



**MÁRCIO WLADIMIR SANTANA**

**AGRUPAMENTO INCREMENTAL DE FLUXO DE DADOS  
PARA ANÁLISE E MONITORAMENTO DA QUALIDADE DE  
ENERGIA**

**LAVRAS – MG**

**2017**

**MÁRCIO WLADIMIR SANTANA**

**AGRUPAMENTO INCREMENTAL DE FLUXO DE DADOS PARA ANÁLISE E  
MONITORAMENTO DA QUALIDADE DE ENERGIA**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. Dr. Daniel Furtado Leite

Orientador

Prof. Dr. Danton Diego Ferreira

Coorientador

**LAVRAS – MG**

**2017**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA,  
com dados informados pelo(a) próprio(a) autor(a).**

Santana, Márcio Wladimir.

Agrupamento incremental de fluxo de dados para análise e monitoramento da qualidade de energia / Márcio Wladimir Santana. - 2017.

97 p.

Orientador: Daniel Furtado Leite.

Coorientador: Danton Diego Ferreira.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2017.

Bibliografia.

1. Sistemas Fuzzy Evolutivos. 2. Aprendizagem Recursiva On-line. 3. Qualidade de Energia Elétrica. I. Leite, Daniel Furtado. II. Ferreira, Danton Diego. III. Título.

**MÁRCIO WLADIMIR SANTANA**

**AGRUPAMENTO INCREMENTAL DE FLUXO DE DADOS PARA ANÁLISE E  
MONITORAMENTO DA QUALIDADE DE ENERGIA**

***INCREMENTAL CLUSTERING OF DATA STREAMS FOR POWER QUALITY  
MONITORING AND ANALYSIS***

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADO em 17 de abril de 2017.

Prof. Dr. Pyramo Pires da Costa Jr                      PPGEE/PUC-MG

Prof. Dr. Maury Meirelles Gouvêa Júnior              PPGEE/PUC-MG

Prof. Dr. Danton Diego Ferreira                        UFLA

Prof. Dr. Daniel Furtado Leite  
Orientador

**LAVRAS – MG**

**2017**

*Dedico este trabalho à minha família, meus pais, meus irmãos, minha esposa Valéria, minha  
filha Luiza e meu filho Pedro.*

*Dedico.*

## **AGRADECIMENTOS**

À Universidade Federal de Lavras (UFLA), ao Departamento de Engenharia (DEG) e ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação (PPGESISA), pela oportunidade concedida para a realização do mestrado.

Ao Prof. Daniel Furtado Leite, meu orientador, pelo apoio e amizade. Por sempre me incentivar e por ter acreditado em meu trabalho.

Ao Prof. Danton Diego Ferreira, meu coorientador, por seu exemplo de carreira acadêmica, simplicidade e grande apoio em todas as etapas do desenvolvimento deste trabalho.

Aos professores do PPGESISA que contribuíram com todo embasamento teórico durante o programa.

À Fernanda, secretária do PPGESISA, pela dedicação e suporte durante a realização do mestrado.

Aos colegas do PPGESISA que sempre estiveram ao meu lado nos momentos de estudo e apresentação de trabalhos.

Aos meus pais e irmãos, pela minha formação como pessoa.

À Valéria, minha esposa, pelo amor e pela compreensão que me dedicou durante todos estes anos. Por suportar minhas ausências e por me ajudar em todas as dificuldades por que passei.

Aos meus filhos, Luiza e Pedro, pela oportunidade de crescimento como pessoa.

Sobretudo a Deus.

## RESUMO

O conceito de Qualidade da Energia está relacionado a um conjunto de alterações que podem ocorrer no sistema elétrico. Pode-se definir o problema de qualidade de energia como aqueles manifestados na tensão, corrente ou nas variações de frequência, que resultam em falha ou má operação em equipamentos de consumidores. Tais alterações (distúrbios) podem ocorrer em várias partes do sistema de energia, sejam nas instalações elétricas dos consumidores ou no sistema supridor da concessionária, causando prejuízos financeiros a ambas as partes. Por isso, é de fundamental importância a detecção em tempo real e classificação destes distúrbios de modo automático baseada em uma grande quantidade de dados gerados pelos equipamentos de monitoramento. Para reconhecimento e classificação de padrões, são considerados modelos inteligentes evolutivos, ou seja, modelos equipados com algoritmos de aprendizado incremental *on-line* capazes de alterar seus parâmetros e estrutura conforme novas informações surgem em um fluxo de dados. Em particular, é considerado um modelo evolutivo *fuzzy* do tipo Takagi-Sugeno (eTS) e a modelagem evolutiva baseada em conjuntos *fuzzy* (FBeM). Para pré-processamento dos dados mensurados e 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. Os modelos desenvolvidos neste trabalho têm alcançado um desempenho comparável aos modelos estado da arte na área de qualidade de energia. Detecção e classificação de distúrbios como afundamento de tensão, elevação de tensão, inter-harmônicos, sub-harmônicos, harmônicos, interrupção curta, transitórios oscilatórios, *spikes* e *notchings*, ocorrendo possivelmente de forma simultânea, foram alcançadas com acurácia de, aproximadamente, 85-95%. Além disso, os modelos evolutivos adotados, combinados com as técnicas de pré-processamento mencionadas, são superiores com relação ao tempo computacional exigido.

**Palavras-chave:** Qualidade de energia. Detecção e classificação de distúrbios. Aprendizado incremental *on-line*. Sistemas Fuzzy Evolutivos.

## ABSTRACT

The concept of Power Quality is related to a set of changes that can occur in the electrical system. Power quality problems can be defined as problems that manifest in voltage and current signals or as variations in frequency. These result in flaws or bad consumer equipment operation. Such changes (disturbances) can occur in many parts of the power system – be it in the consumer electrical wiring or in the supply system, causing financial losses to both. Thus, real-time automatic detection and classification of disturbances, based on a large volume of data generated by monitoring equipment, is of fundamental importance. In this study, evolving intelligent models, that is, models equipped with incremental online learning algorithms capable of changing their parameters and structure according to new information that emerge from a data stream, are considered for pattern recognition and classification. In particular, an evolving Takagi-Sugeno (eTS) fuzzy model, and an evolving fuzzy set-based evolving model (FBeM) are taken into consideration. A Hodrick-Prescott filter combined with a Fast Fourier Transform technique and mean voltages are considered for pre-processing measured data and extracting variables that indicate the presence of disturbances. The models developed in this study have reached classification performance comparable to that of state-of-the-art models in the field of power quality. Detection and classification of disturbances such as voltage sag and swell, inter-harmonics, sub-harmonics, harmonics, short-term interruption, oscillatory transient, spikes and notching, possibly occurring simultaneously, were reached with an accuracy of about 85-95%. In addition, the evolving models adopted, combined with the above-mentioned pre-processing techniques, have shown to be superior in terms of computational memory and time.

**Keywords:** Power quality. Detection and classification of disturbances. Incremental online learning. Evolving fuzzy systems.

## LISTA DE FIGURAS

Figura 1 - Distúrbio <i>Spike</i> no chaveamento de cargas indutivas. ....	22
Figura 2 - Transitório proveniente de simulação do chaveamento de banco de capacitores. ..	23
Figura 3 - Interrupção de curta duração em decorrência de simulação de um curto-circuito. .	24
Figura 4 - Afundamento de tensão devido a uma falta fase-terra.....	26
Figura 5 - Elevação de tensão devido a uma falta fase-terra.....	27
Figura 6 - Exemplo de distorção harmônica .....	29
Figura 7 - Distúrbio <i>notching</i> em um sistema elétrico.....	30
Figura 8 - Esquema geral de um sistema de reconhecimento de padrões .....	34
Figura 9 - Esquema de um sistema inteligente evolutivo.....	41
Figura 10 - Demonstração da função potencial. ....	45
Figura 11 - Sistema de monitoramento proposto.....	58
Figura 12 - Filtro HP para distúrbio transitório oscilatório.....	59
Figura 13 - Filtro HP para distúrbio <i>spike</i> .....	60
Figura 14 - Coeficientes da Série de Fourier para o distúrbio inter-harmônico.....	61
Figura 15 - Coeficientes da Série de Fourier para o distúrbio interrupção curta.....	62
Figura 16 - Componentes do filtro HP para sinal com 20 dB de SNR. ....	63
Figura 17- Matriz de confusão do modelo FBeM para 60dB e 10 ciclos. ....	85
Figura 18 - Matriz de confusão do modelo FBeM para 50dB e 10 ciclos. ....	86
Figura 19 - Curva ROC do modelo FBeM para 60dB e 10 ciclos.....	87
Figura 20 - Curva ROC do modelo FBeM para 50dB e 10 ciclos.....	88

