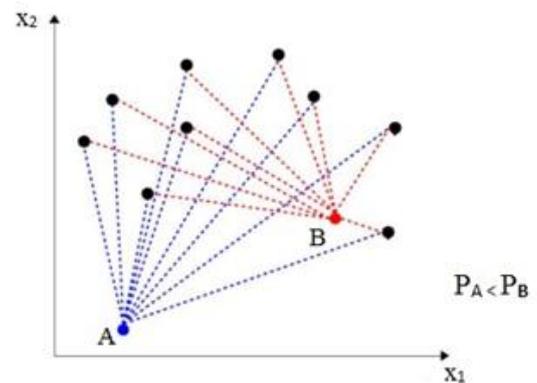
A função potencial de um dado, z^k , depende de todos os outros dados, por meio de uma medida de proximidade como Angelov e Filev (2004), como mostra a Equação 11.

$$P(z^k) = \frac{1}{k-1} \sum_{i=1}^{k-1} \exp(-r \|z^k - z^i\|^2), \quad (11)$$

em que $k = 2, 3, \dots$ o índice dos dados já processados.

A função potencial busca encontrar possíveis dados que definam centro de regiões com concentração de dados. A Figura 2 apresenta a ideia da função potencial, na qual o potencial do dado B, P_B é maior que o potencial de A, P_A . Regiões com maior concentração de dados apresentarão maiores valores de potencial para cada dado, ou seja, a função potencial é inversamente proporcional às distâncias entre os dados.

Figura 2 - Demonstração da função potencial



Fonte - Lemos, 2011.

Calcula-se o potencial de maneira recursiva, como mostra a Equação 12.

$$P^k(z^k) = \frac{k-1}{(k-1)(g^k+1) + \gamma^k - 2v^k}, \quad (12)$$

sendo,

$$\vartheta^k = \sum_{j=1}^{m+1} (z_j^k)^2, \gamma^k = \sum_{i=1}^{k-1} \sum_{j=1}^{m+1} (z_j^i)^2, v^k = \sum_{j=1}^{m+1} z_j^k \beta_j^k, \beta_j^k = \sum_{i=1}^{k-1} z_j^i.$$

Os parâmetros ϑ^k e v^k são computados, a partir de z^k , enquanto β_j^k e γ^k podem ser computados recursivamente (ANGELOV; FILEV, 2004).

Conforme Lemos (2011), o potencial dos centros dos agrupamentos existentes também é calculado de maneira recursiva. Como os potenciais são calculados, utilizando todos os dados disponíveis até o instante k , a cada chegada de um novo dado, os potenciais dos centros, também, mudam. Os potenciais dos grupos são atualizados (Equação 13), de acordo com Angelov e Filev (2004):

$$P^k(\bar{z}_i) = \frac{(k-1)P^{k-1}(\bar{z}_i)}{k-2 + P^{k-1}(\bar{z}_i) + P^{k-1}(\bar{z}_i) \sum_{j=1}^{m+1} d_j^{k(k-1)}}, \quad (13)$$

em que \bar{z}_i é o centro do grupo de l (dimensão $1 \times m + 1$); e $d_j^{k(k-1)} = z_j^k - z_j^{k-1}$.

Adicionalmente, o algoritmo de Mínimos Quadrados Recursivo é usado para ajustar os coeficientes das funções consequentes locais ativadas por um vetor de dados de entrada.

Para a evolução da base de regras, compara-se o valor do potencial do novo dado e dos potenciais dos centros de grupo atualizados. Caso o potencial do novo dado seja maior que o potencial de todos os centros de grupo atualizados, o centro de um grupo será atualizado, ou um novo grupo será criado. Se o novo dado está próximo o suficiente, segundo a distância Euclidiana, de um centro de grupo existente, o novo dado assumirá a condição de centro do grupo. Os limiares são definidos em (ANGELOV; FILEV, 2004). Caso contrário, o novo dado irá originar um novo grupo e será centro deste grupo.

Não satisfazendo nenhuma condição, o novo dado será utilizado para atualizar os parâmetros do consequente da regra relacionada ao grupo com menor distância Euclidiana a ele. É importante notar que, em problemas de classificação, a saída do sistema é uma classe, isto é, um valor constante. Logo não é necessário o ajuste de parâmetros de funções lineares consequentes neste tipo de problema. Não obstante, o algoritmo de agrupamento evolutivo, baseado em potencial, é o mesmo.

4 METODOLOGIA

Esta seção apresenta a metodologia utilizada para a obtenção dos sinais para análise, o sistema de monitoramento proposto e a aplicação dos modelos de seleção de características discutidos na Seção 2.

