

Modelagem Evolutiva Baseada em Conjuntos Fuzzy para Detecção e Classificação de Distúrbios de Qualidade de Energia Elétrica

Márcio Wladimir Santana

CEFET-MG – Centro Federal de Educação Tecnológica de Minas Gerais
marciosantana@nepomuceno.cefetmg.br

Daniel Furtado Leite; Danton Diego Ferreira

UFLA – Universidade Federal de Lavras
daniel.leite@deg.ufla.br
danton@deg.ufla.br

Resumo — Distúrbios de QEE podem ocorrer em várias partes do sistema de energia causando prejuízos financeiros. Por isso, são de fundamental importância a detecção e classificação automática em tempo real destes distúrbios. Para a detecção e classificação, em particular, é considerado a modelagem evolutiva baseada em conjuntos fuzzy (FBeM). Para extração de variáveis indicadoras da presença de distúrbios foi considerado o filtro Hodrick-Prescott, a técnica de transformada rápida de Fourier e o valor eficaz das tensões de fase. Classificação de distúrbios como *sipke*, *notching*, inter-harmônicos e transitório oscilatório, foi alcançada com desempenho médio de aproximadamente 97%.

Palavras-chaves — Qualidade de energia elétrica. Detecção e classificação de distúrbios. Aprendizado incremental on-line. Sistemas Fuzzy Evolutivos.

I. INTRODUÇÃO

Conforme os benefícios da energia elétrica passam a fazer parte do dia-a-dia das pessoas, é natural que se inicie um processo de discussão quanto à qualidade da energia elétrica (QEE) [1]-[2]. Segundo [2], numa análise inicial preocupa-se com a continuidade do serviço, já que qualquer interrupção do fornecimento pode causar transtornos de grande ordem. A questão da QEE surge a partir do momento em que os consumidores constatarem interrupções no fornecimento. À medida que tais consumidores tornam-se mais sofisticados sob o ponto de vista tecnológico, outros fatores começam a ser considerados. Isto se justifica, principalmente, pelos seguintes motivos:

- 1) Os equipamentos utilizados nos dias de hoje são mais sensíveis a variações no sinal elétrico;
- 2) O crescente interesse pela racionalização da energia elétrica tem aumentado o uso de equipamentos que aumentam os níveis de distorções harmônicas;
- 3) Maior conscientização dos consumidores em relação aos fenômenos ligados à qualidade da energia;
- 4) Integração dos processos;

Os autores agradecem ao CEFET-MG, FAPEMIG e CNPq pelo apoio financeiro durante a produção deste trabalho.

- 5) O crescente uso de geração distribuída e de fontes alternativas de energia;

Diante do exposto, é evidente a importância de análises e sistemas de monitoramento da QEE no intuito de determinar as causas e as consequências dos distúrbios no sistema. Este trabalho tem motivações em nível de método e em nível de aplicação. A motivação em se adotar um método de filtragem e decomposição para extração de variáveis em combinação com modelos fuzzy munidos de algoritmos incrementais *online* é devido ao fato que essas abordagens têm se mostrado eficientes para tratar problemas de detecção e classificação de anomalias em diferentes contextos. Por exemplo, elas têm sido consideradas para detecção e classificação de novidades em séries temporais econométricas e climáticas; detecção de faltas em máquinas elétricas; detecção de mudanças abruptas e graduais em aplicações biomédicas, entre outras [3]-[4]-[5]-[6]-[7].

Atualmente é importante considerar o aumento das *smart grids* em nosso sistema elétrico. As *smart grids* são uma nova arquitetura de distribuição de energia elétrica que integra e possibilita ações a todos os usuários a ela conectados [8]-[9]-[10]. A partir deste novo conceito de geração e consumo de energia elétrica podem surgir distúrbios de QEE não previstos. Modelos de detecção e classificação fuzzy evolutivos são capazes de identificar novos distúrbios, pois sua base de regras evolui de acordo com o fluxo de dados.