## LISTA DE TABELAS

Tabela 1 - Categorias e características de distúrbios nos sistemas elétricos .....	20
Tabela 2 - Desempenho de detecção considerando o modelo eTS.....	65
Tabela 3 - Desempenho de detecção considerando o modelo FBeM. ....	66
Tabela 4 - Desempenho de detecção e tempo requerido para distúrbio <i>spike</i> .....	68
Tabela 5 - Medidas de erro de detecção do distúrbio <i>spike</i> . ....	69
Tabela 6 - Desempenho de classificação e tempo requerido: distúrbios <i>spike</i> e <i>notching</i> . ....	70
Tabela 7 - Medidas de erro de classificação dos distúrbios <i>spike</i> e <i>notching</i> . ....	70
Tabela 8 - Desempenho de classificação e tempo requerido considerando três distúrbios. ....	71
Tabela 9 - Medidas de erro de classificação considerando três distúrbios. ....	72
Tabela 10 - Desempenho de classificação e tempo requerido considerando quatro distúrbios. ....	73
Tabela 11 - Medidas de erro de classificação considerando quatro distúrbios. ....	73
Tabela 12 - Desempenho de classificação e tempo requerido considerando cinco distúrbios. ....	74
Tabela 13 - Medidas de erro de classificação considerando cinco distúrbios. ....	75
Tabela 14 - Desempenho de classificação e tempo requerido considerando seis distúrbios. ....	76
Tabela 15 - Medidas de erro de classificação considerando seis distúrbios. ....	77
Tabela 16 - Desempenho de classificação e tempo requerido considerando sete distúrbios. ....	78
Tabela 17 - Medidas de erro de classificação considerando sete distúrbios. ....	79
Tabela 18 - Desempenho de classificação e tempo requerido considerando oito distúrbios. ....	80
Tabela 19 - Medidas de erro de classificação considerando oito distúrbios. ....	80
Tabela 20 - Desempenho de classificação e tempo requerido considerando nove distúrbios. ....	82
Tabela 21 - Medidas de erro de classificação considerando nove distúrbios.....	82

## SUMÁRIO

1	<b>INTRODUÇÃO</b> .....	12
1.1	<b>Proposta de Solução</b> .....	13
1.2	<b>Motivação</b> .....	15
1.3	<b>Objetivos</b> .....	16
1.4	<b>Organização do Trabalho</b> .....	16
2	<b>REFERENCIAL TEÓRICO</b> .....	18
2.1	<b>Análise da Qualidade de Energia</b> .....	18
2.2	<b>Itens de Qualidade de Energia</b> .....	19
2.2.1	<b>Transitórios</b> .....	20
2.2.1.1	<b>Transitórios Impulsivos</b> .....	21
2.2.1.2	<b>Transitórios Oscilatórios</b> .....	22
2.2.2	<b>Variações de Curta Duração</b> .....	23
2.2.2.1	<b>Interrupção de Curta Duração</b> .....	24
2.2.2.2	<b>Afundamento de Tensão de Curta Duração</b> .....	25
2.2.2.3	<b>Elevação de Tensão de Curta Duração</b> .....	26
2.2.3	<b>Variações de Longa Duração</b> .....	27
2.2.4	<b>Distorções da Forma de Onda</b> .....	28
2.2.4.1	<b>Nível CC</b> .....	28
2.2.4.2	<b>Harmônicos</b> .....	28
2.2.4.3	<b>Inter-harmônicos</b> .....	29
2.2.4.4	<i>Notching</i> .....	29
2.2.4.5	<b>Ruídos</b> .....	30
2.2.5	<b>Flutuações ou Oscilações de Tensão</b> .....	31
2.3	<b>Reconhecimento de Padrões</b> .....	31
2.3.1	<b>Padrão e Classe</b> .....	32
2.3.2	<b>Fases do Reconhecimento de Padrões</b> .....	32
2.4	<b>Filtro de Hodrick e Prescott</b> .....	34
2.5	<b>Transformada Rápida de Fourier</b> .....	36
2.6	<b>Valor Eficaz da Tensão</b> .....	37
3	<b>SISTEMAS INTELIGENTES EVOLUTIVOS</b> .....	39
3.1	<b>Conceitos</b> .....	39
3.2	<b>O Paradigma da Inteligência Evolutiva</b> .....	42
3.3	<b>Sistemas Fuzzy Evolutivos</b> .....	42
3.3.1	<b>Modelo Fuzzy Takagi-Sugeno Evolutivo</b> .....	43
3.3.2	<b>Modelagem Evolutiva Granular Baseada em Conjuntos Fuzzy</b> .....	47
3.3.2.1	<b>Modelagem Fuzzy Evolutiva</b> .....	47
3.3.2.2	<b>Aprendizagem Recursiva <i>On-line</i></b> .....	49
3.3.2.2.1	<b>Criação de Regras</b> .....	50
3.3.2.2.2	<b>Adaptação de Regras</b> .....	51
3.3.2.2.3	<b>Ajuste da Granularidade</b> .....	52
3.3.2.2.4	<b>Compactação da Estrutura Resultante</b> .....	53
3.3.2.2.5	<b>Remoção de Grânulos</b> .....	54
4	<b>METODOLOGIA</b> .....	55
4.1	<b>Obtenção de Sinais para Análise</b> .....	55
4.2	<b>Sistema de Monitoramento</b> .....	57
4.3	<b>Filtro Hodrick-Prescott</b> .....	58
4.4	<b>Transformada Rápida de Fourier</b> .....	60
4.5	<b>Valor Eficaz da Tensão da Componente de Tendência</b> .....	62

<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	64
<b>5.1</b>	<b>Detecção de distúrbios de QEE</b> .....	64
<b>5.2</b>	<b>Classificação de distúrbios de QEE</b> .....	67
<b>5.3</b>	<b>Matriz de Confusão</b> .....	83
<b>5.4</b>	<b>Análise de Curvas ROC</b> .....	86
<b>6</b>	<b>CONCLUSÃO</b> .....	89
	<b>REFERÊNCIAS</b> .....	91

## 1 INTRODUÇÃO

A disponibilidade da energia elétrica representa um incremento na qualidade de vida das populações. No primeiro momento, em que um sistema de distribuição de energia elétrica é implantado, a população local, imediatamente, passa a contar com inúmeros benefícios tanto do ponto de vista de maior conforto doméstico como de melhores possibilidades de emprego e produção. À medida que 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 (DUGAN et al., 2003; OLIVEIRA, 2000).

Segundo Oliveira (2000), em uma análise inicial preocupa-se com a continuidade do serviço, já que qualquer interrupção do fornecimento pode causar transtornos de grande ordem. Não tão evidente, no entanto está a questão da qualidade da energia elétrica como um produto comercial, mesmo que não ocorram interrupções. Isso, normalmente, só é percebido de forma indireta, por meio de falhas de funcionamento de alguns equipamentos. A necessidade da qualidade da energia elétrica 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:

- a) Os equipamentos utilizados nos dias de hoje são mais sensíveis a variações na qualidade da energia. Muitos deles possuem controles baseados em microprocessadores e dispositivos eletrônicos sensíveis a certos tipos de distúrbios;
- b) O crescente interesse pela racionalização e conservação da energia elétrica, com o objetivo de otimizar a sua utilização, tem aumentado o uso de equipamentos que, em muitos casos, aumentam os níveis de distorções harmônicas e podem levar o sistema à condição de ressonância;
- c) Maior conscientização dos consumidores em relação aos fenômenos ligados à qualidade da energia como interrupções, subtensões, transitórios de chaveamentos, entre outros, passando a exigir que as concessionárias melhorem a qualidade da energia fornecida;
- d) Integração dos processos. A falha de qualquer componente tem consequências muito mais importantes para o sistema elétrico como um todo;
- e) O crescente uso de geração distribuída e de fontes alternativas de energia;

- f) As consequências negativas da má qualidade da energia sobre a vida útil dos componentes elétricos.