4.1 OBTENÇÃO DE SINAIS PARA ANÁLISE

Os sinais de tensão foram gerados de forma sintética de acordo com a regulamentação do *Institute of Electrical and Electronics Engineers* (IEEE, 2009). Todos os sinais gerados apresentam frequência fundamental igual a 60 Hz. A frequência de amostragem utilizada foi de 15.360 Hz. Dessa forma, 256 amostras por ciclo são obtidas. Essa taxa de amostragem foi escolhida por ser suficiente para caracterizar a maioria dos distúrbios presentes nos sistemas elétricos. Os sinais sintéticos, gerados computacionalmente pelo *software* Matlab R2011b[®], são contaminados por ruído branco gaussiano, com média nula. O ruído branco foi definido de modo que atenda a relação sinal-ruído (SNR - *signal-to-noise ratio*) desejada, de acordo com a Equação 14.

$$SNR = 20 \log \frac{A}{\sqrt{2}\sigma} [dB] \quad (14)$$

em que A é a amplitude do sinal fundamental e σ é o desvio padrão do ruído.

Na prática, sinais de tensão medidos nos sistemas elétricos possuem relação sinal-ruído (SNR) entre 50 dB e 70 dB (TOMIC; KUSLJEVIC; VUJICIC, 2007). Neste trabalho serão utilizadas relações sinal-ruído 20 dB, 30 dB, 40 dB, 50 dB e 60 dB, a fim de se verificar o comportamento do modelo proposto com a presença de altos níveis de ruído no sinal a ser analisado. Foram gerados 12.000 sinais, variando o número de ciclos da senoide entre um, quatro e dez ciclos, dos quais:

- 2.000 não possuem distúrbios;
- 2.000 possuem distúrbio interrupção curta;
- 2.000 possuem distúrbio inter-harmônico;
- 2.000 possuem distúrbio harmônico;
- 2.000 possuem distúrbio *spike*;
- 2.000 possuem distúrbio *notch*.

As características de cada evento de QEE, como amplitude, fase, frequência, são atribuídas de maneira aleatória em intervalos com distribuição uniforme. As amplitudes adotadas neste trabalho são normalizadas, ou seja, as amplitudes de tensão são dadas em pu (por unidade). A fase é atribuída aleatoriamente, dentro do intervalo fechado $[-\pi; \pi]$ com distribuição uniforme.

Quando a forma de onda do sinal de tensão é não senoidal e periódica, ocorre a presença de harmônicos, cuja amplitude pode variar aleatoriamente no intervalo uniforme $[0.2; 0.7]$ pu. O número máximo de harmônicos considerado no presente trabalho foi igual a 6. Múltiplos não inteiros da frequência fundamental revelam a existência de inter ou sub-harmônicos. Quando esses múltiplos são maiores que um, tem-se a presença do inter-harmônico. As frequências e amplitudes dos distúrbios são sorteadas de maneira aleatória. Neste trabalho, as frequências dos inter-harmônicos estão compreendidas entre 64 Hz e 116 Hz, já as amplitudes estão uniformemente distribuídas entre $[0.25; 0.75]$ pu.

Sinais com a presença de interrupção curta de tensão possuem amplitudes, sorteadas aleatoriamente, com variação em intervalo uniformemente distribuído: $[0.0; 0.09]$ pu, e sua duração variando entre um ciclo e cinco ciclos.

O evento definido como *spike*, na componente fundamental do sistema elétrico, manifesta-se de forma periódica no sinal monitorado e, no presente trabalho, é considerado que ele se inicia e passa a ocorrer em regime permanente no sistema. A modelagem adotada do evento considera que ele ocorre apenas em pontos nos quais o módulo da amplitude do sinal seja superior a 0.6 pu de seu valor nominal, delimitando, assim, a fase de ocorrência do evento em relação à componente fundamental do sistema. A amplitude dos *spikes* é função do valor da amplitude da componente fundamental no ponto no qual ele ocorre. Esse valor é definido como sendo 50% do valor da amplitude da componente fundamental.

Os sinais com a presença *notches* são modelados como fenômenos oscilatórios de curta duração que ocorrem de maneira periódica no sistema elétrico. A amplitude do distúrbio depende da amplitude da componente fundamental do sistema e é 0.7 pu. A duração de cada *notch* é de 0,52 ms. A frequência angular de oscilação é correspondente a uma frequência de 3 kHz e é mantida fixa para todos os eventos gerados.