As contribuições desse trabalho são: detectar e classificar distúrbios na rede elétrica em tempo real. Este processo deve acontecer em modo *online* e em tempo real, devendo apresentar boa precisão e baixo custo computacional. Será considerado a modelagem evolutiva baseada em conjuntos fuzzy (FBeM - *Fuzzy Set Based evolving Modeling*) [4]. Serão abordados os seguintes distúrbios neste trabalho: *sipke*, *notching*, inter-harmônicos e transitório oscilatório.

II. MATERIAIS E MÉTODOS

A. Filtro HP

O filtro HP decompõe o sinal em suas componentes de tendência e cíclica/aleatória. Em essência, removem-se as flutuações de baixa frequência dos sinais ou séries. A

hipótese é que, nessa separação, a variabilidade de baixa frequência representa a tendência de prazo mais longo, e a variabilidade de frequência mais alta representa os ciclos mais curtos e/ou aleatórios [11].

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 a τ_t da seguinte expressão:

$$j = \min \sum_{t=1}^T C_t^2 + \lambda \sum_{t=3}^T (\Delta^2 \tau_t)^2 \quad (1)$$

onde $c_t \triangleq y_t - \tau_t$ e $\Delta^2 = (1 - L)^2$, com L sendo o operador de defasagens, por exemplo $Lx_t = x_{t-1}$.

Em (1), T 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, as variações na taxa de crescimento da componente de tendência. O primeiro termo de (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 de quadrados das segundas diferenças das componentes de tendência e é uma medida do grau de suavidade.

B. 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. Sistemas inteligentes evolutivos [3]-[4]-[12]-[13] 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 [12]-[13]. Independentemente da abordagem a ser utilizada, as principais características de modelos evolutivos são:

- 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;
- Os seus parâmetros são ajustados conforme o sistema se desenvolve;
- O seu funcionamento é contínuo, ocorrendo aprendizado em modo *online* e, muitas vezes, em tempo real.

A Fig. 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 em si.




Figura 1 - Esquema de um sistema inteligente evolutivo

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 certa capacidade de resolver novos problemas. 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.

1) Modelagem Evolutiva Baseada em Conjuntos Fuzzy

Proposta em [4], a modelagem evolutiva baseada em conjuntos fuzzy (FBeM - Fuzzy set Based evolving Modeling), diferentemente dos sistemas fuzzy convencionais, emprega grânulos de informação tipo fuzzy para construir mapas granulares que de maneira geral associam dados granulares de entrada a dados granulares de saída. Grânulos fuzzy garantem a generalidade da estrutura dos dados e proveem algoritmos com matemática simples e regras linguísticas descrevendo seu comportamento. Basicamente, um sistema FBeM pode perceber os dados de um fluxo sob diferentes resoluções e decidir entre adotar granularidades mais simples ou mais detalhadas.

Modelos FBeM são criados e evoluídos quando requisitados pelo fluxo de dados. O algoritmo de aprendizagem de FBeM cria, expande e retrai grânulos recursivamente. Eventualmente, a estrutura granular resultante pode ser melhorada de acordo com relações inter-granulares. FBeM combina sistemas fuzzy linguísticos e funcionais para prover aproximações singulares e granulares de funções não estacionárias. Sistemas fuzzy funcionais são geralmente mais precisos enquanto que sistemas fuzzy

linguísticos são mais interpretáveis. Através da combinação destes, FBeM aproveita as vantagens de ambos os sistemas simultaneamente [4].

FBeM é uma abordagem de modelagem incremental a partir de dados detalhados e um algoritmo de aprendizagem. Sua resposta global sucede da agregação de respostas locais mais específicas. O algoritmo incremental de FBeM molda sua estrutura de regras para aceitar novidades, lidar com incerteza, prover aproximações singulares e granulares de funções [4]. A aprendizagem em FBeM não requer pré-concepção de regras. Regras são criadas e adaptadas dinamicamente, consoante com o comportamento da função do processo ou fronteira de decisão ao longo do tempo. Sempre que amostras de dados são disponibilizadas, um mecanismo de decisão pode acrescentar novas regras à estrutura FBeM ou adaptar parâmetros de regras existentes.