Diante do exposto, é evidente a importância de sistemas de análises e de monitoramento da qualidade da energia no intuito de determinar as causas e as consequências dos distúrbios no sistema. Além disso, é importante apresentar medidas técnicas, economicamente viáveis, para minimizar os problemas associados. Para avaliar o quanto um sistema está operando fora de suas condições normais, duas grandezas elétricas básicas podem ser empregadas. São elas: a tensão e a frequência. A frequência, em um sistema interligado, situa-se na faixa de  $60 \pm 0,5\text{Hz}$  (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2012). Por outro lado, quanto à tensão, três aspectos principais devem ser observados:

Forma de onda, a qual deve ser aproximadamente senoidal.

- a) Simetria de sistemas elétricos trifásicos;
- b) Amplitude dentro de limites aceitáveis.

Entretanto existem fenômenos, aleatórios ou intrínsecos, que ocorrem no sistema elétrico fazendo com que os aspectos acima citados sofram alterações. Isto deteriora a qualidade do fornecimento de energia elétrica (DUGAN et al., 2003; OLIVEIRA, 2000).

### **1.1 Proposta de Solução**

O problema da detecção e classificação dos distúrbios tem sido considerado um problema difícil pelas comunidades de Aprendizado de Máquina, Inteligência Computacional e Reconhecimento de Padrões em razão de vários fatores (FERREIRA et al., 2014). Primeiramente, há um grande número de variáveis envolvidas. Estas podem, potencialmente, carregar informações importantes com relação a distúrbios. É impossível monitorar todas as possibilidades. Métodos para obtenção de atributos importantes devem ser considerados. Segundo, em monitoramento *on-line* de sistemas elétricos, é frequente o aparecimento de situações novas. Estas situações surgem pela 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 autoajustáveis em modo *on-line*. Terceiro, a quantidade de dados e amostras é grande. Dessa forma, por vezes, é inviável armazená-los 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, baseado em métodos estatísticos e métodos de inteligência computacional, é o surgimento de condições de operação/distúrbios não previstas.

Neste trabalho, na etapa de obtenção de atributos importantes, são utilizados dados gerados, artificialmente, dentro dos padrões do IEEE (THE INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS, 2009). Em particular, o filtro de Hodrick-Prescott (HP) é um filtro que tem sido utilizado, extensamente, em séries temporais econômicas por ter uma implementação computacional, relativamente fácil e código provido em vários *softwares* (HODRICK; PRESCOTT, 1997). No presente trabalho, o filtro é pela primeira vez considerado, para a decomposição de sinais de tensão, em suas componentes cíclicas e de tendência, para posterior obtenção de atributos e análise por algoritmos inteligentes. Em conjunto com o filtro HP, é considerada, também, a transformada rápida de Fourier (FFT) e o valor eficaz do sinal de tensão ( $V_{rms}$ ) para obtenção de variáveis indicadoras da presença de distúrbios. Estas abordagens proveem informações que se complementam e ajudam na detecção e na classificação de distúrbios.

Uma frente de pesquisa, em classificação *on-line* de dados sequenciais (fluxos de dados) como aqueles encontrados, nos sistemas elétricos descritos anteriormente, é denominada Sistemas Inteligentes Evolutivos (GOMIDE; PEDRYCZ, 2007; LUGHOFER, 2011a). 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 *on-line* e, muitas vezes, em tempo real, determinar gradualmente tanto a sua estrutura quanto a seus parâmetros (ANGELOV; KASABOV, 2006; LEITE, 2012; LEITE et al., 2011a).

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 (ANGELOV; FILEV; KASABOV, 2010; LEITE, 2012). 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 (ANGELOV; FILEV; KASABOV, 2010; GOMIDE; PEDRYCZ, 2007).

## 1.2 Motivação

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 *on-line* é pelo de 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 (ANGELOV; FILEV; KASABOV, 2010; BOUCHACHIA, 2010; GABRYS; PETRAKIEVA, 2004; LEITE, 2012).

Atualmente é importante considerar o aumento das *smart grids* (redes inteligentes de energia) no sistema elétrico. 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 (DI SANTO et al., 2015; EL-HAWARY, 2014; RIBEIRO et al., 2013). Neste contexto, o fluxo de energia elétrica e de informações se dá de forma bidirecional. Assim, a energia tradicionalmente gerada, transmitida e distribuída de forma radial, a partir de instalações das concessionárias, poderá, também, ser gerada e integrada às redes elétricas a partir de unidades consumidoras. Com base neste 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.

Em princípio, os problemas relacionados com a qualidade da energia elétrica começam, quando um equipamento alimentado pela rede elétrica deixa de funcionar como deveria. Assim, uma lâmpada que apresenta variações luminosas, um motor que sofre vibrações mecânicas, equipamentos operando com sobreaquecimento, proteção atuando intempestivamente, capacitores com sobretensões ou sobrecorrentes podem ser indícios de sérios problemas elétricos. Se tais problemas não forem adequadamente tratados, poderá haver prejuízos materiais (redução da vida útil ou até queima de transformadores, motores, capacitores e equipamentos eletrônicos sensíveis), bem como ocorrer problemas envolvendo pessoas (incômodo visual pelo efeito de cintilação, incômodo auditivo pela ressonância eletromagnética) (DECKMANN; POMILIO, 2010).

Conforme Deckmann e Pomílio (2010), existem estudos que mostram os custos relacionados com perda de QEE. Em McGranaghan e Roettger (2002) menciona-se que a

indústria de manufatura americana tem custos da ordem de 10 bilhões de dólares associados à interrupção de processos produtivos. Outro estudo, realizado na Europa, apresentado em fevereiro de 2002, indica que os custos associados com vários tipos de distúrbios podem chegar a 1,5% do PIB do país (POWER QUALITY IN EUROPEAN ELECTRICITY SUPPLY NETWORKS, 2004). Além dos valores atualmente serem elevados, estima-se que tais custos aumentem se não forem adotadas soluções em curto prazo. Isso se deve aos efeitos cumulativos que a baixa QEE pode impor, seja por meio da redução da vida útil de equipamentos, limitação da capacidade efetiva dos equipamentos, mau funcionamento de máquinas além das perdas elétricas em si. Ganhos mínimos com relação ao desempenho de métodos de monitoramento da qualidade de energia podem ser traduzidos em considerável redução de custos.

### **1.3 Objetivos**

Este trabalho tem por objetivo principal apresentar modelos inteligentes evolutivos como proposta de solução para o problema de detecção e classificação de padrões de distúrbios em sinais de tensão. Modelos são muito importantes à questão da qualidade da energia, 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 claras: detectar e classificar distúrbios na rede elétrica em tempo real. A detecção e a classificação devem acontecer em modo *on-line*, em tempo real e devem apresentar boa precisão e baixo custo computacional.

Os métodos e modelos discutidos neste trabalho são comparados com outros métodos da literatura de inteligência computacional a fim de verificar sua eficiência e complexidade computacional. Para o desenvolvimento deste trabalho, foi realizada pesquisa bibliográfica sobre os assuntos: qualidade de energia, reconhecimento de padrões e inteligência evolutiva, no sentido de se obter subsídios adicionais que contribuíssem para o enriquecimento do trabalho.

### **1.4 Organização do Trabalho**

Após este breve capítulo introdutório, no capítulo 2 realiza-se uma revisão do estado da arte da área de qualidade de energia elétrica, bem como dos modelos que são considerados para a extração e seleção de parâmetros dos sinais elétricos com distúrbios de QEE. Contém parte da teoria de reconhecimento de padrões, útil para fundamentação deste estudo, uma explanação dos fundamentos do filtro Hodrick-Prescot, da transformada rápida de Fourier e de cálculo de valor eficaz da tensão.