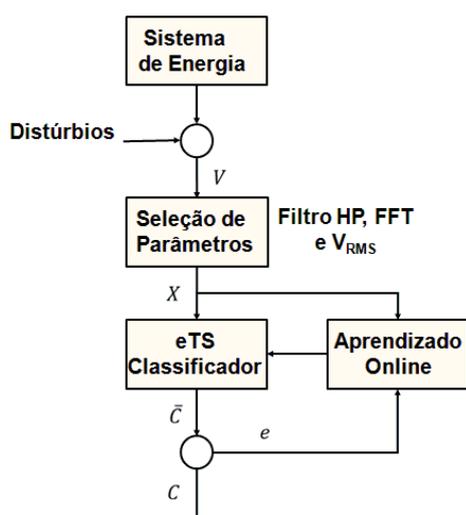
4.2 SISTEMA DE MONITORAMENTO PROPOSTO

O monitoramento de distúrbios, em geral, compreende basicamente a obtenção de variáveis e a aplicação de um algoritmo que realize a detecção e classificação baseada nas variáveis escolhidas como indicadores da existência de distúrbios (FERREIRA, 2010). Neste trabalho a obtenção de variáveis indicadoras de distúrbios foi feita a partir dos resultados obtidos com

o emprego do filtro HP, da FFT e do valor eficaz da tensão da componente de tendência do filtro HP. A construção do modelo detector/classificador foi realizada em modo *online* a partir de um fluxo de dados. A construção e adaptação de detectores/classificadores em modo *online* é uma clara contribuição do trabalho à área de QEE.

O esquema geral do sistema de monitoramento proposto neste trabalho é ilustrado pela Figura 3. Os dados a serem processados pelo classificador são os indicadores de QEE resultantes do pré-processamento do sinal com distúrbio através filtro HP, Transformada Rápida de Fourier e do valor RMS da tensão.

Figura 3 - Sistema de monitoramento proposto.

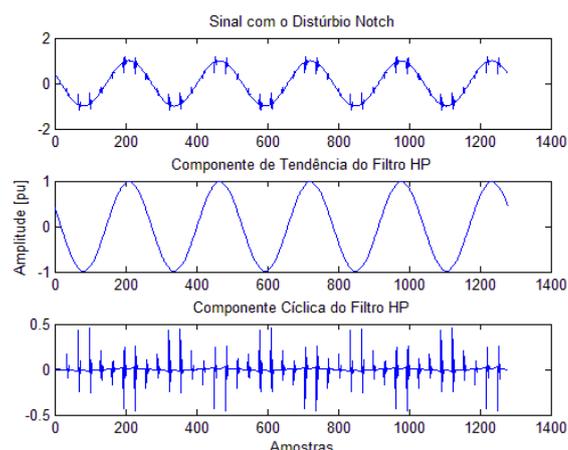


Fonte - Próprio autor.

4.3 FILTRO HP

O filtro HP foi usado para decompor o sinal elétrico em suas componentes de tendência e cíclica na etapa de extração de características. As características que serão extraídas são as amplitudes máximas e mínimas das duas componentes, que irão compor os quatro primeiros parâmetros do vetor de entrada no detector/classificador. A Figura 4 exemplifica um sinal elétrico contaminado com o distúrbio *notch*.

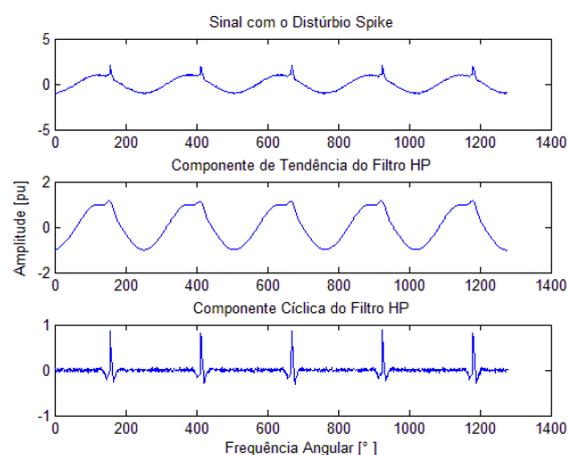
Figura 4 - Filtro HP para distúrbio *notch*.



Fonte - Próprio autor.

O sinal mostrado na Figura 4 tem frequência de 60 Hz, amplitude de 1 pu e SNR de 30 dB. O filtro HP decompôs o sinal original em duas componentes, a se ver: componente de tendência e componente cíclica. O ruído presente no sinal, componente de alta frequência, apresentou-se na componente cíclica bem como o distúrbio que também é uma componente de alta frequência. Na componente de tendência apresentou-se o sinal de frequência fundamental em 60 Hz sem distúrbio e sem ruído também.

Figura 5 - Filtro HP para distúrbio *Spike*.



Fonte - Próprio autor.

Para realizar uma comparação da aplicação do filtro HP vamos considerar o distúrbio *spike* nas mesmas condições que o *notch*. Percebe-se, nas Figuras 4 e 5 na componente cíclica do filtro HP, que é possível extrair padrões nos dados, portanto, sua aplicação é justificável no modelo proposto neste trabalho.