III. METODOLOGIA

A. Banco de Dados

Os sinais de tensão foram gerados, de forma sintética, de acordo com a regulamentação do IEEE [14]. Todos os sinais gerados apresentam frequência fundamental igual a 60Hz. A frequência de amostragem utilizada foi de 15.360Hz. Desta 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, 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:

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

onde 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 entre 50dB e 70dB [15]. Neste trabalho serão utilizadas relações sinal-ruído 20dB, 30dB, 40dB, 50dB e 60dB, 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 10.000 sinais, variando o número de ciclos da senóide entre um, quatro e dez ciclos, dos quais:

- 2.000 não possuem distúrbios;
- 2.000 possuem distúrbio *spike*;
- 2.000 possuem distúrbio *notching*;
- 2.000 possuem distúrbio inter-harmônico;
- 2.000 possuem distúrbio transitório oscilatório.

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, a tensão de pico

nominal tem valor unitário. A fase é atribuída aleatoriamente, dentro do intervalo $[-\pi; \pi]$ com distribuição uniforme.

B. 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. Neste trabalho a obtenção de variáveis indicadoras de distúrbios será feita a partir dos resultados obtidos com o emprego do filtro HP, da FFT e do valor eficaz. A construção do modelo detector/classificador será 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 pelo diagrama em blocos da Fig. 2. O sinal a ser processado pelo classificador é o vetor $e[n]$ resultante do pré-processamento do sinal com distúrbio através filtro HP, Transformada Rápida de Fourier e do RMS.




Figura 2 - Sistema de monitoramento proposto

C. Filtro HP

O filtro HP será usado para decompor o sinal elétrico em suas componentes de tendência e cíclica na etapa de extração de parâmetros. As características que serão extraídas são as amplitudes máximas e mínimas das duas componentes, que irão compor os quatro primeiros dados do vetor de entrada no detector/classificador. A Fig. 3 exemplifica um sinal elétrico típico.




Figura 3 - Filtro HP para distúrbio transitório oscilatório

O sinal mostrado na figura tem frequência de 60Hz, amplitude de 1pu e SNR de 30dB. Porém, o sinal está contaminado com o distúrbio transitório oscilatório proveniente do chaveamento de banco de capacitores. O filtro HP decompõe 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 transitório oscilatório que também é uma componente de alta frequência (entre 1.000Hz e 2.500Hz). Na componente de tendência apresentou-se o sinal de frequência fundamental em 60Hz sem distúrbio e sem ruído também.

D. Transformada Rápida de Fourier

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

Neste trabalho, foi utilizada a função *fft* do Matlab, que calcula a Transformada de Fourier Discreta utilizando o algoritmo da FFT. Esta função, contudo, exige que o número de amostras seja do formato 2^n , podendo gerar alguns problemas.

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.

E. Valor Eficaz da Tensão da Componente de Tendência

Neste trabalho o valor eficaz da tensão da componente de tendência será utilizado como um dos parâmetros a serem analisados pelo detector/classificador proposto.




Figura 4 - Componentes do filtro HP para sinal com 20 dB de SNR

Será o sexto, e último, dado do vetor de entrada. Este parâmetro atuará de modo complementar ao quinto parâmetro, pois a componente de tendência está livre das componentes de alta frequência presentes no sinal analisado, ou seja, livre dos ruídos, conforme a Fig. 4. Isto é de fundamental importância na análise que está sendo proposta, pois estamos considerando baixos valores de SNR.

IV. RESULTADOS E DISCUSSÃO

Neste item o sistema de detecção e classificação apresentado na seção anterior será avaliado. Diferente da maioria dos trabalhos de detecção e classificação de distúrbios de QEE conhecidos na literatura onde uma base de dados é conhecida a priori e os sistemas são implementados de forma *offline*, o presente trabalho apresenta uma análise de forma *online* através de fluxo de dados em tempo real. Desta forma, não há conhecimento a priori dos dados a serem analisados.