No capítulo 3 descrevem-se os sistemas evolutivos que são levados em consideração para tratar o problema de detecção e classificação de distúrbios. São consideradas versões adaptadas da abordagem *fuzzy* evolutiva tipo Takagi-Sugeno eTS (*evolving Takagi-Sugeno*) e da modelagem evolutiva baseada em conjuntos *fuzzy* (FBeM - *Fuzzy Set Based evolving Modeling*).

No capítulo 4 é descrita a metodologia. Neste capítulo, há uma explanação sobre a composição da base de dados e detalha-se o fluxograma que conecta os métodos e abordagens de extração de atributos e classificação de padrões descritos nos capítulos anteriores.

No capítulo 5 relacionam-se os resultados obtidos com a aplicação das abordagens evolutivas eTS e FBeM na detecção e classificação dos distúrbios elétricos. Este capítulo apresenta, ainda, avaliações de desempenho, acurácia e complexidade considerando os métodos apresentados e outros métodos da literatura da área.

No capítulo 6 está a conclusão do trabalho e propostas de trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

### 2.1 Análise da Qualidade de Energia

Do mesmo modo como o médico há de fazer uma pesquisa (consulta) preliminar, a fim de diagnosticar uma doença em um paciente, o técnico deve fazer uma pesquisa (estudo) para diagnosticar as causas de um problema relativo à qualidade da energia elétrica. Como se trata de diagnosticar um problema de compatibilidade eletromagnética, esta pesquisa pode envolver questões que vão além de um simples problema tecnológico (DECKMANN; POMILIO, 2010).

Uma abordagem recomendável incluiria os seguintes passos:

- a) Conhecer os problemas a serem enfrentados.
- b) Estudar as condições locais onde o problema se manifesta.
- c) Medir e registrar grandezas contendo os sintomas do problema.
- d) Analisar dados e confrontar os resultados obtidos com estudos ou simulações.
- e) Diagnosticar a causa do problema e propor soluções.

Segundo Deckmann e Pomílio (2010), cada um desses passos requer certo conhecimento ou estudo específico. Quando se tem uma ideia de como os problemas se manifestam, das suas causas, dos seus efeitos e das soluções usuais, fica mais fácil chegar a um diagnóstico correto. Conhecer as condições locais é fundamental para levantar as hipóteses que levam às causas do problema. As circunstâncias locais, muitas vezes, interferem na forma em que os sintomas se apresentam ao observador. Por exemplo, o afundamento da tensão pode ser a causa da falha na partida de um motor (dimensionamento errado do alimentador) ou a consequência (curto-circuito no enrolamento, falta de fase, etc.). Escolher corretamente os instrumentos de medida e os locais mais adequados, para a sua instalação, pode ser decisivo a fim de se conseguir detectar e quantificar o problema. Por exemplo, surtos rápidos de elevação de tensão podem passar despercebidos, mesmo quando se utilizam osciloscópios rápidos, caso se o nível de *trigger* não for ajustado adequadamente. Conhecer a faixa de frequências do distúrbio, também, é importante para escolher o tipo de registrador que deve ser usado. Fenômenos térmicos, por exemplo, costumam ser lentos, requerendo registradores contínuos para longos períodos de medição.

Eventos intermitentes ou espúrios podem requerer registradores contínuos para a sua detecção. Fenômenos periódicos, como ressonâncias harmônicas ou modulação de amplitude,

podem requerer analisadores de espectro em frequência. A interpretação dos dados, muitas vezes, exige certo conhecimento sobre técnicas de medição. Isso é válido, particularmente, aos analisadores de espectro em razão das limitações impostas pelo truncamento do sinal amostrado.

O efeito de vazamento espectral (*aliasing*), causado pelo truncamento da amostragem, pode ser confundido com componentes inter-harmônicas ou modulantes, que, na verdade, não existem. Dependendo do princípio de funcionamento do instrumento, as medidas podem ser contaminadas erroneamente pela presença de harmônicos. Modelos de simulação, também, são úteis para validar encontrar e validar soluções. Modelos físicos ou matemáticos, que permitem realizar simulações computacionais, muitas vezes, ajudam a entender o fenômeno e permitem descobrir em que condições o problema se manifesta. Por outro lado, uma solução simples às vezes só é encontrada depois que o problema foi exaustivamente estudado através de simulação (DECKMANN; POMILIO, 2010; DUGAN et al., 2003).

## 2.2 Itens de Qualidade de Energia

Os distúrbios de QEE são divididos em duas categorias que requerem diferentes tipos de análise. São elas: variações de QEE e eventos de QEE (BOLLEN et al., 2009). As variações de QEE são pequenos desvios da tensão nominal, tais como: variações de tensão, variações de frequência, desbalanceamentos trifásicos, presença de harmônicos e inter-harmônicos e flutuações de tensão. Já os eventos de QEE correspondem aos desvios maiores, no sinal de tensão, tais como: interrupções, afundamentos de tensão, transitórios impulsivos e transitórios oscilatórios.

A Tabela 1 mostra as categorias dos itens de QEE e as características típicas dos fenômenos que contribuem para a perda da qualidade do suprimento elétrico. As amplitudes de tensão típicas dos sinais são dadas em pu<sup>1</sup>. Após a tabela, são apresentadas as definições (DUGAN et al., 2003; OLIVEIRA, 2000) e outros aspectos importantes, como causas e consequências, relacionados a cada item.

---

<sup>1</sup> O sistema "por unidade" ou, brevemente, sistema pu consiste na definição de valores de base, para as grandezas (tensão, corrente, potência, etc.), seguida da substituição dos valores das variáveis e constantes (expressas no Sistema Internacional de unidades) pelas suas relações com valores de base pré-definidos.

Tabela 1 - Categorias e características de distúrbios nos sistemas elétricos

<b>Categoria</b>	<b>Conteúdo Espectral Típico</b>	<b>Duração Típica</b>	<b>Amplitude de Tensão Típica</b>
<b>1. Transitórios</b>			
Impulsivos	5 ns - 0,1ms	<50 ns > 1 ms	
Oscilatórios	5 kHz - 5 MHz	5 $\mu$ s - 50 ms	0,4 pu
<b>2. Variações de Curta Duração</b>			
<b>2.1. Instantânea</b>			
Afundamento de tensão		0.5 - 30 ciclos	0,1 - 0,9 pu
Elevação de tensão		0.5 - 30 ciclos	1,1 - 1,8 pu
<b>2.2. Temporária</b>			
Interrupção		3 s - 1 minuto	<0,1 pu
Afundamento de tensão		3 s - 1 minuto	0,1 - 0,9 pu
Elevação de tensão		3 s - 1 minuto	1,1 - 1,2 pu
<b>3. Variações de Longa Duração</b>			
Interrupção Sustentada		>1 minuto	0,0 pu
Afundamento de tensão		>1 minuto	0,8 - 0,9 pu
Elevação de tensão		>1 minuto	1,1 - 1,2 pu
<b>4. Distorção da Forma de Onda</b>			
Nível CC		permanente	0 - 0,1%
Harmônicos	ordem 0 - 100th	permanente	0 - 20%
Inter-harmônicos	0 - 6 kHz	permanente	0 - 2%
<i>Notching</i>		permanente	
Ruído	faixa ampla	permanente	0 - 1%
<b>5. Flutuação de Tensão</b>	<25 Hz	intermitente	0,1 - 7%

Fonte: Adaptado de Dugan et al. (2003).

### 2.2.1 Transitórios

Transitórios eletromagnéticos são manifestações ou respostas elétricas locais ou nas adjacências, advindas de alterações súbitas nas condições operacionais de um sistema de energia elétrica. Em geral, a duração de um transitório eletromagnético é muito pequena, mas

de grande importância, uma vez que os equipamentos presentes nos sistemas elétricos estarão submetidos a grandes solicitações de tensão ou corrente.