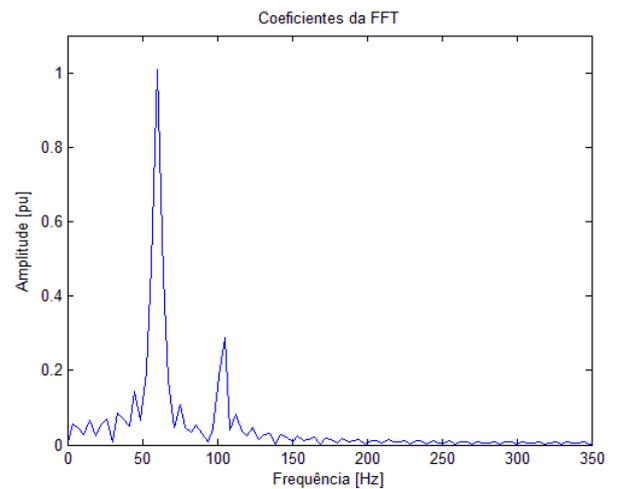
4.4 TRANSFORMADA RÁPIDA DE FOURIER

A FFT será utilizada para extrair o valor máximo do coeficiente da Transformada Discreta de Fourier para a frequência fundamental, que será o quinto dado do vetor de entrada. Esse dado tem seu valor alterado de acordo com os distúrbios, portanto pode ser utilizada para o modelo proposto, pois consegue extrair padrões em dados.

Neste trabalho, foi utilizada a função *fft* do *software* Matlab R2011b®, que calcula a Transformada de Fourier Discreta utilizando o algoritmo da FFT. Essa função, contudo, exige que o número de amostras seja do formato 2^n , podendo gerar alguns problemas. Quando o número de amostras é menor que a potência de 2 mais próxima, a sequência de valores discretos é completada com zeros até que se chegue ao número desejado; em contrapartida, quando o número de amostras é maior que a potência de 2 mais próxima, a sequência é truncada (GAO; YAN, 2011).

O problema do número de amostras foi solucionado já na geração dos dados, uma vez que a taxa de amostragem das medições foi de 256 amostras por ciclo. A aplicação da Transformada de Fourier a medidas discretizadas é mais eficiente quando é aplicada a transformada rápida (FFT). O objetivo desse procedimento é obter os coeficientes da Série de Fourier, que estabelecem a composição harmônica de uma determinada forma de onda, a partir da Transformada. Para mostrar a variação do valor do coeficiente da FFT utilizaram-se as Figuras 6 e 7.

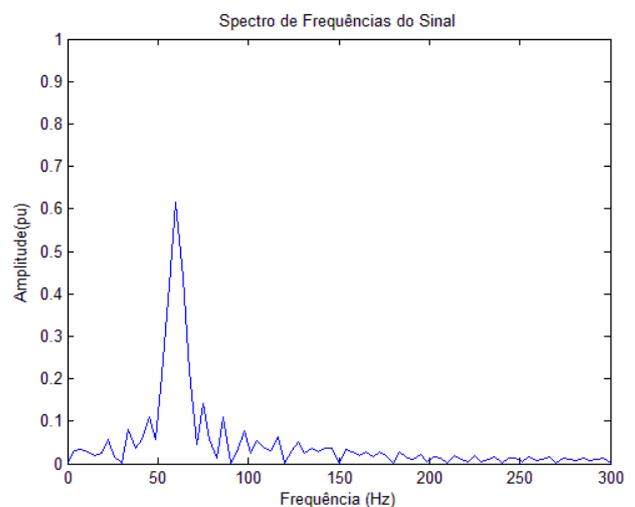
Figura 6 - Coeficientes da Série de Fourier para o distúrbio inter-harmônico



Fonte - Próprio autor.

Na Figura 6 tem-se o distúrbio inter-harmônico na frequência de 113 Hz. Percebe-se que o valor do coeficiente da FFT para frequência fundamental do sistema é 1 pu. Em uma análise posterior por parte do especialista é possível, através da FFT, identificar as componentes de frequências presentes no sinal original. Na Figura 7 tem-se um sinal com a presença do distúrbio interrupção curta.

Figura 7 - Coeficientes da Série de Fourier para o distúrbio interrupção curta



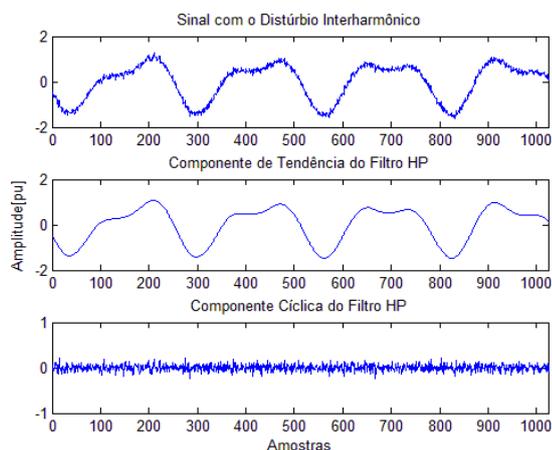
Fonte - Próprio autor.

Percebe-se que o valor do coeficiente da FFT para frequência fundamental do sistema é 0,61 pu. Portanto, essa variável é eficiente para o modelo proposto, pois se consegue extrair padrões em dados.