A. Detecção de Distúrbios

Neste item será analisado o desempenho de detecção utilizando o modelo FBeM. Será simulado o fluxo de dados contendo apenas um distúrbio por vez 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 senóide a fim de se verificar a robustez do sistema a várias janelas de análise. A relação sinal-ruído terá variação entre 20dB a 60dB. O índice de desempenho utilizado pelos modelos propostos é calculado por:

$$Acc(\%) = \frac{acertos}{(acertos + erros)} \cdot 100\% \quad (3)$$

onde, os acertos são a somatória dos dados de saída classificados corretamente e os erros são a somatória dos dados de saída classificados de maneira incorreta.

A Tabela I resume o desempenho de detecção para os distúrbios considerados neste trabalho, em função da relação sinal-ruído e do número de ciclos da senóide.

Tabela I. - DESEMPENHO DE DETECÇÃO E DO MODELO FBeM

Distúrbios	Ciclos	20dB	30dB	40dB	50dB	60dB
Transitório oscilatório	Dez	98.72	99.92	99.92	99.92	99.95
	Um	99.42	99.95	99.95	99.95	99.95
	Quatro	99.17	99.97	99.95	99.97	99.90
Spike	Dez	99.85	99.92	99.92	99.97	99.97
	Um	92.17	99.97	99.95	99.95	99.95
	Quatro	98.90	99.95	99.97	99.95	99.97
Notching	Dez	99.95	99.95	99.95	99.95	99.97
	Um	99.90	99.95	99.95	99.97	99.97
	Quatro	99.95	99.95	99.95	99.95	99.97
Inter-harmônico	Dez	99.95	99.40	99.37	99.55	99.42
	Um	88.57	94.12	91.60	91.45	91.60
	Quatro	96.55	96.57	98.47	97.80	98.87

Percebe-se pela Tabela I que os melhores resultados foram para os distúrbios transitório oscilatório, *notching*, *spike*, mostrando que os parâmetros utilizados a partir do filtro HP, FFT e valor eficaz são eficientes, nestes casos, mesmo para baixos valores de relação sinal-ruído e independente do número de ciclos da senóide analisados. Para o distúrbio inter-harmônico o resultado ficou acima dos 99% para SNR de 20dB a 60dB e dez ciclos de análise da senóide, nos indicando que o número baixo de ciclos de análise interfere na detecção deste distúrbio.

A tabela II apresenta o tempo computacional requerido, em segundos, pelo modelo FBeM para a detecção dos distúrbios considerados neste trabalho.

Tabela II. - TEMPO COMPUTACIONAL REQUERIDO PELO MODELO FBeM NA DETECÇÃO DOS DISTÚRBIOS

Distúrbios	Ciclos	20dB	30dB	40dB	50dB	60dB
Transitório oscilatório	Dez	6.39	5.40	5.62	6.53	6.68
	Um	5.69	5.31	5.53	5.58	5.93
	Quatro	5.47	5.93	5.81	6.39	6.32
Spike	Dez	8.34	7.42	6.84	6.79	6.11
	Um	8.20	6.78	6.96	6.48	5.49
	Quatro	8.03	6.45	6.61	6.67	5.70
Notching	Dez	6.38	4.16	4.16	4.09	4.19
	Um	4.53	4.16	4.14	4.11	4.14
	Quatro	4.56	4.27	4.12	4.10	4.08
Inter-harmônico	Dez	6.09	6.21	7.45	7.07	6.68
	Um	7.82	7.43	7.25	7.37	7.18
	Quatro	6.95	6.14	8.07	6.63	7.55

B. Classificação de Distúrbios

Neste item contem 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, será inserido um distúrbio por vez, simulando como o fluxo de dados acorreria na prática, aonde 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. Estes processos acontecerão ao mesmo tempo, ou seja, os distúrbios serão sempre apresentados com o sinal sem distúrbio ao algoritmo evolutivo 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 percebendo (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. A seguir temos as fórmulas do RMSE e NDEI, respectivamente:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (4)$$

$$NDEI = \frac{RMSE}{\sigma(y_i)} \quad (5)$$

onde: 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 quatro distúrbios considerados neste trabalho, FBeM deverá identificar cinco classes (quatro distúrbios e o sinal sem distúrbio). A Tabela III apresenta o desempenho de classificação do modelo FBeM e o tempo computacional, em segundos, requerido pelo modelo.