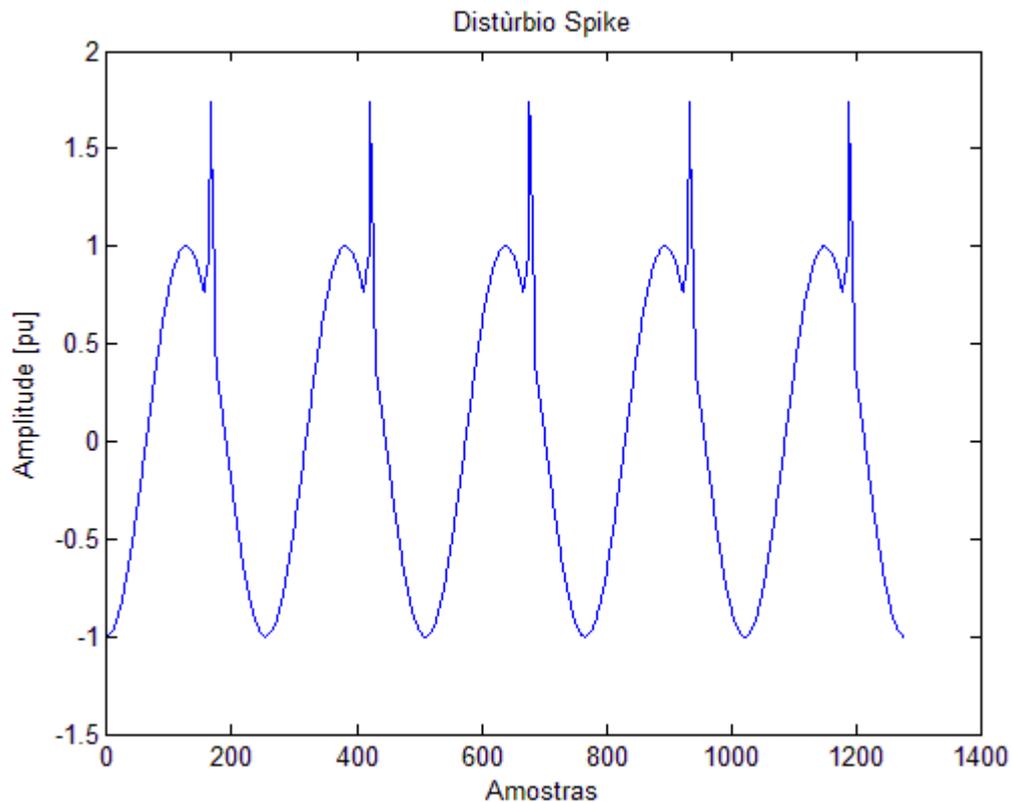
Os transitórios podem ser classificados em dois grupos distintos: transitórios impulsivos, causados por descargas atmosféricas e os transitórios oscilatórios, causados por chaveamentos no sistema de energia elétrica.

### **2.2.1.1 Transitórios Impulsivos**

Um transitório impulsivo pode ser definido como uma alteração repentina, nas condições de regime permanente da tensão, corrente ou ambas. Este transitório caracteriza-se por apresentar impulsos unidirecionais em polaridade (positivo ou negativo) e com frequência bastante diferente daquela da rede elétrica, causados, em geral, por descargas atmosféricas. Os transitórios impulsivos são definidos por um tempo de subida e outro de descida do impulso, os quais, também, podem ser expressos pelo seu conteúdo espectral. Para exemplificar, um impulso transitório definido como 1,2 x 50 ms e 2.000 V significa que o impulso atinge seu valor máximo de 2.000 V, em um tempo de 1,2 ms e, posteriormente, decai até a metade de seu valor máximo em 50 ms.

Um caso particular de um transitório impulsivo, não causado por descargas atmosféricas, são os *spikes*. O *spike* é um transitório formado por uma rápida sobretensão, seguida de uma subtensão, ambos da ordem de micro ou milissegundos. Esse distúrbio assemelha-se a uma agulha. A sobretensão, geralmente, atinge amplitudes que vão de uma e meia a quatro vezes a tensão nominal e a subtensão pode atingir até metade da tensão nominal, conforme a Figura 1. O *spike*, também, pode ser esporádico ou periódico. Sua principal causa é o chaveamento de cargas indutivas como inversores de frequência, conversores CC, entre outras.

Figura 1 - Distúrbio *Spike* no chaveamento de cargas indutivas.

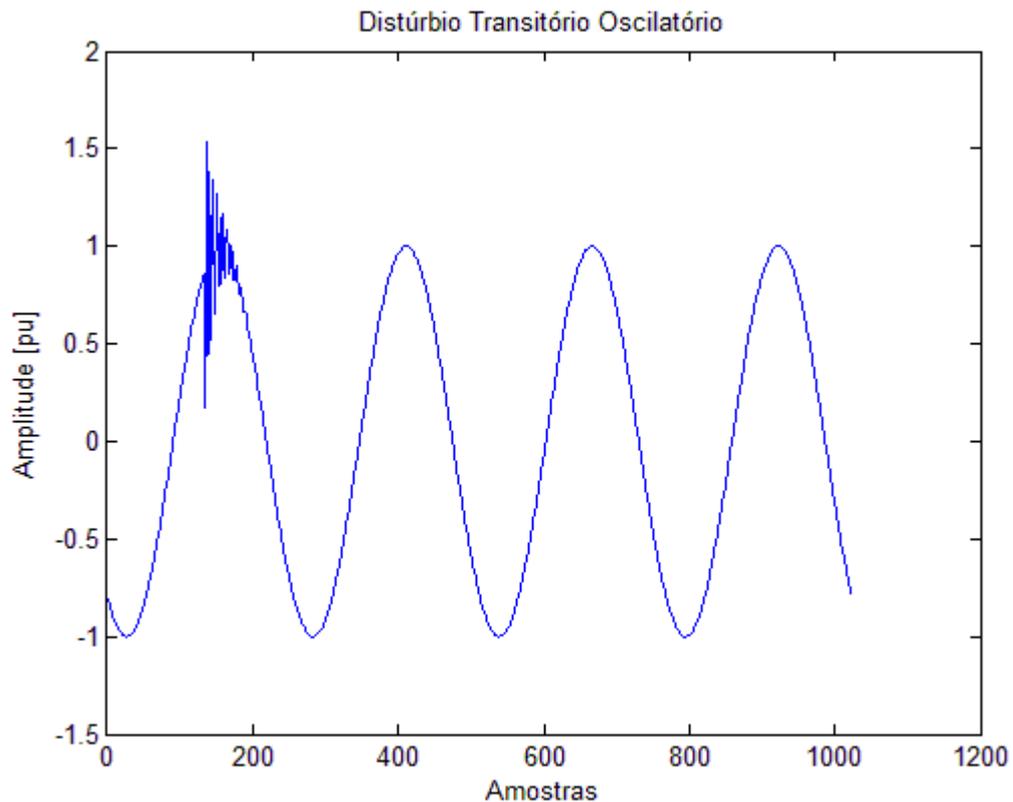


Fonte: Do autor (2017).

### 2.2.1.2 Transitórios Oscilatórios

O transitório oscilatório é caracterizado por uma alteração repentina, nas condições de regime permanente da tensão ou corrente, possuindo valores de polaridade positiva e negativa. Estes transitórios são decorrentes de energização de linhas, corte de corrente indutiva, eliminação de faltas, chaveamento de bancos de capacitores e transformadores, entre outros. Os transitórios oscilatórios de baixa frequência são usualmente encontrados em sistemas de subtransmissão e distribuição e são causados por vários tipos de eventos. O mais comum é a energização de bancos de capacitores. Esta energização, geralmente, resulta em oscilações de tensão com frequência entre 300 e 900Hz, com magnitude máxima em torno de 2,0pu, sendo valores típicos de 1,3 a 1,5pu com uma duração entre 0,5 e 3 ciclos de senoide, dependendo das características de amortecimento do sistema. A Figura 2 ilustra o resultado da simulação de energização de um banco de capacitores.

Figura 2 - Transitório proveniente de simulação do chaveamento de banco de capacitores.



Fonte: Do autor (2017)

Considerando o crescente emprego de capacitores pelas concessionárias, para a manutenção dos níveis de tensão e pelas indústrias atendo em vista a correção do fator de potência, há uma preocupação especial, no que se refere à possibilidade de se estabelecer uma condição de ressonância, em virtude das oscilações de altas frequências entre o sistema da concessionária e a indústria e, assim, ocorrer uma amplificação das tensões transitórias, bem superiores às citadas anteriormente, podendo atingir níveis de 3 a 4pu.