4.5 VALOR EFICAZ DA TENSÃO DA COMPONENTE DE TENDÊNCIA

Neste trabalho o valor eficaz da tensão da componente de tendência foi utilizado como um dos parâmetros a serem analisados pelo detector/classificador proposto. É o sexto, e último, dado do vetor de entrada. A componente de tendência está livre das componentes de alta frequência presentes no sinal analisado, ou seja, livre do ruído, conforme a Figura 8. Isso é de fundamental importância na análise que está sendo proposta, pois consideram-se baixos valores de SNR.

Figura 8 - Componentes do filtro HP para sinal com 20 dB de SNR



Fonte - Próprio autor.

5 RESULTADOS E DISCUSSÕES

Nesta seção o sistema de detecção e classificação apresentado na seção anterior foi avaliado. Diferente da maioria dos trabalhos de detecção e classificação

de distúrbios de QEE conhecidos na literatura em que uma base de dados é conhecida *a priori* e os sistemas são implementados de forma *offline*, o presente trabalho simula uma análise de forma *online* através de fluxo de dados em tempo real. Dessa forma, não há conhecimento *a priori* dos dados a serem analisados.

5.1 DETECÇÃO DE DISTÚRBIOS

Nesta seção foi analisado o desempenho de detecção utilizando o modelo eTS. Foi simulado o fluxo de dados contendo apenas um distúrbio e o sinal sem distúrbio, a fim de se verificar a eficiência do modelo proposto na detecção de distúrbios de QEE. Os sinais analisados contêm um, quatro e dez ciclos da senoide a fim de se verificar a robustez do sistema a várias janelas de análise. A relação sinal-ruído teve variação entre 20 dB a 60 dB. O índice de desempenho acurácia ($Acc(\%)$) utilizado pelos modelos propostos é calculado pela Equação 15.

$$Acc(\%) = \frac{acertos}{(acertos + erros)} \cdot 100\% \quad (15)$$

em que os *acertos* são a somatória dos dados de saída classificados corretamente (verdadeiros positivos e verdadeiros negativos) e os *erros* são a somatória dos dados de saída classificados de maneira incorreta (falsos positivos e falsos negativos). A Tabela 1 resume o desempenho ($Acc(\%)$) de detecção em função da relação sinal-ruído e do número de ciclos da senoide.

Percebe-se pela Tabela 1 que os melhores resultados foram para os distúrbios *notch*, *spike* e interrupção curta mostrando que os parâmetros utilizados a partir do filtro HP, FFT e valor eficaz são eficientes mesmo para baixos valores de relação sinal-ruído e independente do número de ciclos da senoide analisados.

Tabela 1 - Desempenho de detecção do modelo eTS

Distúrbios	Ciclos	20dB	30dB	40dB	50dB	60dB
<i>Spike</i>	Um	95.94	99.80	99.81	99.83	99.85
	Quatro	99.00	99.68	99.88	99.80	99.88
	Dez	99.23	99.70	99.61	99.80	99.90
<i>Notch</i>	Um	99.66	99.80	99.80	99.81	99.88
	Quatro	99.80	99.84	99.80	99.88	99.90
	Dez	99.78	99.80	99.80	99.80	99.90
Inter-harmônico	Um	74.97	77.00	80.15	82.52	85.62
	Quatro	94.80	96.48	97.17	97.47	98.11
	Dez	98.23	98.63	98.80	99.09	99.40
Interrupção curta	Um	99.70	99.70	99.75	99.78	99.81
	Quatro	99.87	99.88	99.89	99.90	99.91
	Dez	99.80	99.80	99.80	99.80	99.80
Harmônico	Um	92.32	98.28	99.07	99.21	99.38
	Quatro	98.00	98.60	99.30	99.45	99.75
	Dez	97.78	98.78	99.27	99.30	99.46

Fonte - Próprio autor.

Para o distúrbio harmônico, o resultado ficou acima dos 99% para SNR de 40 dB a 60 dB, independentemente do número de ciclos, indicando que a relação sinal-ruído baixa interfere na detecção deste distúrbio. As menores taxas de acertos foram encontradas, para o distúrbio inter-harmônico para um ciclo de análise. Isso ocorre, porque são necessários vários ciclos de análise da senoide para melhor caracterizar o distúrbio.