Tabela III. - DESEMPENHO DE CLASSIFICAÇÃO E TEMPO REQUERIDO

Distúrbios	Dados	Acc FBeM (%)	Tempo FBeM (seg)
Spike, Notching, Inter-harmônico e Transitório oscilatório	20dB_10ciclos	98.83	35.15
	20dB_1ciclo	84.39	45.58
	20dB_4ciclos	91.51	33.84
	30dB_10ciclos	99.67	27.78
	30dB_1ciclo	96.73	37.78
	30dB_4ciclos	96.47	30.93
	40dB_10ciclos	99.71	30.86
	40dB_1ciclo	97.85	37.79
	40dB_4ciclos	99.14	29.60
	50dB_10ciclos	99.74	29.44
	50dB_1ciclo	97.31	36.74
	50dB_4ciclos	99.48	31.04
	60dB_10ciclos	99.78	28.34
	60dB_1ciclo	97.33	38.44
	60dB_4ciclos	99.48	30.31

A Tabela IV apresenta as medidas de erro de classificação.

Tabela IV. - MEDIDAS DE ERRO DE CLASSIFICAÇÃO

Distúrbios	Dados	RMSE FBeM	NDEI FBeM
Spike, Notching, Inter-harmônico e Transitório oscilatório	20dB_10ciclos	0.0602	0.1701
	20dB_1ciclo	0.2358	0.6668
	20dB_4ciclos	0.1682	0.4757
	30dB_10ciclos	0.0289	0.0818
	30dB_1ciclo	0.0914	0.2585
	30dB_4ciclos	0.0942	0.2665
	40dB_10ciclos	0.0288	0.0815
	40dB_1ciclo	0.0734	0.2076
	40dB_4ciclos	0.0467	0.1321
	50dB_10ciclos	0.0272	0.0768
	50dB_1ciclo	0.0830	0.2346
	50dB_4ciclos	0.0368	0.1042
	60dB_10ciclos	0.0233	0.0660
	60dB_1ciclo	0.0822	0.2326
	60dB_4ciclos	0.0358	0.1012

Nota-se, que FBeM teve desempenho bastante satisfatório, comprovando desta forma e eficiência dos sistemas de extração de atributos discutidos no item III deste trabalho. O modelo FBeM obteve o melhor resultado de classificação (desempenho e medida de erro) para 60dB e dez ciclos.

C. 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.

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 [16]. As classes são distribuídas da seguinte forma:

- Classe 1: distúrbio *spike*;
- Classe 2: distúrbio *notching*;
- Classe 3: distúrbio inter-harmônico;
- Classe 4: distúrbio transitório oscilatório;
- Classe 5: sinal sem distúrbio.

Tabela V. - MATRIZ DE CONFUSÃO DO MODELO FBeM

Saída Estimada	1	1999	0	0	0	0	100%
	2	0	1999	0	1	1	99.9%
	3	0	0	1978	0	0	100%
	4	0	0	0	1999	0	100%
	5	1	1	22	0	1999	98.8%
		100%	100%	98.9%	100%	100%	99.7%
		1	2	3	4	5	
		Saída Desejada					

A Tabela V apresenta a matriz de confusão para a relação sinal-ruído de 60dB e 10 ciclos de análise da senoide do modelo FBeM. Percebe-se pela Tabela V como cada amostra foi classificada (acertos e erros). Os acertos estão na diagonal principal da matriz. Os erros estão identificados pelos dados localizados fora da matriz principal. As classes 1, 2, 4 e 5 foram as que tiveram melhor desempenho com somente uma amostra classificada errada em duas mil no total. Este desempenho é de fundamental relevância para a classe 5 (sinal sem distúrbio), pois significa que o modelo é capaz de identificar quando o sinal não tem distúrbio de QEE. Na classe 3 tivemos o pior desempenho com 22 amostras classificadas como sinal sem distúrbio sendo que continha o distúrbio inter-harmônico. O modelo apresentou desempenho total de 99,7%.