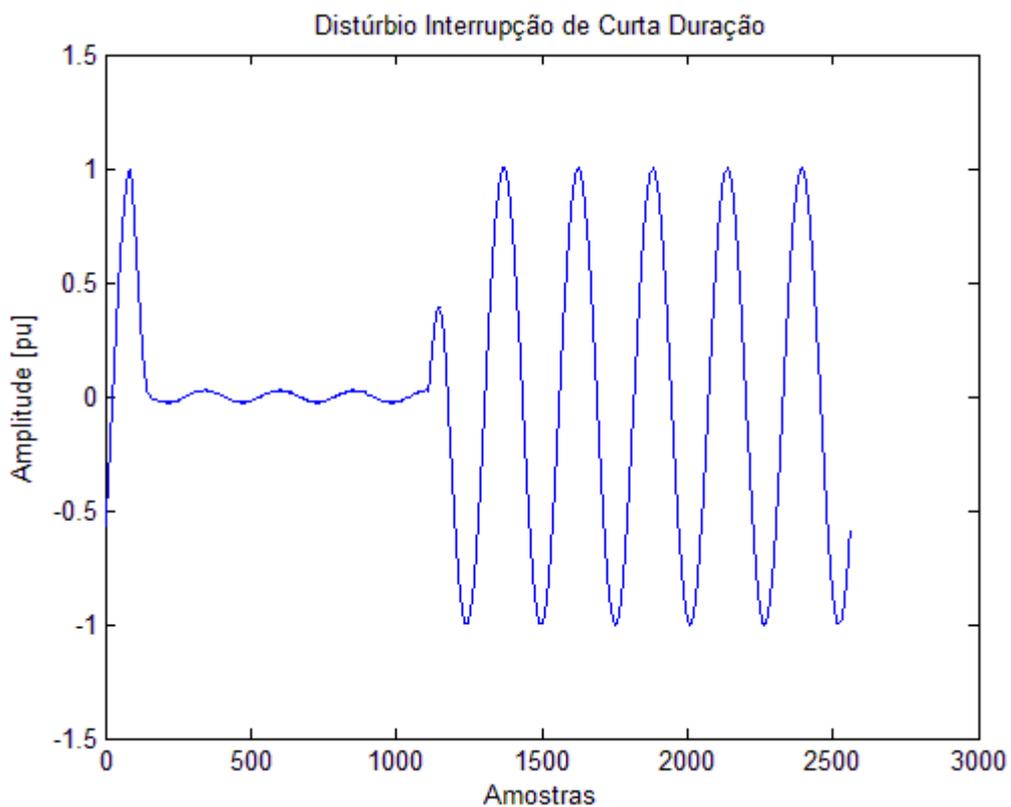
### 2.2.2 Variações de Curta Duração

As variações de tensão de curta duração podem ser caracterizadas por alterações instantâneas ou temporárias, dependendo da duração, conforme definido na Tabela 1. Tais variações de tensão são, geralmente, causadas por condições de falta; energização de grandes cargas, as quais requerem altas correntes de partida; ou por faltas intermitentes nas conexões dos cabos de sistema. Dependendo do local e das condições do sistema, a falta pode causar tanto um afundamento de tensão temporária (*sag*) como uma elevação de tensão (*swell*) ou mesmo uma interrupção completa do sistema elétrico.

### 2.2.2.1 Interrupção de Curta Duração

Uma interrupção de curta duração ocorre, quando a tensão de suprimento decresce para um valor menor que 0,1pu, por um período de tempo não superior a 1 minuto. Este tipo de interrupção pode ser causado por faltas no sistema de energia, falhas de equipamentos e mau funcionamento de sistemas de controle. A duração de uma interrupção, por uma falta no sistema de uma concessionária, é determinada pelo tempo de operação dos dispositivos de proteção. Religadores programados, para operar instantaneamente, geralmente, limitam a interrupção a períodos inferiores a 30 ciclos. Religadores temporizados podem originar interrupções momentâneas ou temporárias, dependendo da escolha das curvas de operação do equipamento. A Figura 3 mostra uma interrupção momentânea.

Figura 3 - Interrupção de curta duração em decorrência de simulação de um curto-circuito.



Fonte: Do autor (2017).

Sendo a falta de caráter temporário, o equipamento de proteção não completará a sequência de operações programadas e o fornecimento de energia não é interrompido. Assim, grande parte dos consumidores, principalmente em áreas residenciais, não sentirão os efeitos da interrupção. Porém algumas cargas mais sensíveis do tipo computadores e outras cargas

eletrônicas estarão sujeitas a tais efeitos, a menos que a instalação seja dotada de unidades UPS (*Uninterruptible Power Supply*), as quais evitarão maiores consequências na operação destes equipamentos na eventualidade de interrupção de curta duração.

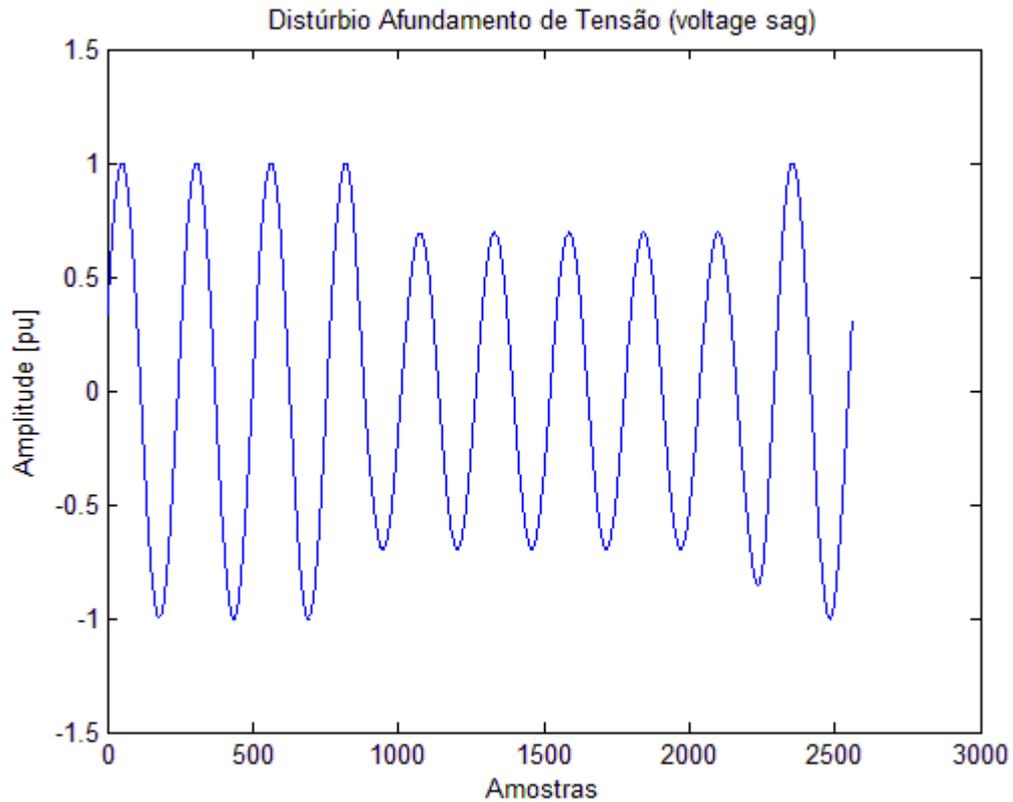
#### **2.2.2.2 Afundamento de Tensão de Curta Duração**

Os afundamentos de tensão de curta duração ou *voltage sags* são caracterizados por uma redução, no valor eficaz da tensão, entre 0,1 e 0,9pu, com duração entre 0,5 ciclos e 1 minuto. Quedas de tensão com período inferior a 10ms e abaixo de 10% não são levadas em consideração. Isto se explica pelo fato de que os distúrbios com período de duração abaixo de 10ms são considerados como transitórios e, quedas de tensão menores que 10% são toleradas pela maioria dos equipamentos elétricos.

Este tipo de distúrbio está associado, principalmente, a curtos-circuitos ocorridos nas redes de distribuição. Porém ele pode também ser causado pela energização de grandes cargas, partida de grandes motores e pela corrente *inrush* de um transformador. A Figura 4 ilustra um afundamento de tensão de curta duração típico, na simulação de uma falta fase-terra. Entretanto as características e o número de afundamentos diante de uma determinada falta dependem de vários fatores como: a natureza da falta, sua posição relativa a outros consumidores ligados na rede e o tipo de filosofia de proteção adotado.