5.2 CLASSIFICAÇÃO DE DISTÚRBIOS

Este item contém a análise de classificação. Considere, inicialmente, o distúrbio *spike*, por este se manifestar de forma periódica no sinal monitorado e ocorrer em regime permanente no sistema elétrico. Em seguida, foi inserido um distúrbio por vez, simulando como o fluxo de dados ocorreria na prática, em que os distúrbios serão apresentados, no decorrer do tempo, ao sistema de detecção/classificação. O algoritmo evolutivo proposto neste trabalho realizará a

detecção e a classificação dos distúrbios de maneira recursiva e *online*. Esses processos acontecerão ao mesmo tempo, ou seja, os distúrbios serão sempre apresentados ao algoritmo evolutivo, de forma aleatória, que realizará a detecção e classificação dos mesmos. Portanto, se uma nova amostra é suficientemente diferente do conhecimento atual do sistema, então, cria-se uma nova regra só para representá-la em princípio; se não, adapta-se uma regra no sentido de incluir a amostra e reconhecer amostras semelhantes que aparecerem no futuro. Assim, o modelo vai evoluindo e adaptando-se ao longo do tempo detectando novos distúrbios e classificando-os.

As medidas de erro RMSE (*Root Mean Squared Error*) e NDEI (*Non Dimensional Error Index*) foram utilizadas para avaliar a precisão dos modelos. O RMSE é definido como a raiz quadrada do erro quadrático médio. O NDEI é a razão entre o RMSE e o desvio padrão da saída desejada. As Equações 16 e 17 referem-se ao RMSE e NDEI, respectivamente.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{N}} \quad (16)$$

$$NDEI = \frac{RMSE}{\sigma(y_i)} \quad (17)$$

em que N é o número de amostras na saída do classificador, y_i é a saída desejada do classificador, \hat{y}_i

é a saída estimada do classificador e $\sigma(y_i)$ é o desvio padrão da saída desejada.

Após a inserção dos distúrbios considerados neste trabalho, eTS deverá identificar seis classes (cinco distúrbios e o sinal sem distúrbio). A Tabela 2 apresenta os parâmetros de desempenho de classificação do modelo eTS.

Tabela 2 – Parâmetros de desempenho de classificação do modelo eTS

Classes	Dados	Acc(%)	Tempo(s)	RMSE	NDEI
As seis classes consideradas simultaneamente	20dB_1ciclo	74.29	383.7	0.1732	0.5071
	20dB_4ciclos	85.47	329.4	0.1302	0.3812
	20dB_10ciclos	90.97	378.9	0.1280	0.3746
	30dB_1ciclo	86.74	115.6	0.1244	0.3642
	30dB_4ciclos	91.02	121.8	0.1024	0.2998
	30dB_10ciclos	98.02	155.9	0.0489	0.1431
	40dB_1ciclo	91.41	232.3	0.1001	0.2931
	40dB_4ciclos	94.48	107.1	0.0803	0.2351
	40dB_10ciclos	98.75	110.3	0.0382	0.1117
	50dB_1ciclo	95.04	265.2	0.0761	0.2227
	50dB_4ciclos	98.68	162.9	0.0392	0.1149
	50dB_10ciclos	98.85	107.4	0.0440	0.1287
60dB_1ciclo	94.52	362.4	0.0800	0.2342	
60dB_4ciclos	98.97	163.5	0.0549	0.1608	
60dB_10ciclos	99.60	106.5	0.0355	0.1039	

Fonte - Próprio autor.

5.3 MATRIZ DE CONFUSÃO

A matriz de confusão oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas *versus* as classificações erradas para cada classe, sobre um conjunto de N exemplos. Cada coluna da matriz representa as amostras de uma classe prevista, enquanto as linhas representam os casos de uma classe estimada pelo

modelo. As entradas da matriz são representadas por $M(C_i, C_j)$ indicando o número de exemplos de N que são da classe C_i mas que foram classificados pela hipótese h como sendo da classe C_j . O número de acertos se localiza na diagonal principal $M(C_i, C_i)$ da matriz; os demais elementos $M(C_i, C_j)$, para $i \neq j$, representam erros na classificação (Equação 18).

$$M(C_i, C_j) = \sum_{\{v(x,y) \in N: y=C_j\}} \|\hat{h}(x) = C_j\| \quad (18)$$

A matriz de confusão de um classificador ideal possui todos os elementos fora da diagonal iguais a zero uma vez que ele não comete erros. A matriz de confusão possibilita analisar a porcentagem de assiduidade das diversas amostras associadas a uma classe, assim como permite o entendimento e a quantificação das amostras classificadas de forma errada. A matriz de confusão será utilizada para avaliar o modelo eTS quanto ao erro (confusão) na classificação entre as diversas classes e verificar possibilidades que otimizem sua saída. As classes são distribuídas da seguinte forma:

- Classe 1: distúrbio *spike*;
- Classe 2: distúrbio *notch*;
- Classe 3: distúrbio inter-harmônico;
- Classe 4: distúrbio interrupção curta;
- Classe 5: distúrbio harmônico;
- Classe 6: sinal sem distúrbio.

A Tabela 3 apresenta a matriz de confusão para a relação sinal-ruído de 60dB e 10 ciclos de análise da senoide do modelo eTS.