V. CONCLUSÃO

Os modelos evolutivos são bastante eficientes em problemas de classificação em tempo real, onde 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. Neste contexto, este trabalho propôs a modelagem evolutiva baseada em conjuntos fuzzy (FBeM), para a detecção e classificação de distúrbios de QEE. FBeM emprega grânulos de informação tipo fuzzy para construir mapas granulares que de maneira geral associam dados granulares de entrada a dados granulares de saída.

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; abordar metodologias de seleção incremental de variáveis de entrada para tornar todo o sistema evolutivo.

VI. REFERÊNCIAS

- [1] R. C. Dugan et al. Electrical Power Systems Quality, 2nd. Ed., McGraw-Hill, 2003.
- [2] J. C. Oliveira, Qualidade da energia elétrica: definição e análise dos itens de qualidade. Cap. II, Universidade Federal de Uberlândia, Centro de Ciências Exatas e Tecnologia, Departamento de Engenharia Elétrica, Grupo de Qualidade e Racionalização da Energia Elétrica. Projeto SIDAQEE, 2000.
- [3] P. Angelov; D. Filev; N. Kasabov. Evolving Intelligent Systems: Methodology and Applications. John Wiley & Sons, New York, USA, 2010.
- [4] D. Leite. Sistemas Granulares Evolutivos. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, 2012.
- [5] A. Bouchachia. An evolving classification cascade with self-learning. Evolving Systems, Vol. 1, Issue 3, pp: 143-160, 2010.
- [6] B. Gabrys; L. Petrakieva. Combining labelled and unlabelled data in the design of pattern classification systems. International Journal of Approximate Reasoning, Vol. 35, Issue 3, pp: 251-273, 2004.
- [7] D. Leite, M. Santana, A. Borges, F. Gomide. "Fuzzy Granular Neural Network for Incremental Modeling of Nonlinear Chaotic Systems." IEEE International Conference on Fuzzy Systems, pp. 64-71, 2016.
- [8] K. G. Di Santo et al. A review on smart grids and experiences in Brazil. Renewable and Sustainable Energy Reviews, v. 52, p. 1072-1082, 2015.
- [9] M. E. El-Hawary. The smart grid – state-of-the-art and future trends. Electr Power Compon Syst, v. 50, p. 42-239, 2014.
- [10] P. F. Ribeiro et al. Power Systems Signal Processing for Smart Grids. John Wiley and Sons, 2013.
- [11] R. Hodrick; E. Prescott. Postwar U.S. Business Cycles: An Empirical Investigation. Journal of Money, Credit, and Banking 29 (1): 1-16, 1997.
- [12] P. Angelov; N. Kasabov. Evolving Intelligent Systems - eIS. IEEE SMC eNewsLetter, 15:1-13, 2006.
- [13] P. Angelov; X. Zhou; D. Filev; E. Lughofer. Architectures for evolving fuzzy rule-based classifiers. IEEE International Conference on Systems, Man and Cybernetics, pp: 2050-2055, 2007.
- [14] IEEE. IEEE recommended practice for monitoring electric power quality. Technical report, IEEE Power and Energy Society, 2009.
- [15] J. Tomic; M. Kusljevic; V. Vujiciv. A new power system digital harmonic analyzer. IEEE Transactions on Power Delivery, 22(2):772-780, 2007.
- [16] P-N. Tan et al. Introduction to data mining. Noida: Pearson Education India, 2006. 165 p.