Como efeito destes distúrbios, tem-se, principalmente, a má operação de equipamentos eletrônicos, em especial, de computadores. Estes têm sido alvo de preocupações em órgãos de pesquisa em Qualidade de Energia. Entretanto determinar os níveis de sensibilidade de tais equipamentos torna-se uma tarefa difícil, pelo grande número de medições necessárias em coleta de dados e, ainda, pela dificuldade de se ter equipamentos de medição em condições reais de campo.

Figura 4 - Afundamento de tensão devido a uma falta fase-terra.

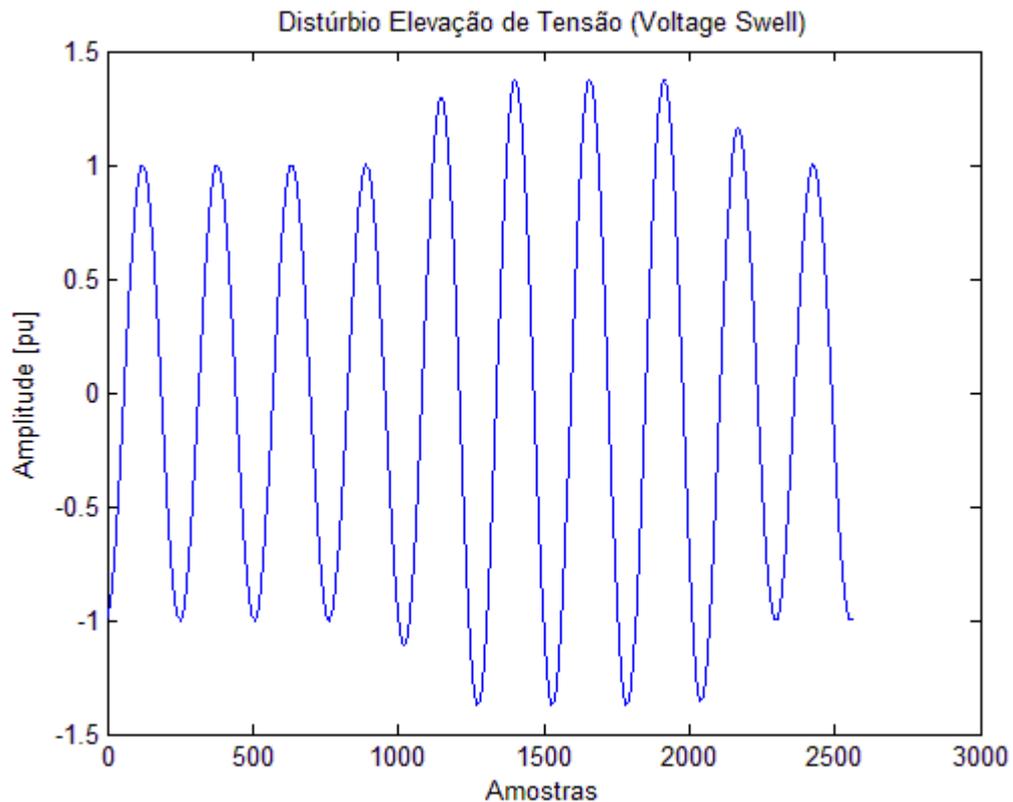


Fonte: Do autor (2017).

### 2.2.2.3 Elevação de Tensão de Curta Duração

Uma elevação de tensão de curta duração ou *voltage swell* é definida como um aumento entre 1,1 e 1,8pu, na tensão eficaz, na frequência da rede, com duração entre 0,5 ciclo a 1 minuto. Assim como os *voltage sags*, os *voltage swells* estão, geralmente, associados a condições de falta no sistema, principalmente, no que diz respeito ao curto-circuito fase-terra. Nestas condições, as fases não defeituosas experimentam uma elevação de tensão. Esta elevação de tensão pode atingir, por exemplo, valores próximos a 1,25pu em um sistema a 4 fios multiterrado.

Figura 5 - Elevação de tensão devido a uma falta fase-terra



Fonte: Do autor (2017).

A Figura 5 ilustra um *voltage swell* como resultado de simulação de uma falta fase-terra. Nota-se, na figura, que este fenômeno pode, também, estar associado à saída de grandes blocos de cargas ou à energização de grandes bancos de capacitores. Porém sua incidência é pequena, se comparada com as elevações de tensão provenientes de faltas fase-terra nas redes de transmissão e distribuição.

As elevações tensões de curta duração são caracterizadas pelas suas magnitudes (valores eficazes) e suas durações. A severidade de um *voltage swell*, durante uma condição de falta, é função do local da falta, da impedância do sistema e do aterramento. Em um sistema aterrado, com valor de impedância de sequência zero finita, as tensões de fase serão 1,73pu durante as condições de falta fase-terra (BARBI, 2006; MAMEDE FILHO, 2002).

### 2.2.3 Variações de Longa Duração

As variações de tensão de longa duração podem ser caracterizadas como desvios que ocorrem, no valor eficaz da tensão, na frequência do sistema, com duração maior que 1 minuto. Estas variações de tensão podem se dar como subtensões, sobretensões ou

interrupções sustentadas. Todas elas são, geralmente, causadas por variações de carga e operações de chaveamento no sistema.

#### **2.2.4 Distorções da Forma de Onda**

A distorção da forma de onda é definida como um desvio, em regime permanente, da forma de onda puramente senoidal, na frequência fundamental e é caracterizada, principalmente, pelo seu conteúdo espectral. Existem cinco tipos principais de distorções da forma de onda: nível CC; harmônicos; inter-harmônicos; *notching* e ruídos.

##### **2.2.4.1 Nível CC**

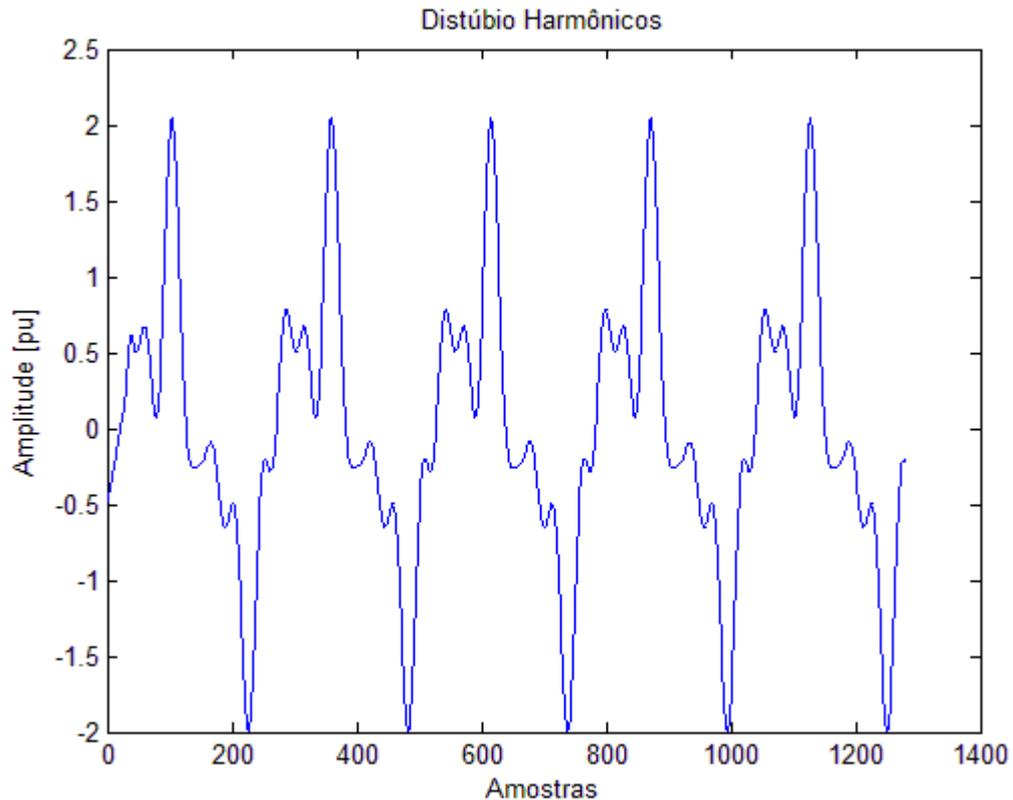
A presença de tensão ou corrente CC, em um sistema elétrico CA, é denominado *DC offset*. Este fenômeno pode ocorrer como resultado da operação ideal de retificadores de meia-onda. O nível CC, em redes de corrente alternada, pode levar à saturação de transformadores, resultando em perdas adicionais e redução da vida útil. Pode, também, causar corrosão dos eletrodos de aterramento e de outros conectores.