Tabela 3 - Matriz de confusão do modelo eTS

1	1999	0	0	0	7	1	99%
2	0	2000	0	0	0	0	100%
3	0	0	1973	0	12	0	99%
4	0	0	0	2000	0	0	100%
5	0	0	18	0	1980	0	99%
6	1	0	9	0	1	1999	99%
	100%	100%	98%	100%	99%	100%	99,6%
	1	2	3	4	5	6	

Saída Desejada

Fonte - Próprio autor.

Percebe-se pela Tabela 3 como cada amostra foi classificada (acertos e erros). Os acertos estão na diagonal principal da matriz. As classes 1, 2, 4 e 6 foram as que tiveram melhor desempenho com praticamente 100% de acerto. Esse desempenho é de fundamental relevância para a classe 6 (sinal sem distúrbio), pois significa que o modelo apresenta baixa taxa de falso alarme.

A classe com o pior desempenho foi a inter-harmônico com 2% de erro de classificação e 27 amostras classificadas erradas. Dessas, 9 foram classificadas como sinal sem distúrbio e 18 classificadas como harmônico. Isso é devido à variação da frequência do inter-harmônico em sua geração, conforme comentado no item 4.1. Quando o inter-harmônico tem seu valor próximo da frequência fundamental ele se confunde com o sinal sem distúrbio. Quando sua frequência se aproxima do 2º harmônico (120Hz) ele se confunde com o distúrbio harmônico. Outra classe que não obteve 100% de acerto foi a dos harmônicos, com 1% de erro de classificação e 20 amostras classificadas erradas. Dessas, 12 foram classificadas como inter-harmônico, 7 classificadas como *spike* e 1 como sendo sinal sem distúrbio.

Outra análise importante é que de todas as amostras com distúrbio 38 amostras foram classificadas erradas como sendo outros distúrbios e 11 amostras foram classificadas erradas como sendo sinal sem distúrbio. É melhor dessa forma, pois uma análise posterior do especialista pode identificar o distúrbio correto.

5.4 RESULTADOS COMPARATIVOS

Nesta seção, o desempenho comparativo (Acc (%)) entre o modelo considerado neste artigo e entre os modelos xTS (*extended Takagi-Sugeno*) e a rede neural MLP (*Multilayer Perceptron*) é mostrado.

Pode ser visto na Tabela 4 que o modelo eTS teve um desempenho melhor do que os outros modelos usados na comparação. Em seguida vem o modelo xTS e a rede neural MLP. Esses resultados demonstram a grande capacidade dos modelos evolutivos, especialmente o eTS, no agrupamento de dados de forma incremental e através de um fluxo contínuo de dados, obtendo excelentes resultados na classificação de perturbações da qualidade da energia elétrica.

Outro ponto que vale ressaltar é que a rede neural MLP funciona em modo *offline*, e por isto, o número de épocas de treinamento do algoritmo foi limitado em dez, para tornar a comparação mais justa, uma vez que os algoritmos dos modelos evolutivos funcionam com somente uma época de treinamento, pois o algoritmo funciona em modo *online*, através de um fluxo de dados contínuo e em tempo real. Mesmo com essa desvantagem em relação às épocas de treinamento, os modelos evolutivos tiveram desempenho de classificação superior à MLP.

Tabela 4 - Resultados comparativos entre modelos - Acc(%)

Classes	SNR	Ciclos	eTS	xTS	MLP
As seis classes consideradas simultaneamente	20dB	1 ciclo	74.29	71.71	69.10
		4 ciclos	85.47	83.59	83.62
		10 ciclos	90.97	89.34	87.96
	30dB	1 ciclo	86.74	86.81	85.01
		4 ciclos	91.02	90.08	89.90
		10 ciclos	98.02	96.56	95.00
	40dB	1 ciclo	91.41	90.86	90.24
		4 ciclos	94.48	91.13	92.10
		10 ciclos	98.75	95.16	94.25
	50dB	1 ciclo	95.04	94.24	92.09
		4 ciclos	98.68	96.69	93.20
		10 ciclos	98.85	97.06	95.49
	60dB	1 ciclo	94.52	90.04	91.58
		4 ciclos	98.97	95.09	94.15
		10 ciclos	99.60	97.22	96.26

Fonte - Próprio autor.

6 CONCLUSÃO

Os modelos evolutivos são bastante eficientes em problemas de classificação em tempo real, em que os dados são fornecidos na forma de fluxo. Em cada instante, tanto a estrutura quanto os parâmetros que descrevem o algoritmo são atualizados em tempo real.

Adaptação é importante quando se trata de modelagem de sistemas dinâmicos não lineares variantes no tempo em ambientes dinâmicos. Nesse contexto, este trabalho propôs o modelo *fuzzy* Takagi-Sugeno evolutivo para a detecção e classificação de distúrbios de QEE.

O modelo eTS foi avaliado utilizando dados gerados de forma artificial no *software* Matlab R2011b® seguindo padrões do IEEE. O desempenho do modelo quanto à classificação de distúrbios de QEE foi aferido através da acurácia e tempo computacional requerido; e medidas de erro RMSE e NDEI foram utilizadas para avaliar a precisão do modelo. O desempenho de classificação foi promissor, mesmo considerando baixos níveis de relação sinal-ruído, poucos ciclos de análise da senoide e várias classes de distúrbios consideradas ao mesmo tempo.

Para trabalhos futuros propõe-se a extensão dos métodos propostos a outros tipos de distúrbios de QEE não contemplados neste trabalho; utilização de outros modelos na fase de extração de parâmetros; empregar outros modelos evolutivos para comparar com os resultados obtidos neste trabalho; desenvolvimento de modelos para detecção e classificação de inter-harmônicos em frequências superiores às propostas neste trabalho.

REFERÊNCIAS

ANGELOV, P. **Evolving rule-based models: a tool for design of flexible adaptive systems**. London: Springer-Verlag. 92 p, 2002.

ANGELOV, P.; FILEV, D. An approach to online identification of takagi-suigeno fuzzy models. **IEEE Transactions on Systems Man and Cybernetics. Part B-Cybernetics**, UK, v. 34, n. 1, p. 484–498, Feb. 2004.

ANGELOV, P.; KASABOV, N. Evolving Intelligent Systems - eIS. **IEEE SMC eNewsLetter**, London, v. 15, p. 1–13, 2006.

BOUCHACHIA, A. An evolving classification cascade with self-learning. **Evolving Systems**, New York, v. 1, n. 3, p. 143-160, Oct. 2010.

FERREIRA, D. D. **Análise de distúrbios elétricos em sistemas de potência**. 2010. 233 p. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

GAO, R.; YAN, R. Wavelets theory and applications for manufacturing. In: GAO, R. X.; YAN, R. **Wavelets: theory and applications for manufacturing**. New York: Springer. Chap. 2, p. 17-31, 2011.

GOMIDE, F.; PEDRYCZ, W. **Fuzzy systems engineering: toward human-centric computing**. New Jersey: John Wiley & Sons, 2007. 526 p.

HODRICK, R.; PRESCOTT, E. C. Postwar U.S. business cycles: an empirical investigation. **Journal of Money**, Ohio, v. 29, n. 1, p. 1–16, Feb. 1997.

IEE (INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS). **IEEE recommended practice for monitoring electric power quality**. New York: IEEE, 91 p., 2009.

KASABOV, N. **ECOS: evolving connectionist systems and the ECO learning paradigm**. In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION, 15., Kitakyushu. **Proceedings...** Kitakyushu: [s.n.]. p. 1232–1235, 1998.

_____. **Evolving connectionist systems: the knowledge engineering approach**. 2. ed. London: Springer-Verlag- London. 451 p, 2007.

LEITE, D. **Sistemas granulares evolutivos**. 2012. 170 p. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 2012.

LEITE, D. et al. “Fuzzy Granular Neural Network for Incremental Modeling of Nonlinear Chaotic Systems.” **IEEE International Conference on Fuzzy Systems**, pp. 64-71, 2016.

LEITE, D.; COSTA, P.; GOMIDE, F. **Evolving granular classification neural networks**. In: IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2009b, Atlanta. **Proceedings...** Atlanta: [s.n.], p. 1736-1743, 2009.

LEMOS, A. P. **Modelagem nebulosa evolutiva: novas topologias e algoritmos de aprendizagem**. 2011. 110 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2011.

LUGHOFER, E. On-line incremental feature weighting in evolving fuzzy classifiers. **Fuzzy Sets Systems**, Amsterdam, v. 163, n. 1, p. 1–23, Jan. 2011.

LUGHOFER, E.; ANGELOV, P. Handling drifts and shifts in on-line data streams with evolving fuzzy systems. **Applied Soft Computing**, Amsterdam, v. 11, n. 2, p. 2057-2068, Mar. 2011.

NAGATA, E. *et al.* Voltage sag and swell detection and segmentation based on Independent Component Analysis. **Electric Power Systems Research**, v. 155, p. 274-280, 2018.

RIBEIRO, E. *et al.* Real-time system for automatic detection and classification of single and multiple power quality disturbances. **Measurement**, v. 128, p. 276-283, 2018.

SILVA, S. *et al.* High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. **Electr Power Syst Res** 154:474–483, 2018.

TOMIC, J.; KUSLJEVIC, M.; VUJICIC, V. A new power system digital harmonic analyzer. **IEEE Transactions on Power Delivery**, New York, v. 22, n. 2, p. 772–780, Apr. 2007.

YAGER, R. R.; FILEV, D. P. Approximate clustering via the mountain method. **IEEE Transactions on Systems, Man and Cybernetics**, Amsterdam, v. 24, n. 8, p. 1279, Aug. 1994.