##### **2.2.4.2 Harmônicos**

Harmônicos são tensões ou correntes senoidais de frequências múltiplas inteiras da frequência fundamental na qual opera o sistema de energia elétrica. Estes harmônicos distorcem as formas de onda da tensão e corrente e são oriundos de equipamentos e cargas com características não lineares instalados no sistema de energia. A Figura 6 mostra a forma de onda da tensão de uma simulação de cargas não lineares, na qual se evidenciam as deformações na forma de onda resultante.

A distorção harmônica vem contra os objetivos da qualidade do suprimento, promovido por uma concessionária de energia elétrica, a qual deve fornecer aos seus consumidores uma tensão puramente senoidal, com amplitude e frequência constantes. Contudo o fornecimento de energia a determinados consumidores, que causam deformações no sistema supridor, prejudicam não apenas o consumidor responsável pelo distúrbio, mas também outros conectados à mesma rede elétrica.

Figura 6 – Exemplo de distorção harmônica



Fonte: Do autor (2017).

#### 2.2.4.3 Inter-harmônicos

Inter-harmônicos são componentes de frequência, em tensão ou corrente, que não são múltiplos inteiros da frequência fundamental do sistema supridor (50 ou 60 Hz). Quando estas frequências estão abaixo da frequência fundamental do sistema, elas são chamadas de sub-harmônicas. Elas podem aparecer como frequências discretas ou como uma larga faixa espectral.

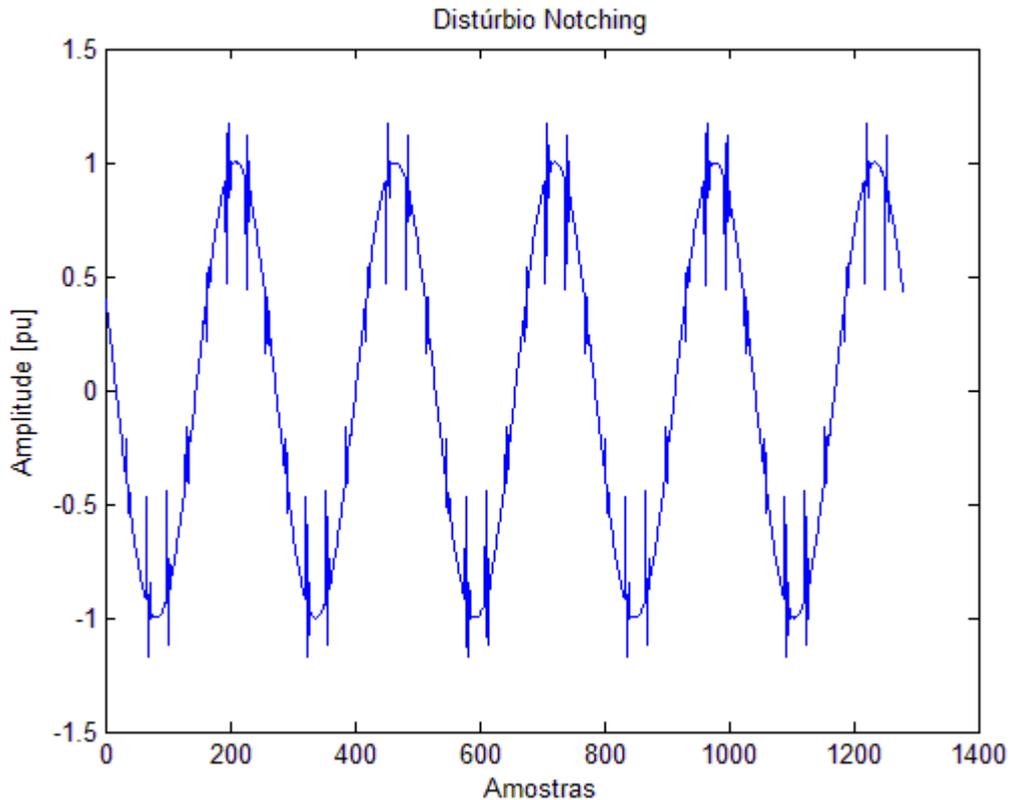
Os inter-harmônicos podem ser encontrados em redes de diferentes classes de tensão. As suas principais fontes são conversores estáticos de potência, cicloconversores, motores de indução e equipamentos a arco.

#### 2.2.4.4 *Notching*

*Notching* é um distúrbio de tensão causado pela operação normal de equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra. Este fenômeno pode ser detectado por meio do conteúdo harmônico da tensão afetada. As componentes de frequência associadas aos *notchings* são de alto valor e, desta forma, não podem ser medidas

pelos equipamentos, normalmente utilizados, para análise harmônica. A Figura 7 ilustra este tipo de distúrbio.

Figura 7 - Distúrbio *notching* em um sistema elétrico.



Fonte: Do autor (2017).

#### 2.2.4.5 Ruídos

Ruído é definido como um sinal elétrico indesejado, contendo uma larga faixa espectral com frequências menores que 200kHz, as quais são superpostas às tensões ou correntes de fase, ou encontradas em condutores de neutro em linhas de sinais. Os ruídos em sistemas de potência podem ser causados por equipamentos eletrônicos de potência, circuitos de controle, equipamentos a arco, retificadores a estado sólido e fontes chaveadas. Eles estão relacionados com aterramentos impróprios. Basicamente, os ruídos consistem de uma distorção indesejada no sinal elétrico que não pode ser classificada como distorção harmônica ou transitório.

A faixa de frequência e o nível da amplitude dependem da fonte que produz o ruído e das características do sistema. A amplitude típica é menor que 1% da tensão fundamental. Ruídos podem causar problemas em equipamentos eletrônicos tais como microcomputadores

e controladores programáveis. O problema pode ser minimizado, utilizando-se filtros, transformadores isoladores e condicionadores de linha.

### **2.2.5 Flutuações ou Oscilações de Tensão**

As flutuações de tensão correspondem a variações sistemáticas dos valores eficazes da tensão de suprimento dentro da faixa compreendida entre 0,95 e 1,05pu. Tais flutuações são, geralmente, causadas por cargas industriais e manifestam-se de diferentes formas, a destacar:

- a) Flutuações Aleatórias: a principal fonte destas flutuações são os fornos a arco, nos quais as amplitudes das oscilações dependem do estado de fusão do material, bem como do nível de curto-circuito da instalação.
- b) Flutuações Repetitivas: dentre as principais fontes geradoras de flutuações desta natureza, há máquinas de solda, laminadores, elevadores de minas, entre outras.
- c) Flutuações Esporádicas: a principal fonte causadora destas oscilações é a partida direta de grandes motores.

### **2.3 Reconhecimento de Padrões**

Reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos em um número de categorias ou classes. Dependendo da aplicação, estes objetos podem ser imagens, formas de onda de sinal ou qualquer tipo de medições que necessitam serem distinguidas (THEODORIDIS; KOUTOUMBAS, 1999).

O reconhecimento de padrões é uma habilidade extremamente desenvolvida nos seres humanos e em alguns animais. O ser humano é hábil em reconhecer faces, vozes, caligrafias e, até mesmo, estados de humor de pessoas conhecidas. Alguns animais, também, têm essa característica bem desenvolvida, tais como os cães farejadores, que vasculham bagagens em aeroportos em busca de drogas. O grau de refinamento do reconhecimento de padrões, por parte do ser humano, pode chegar ao ponto de distinguir uma pintura de um mestre daquela feita por um falsário ou, adiante, pode tomar decisões em um dia de grande movimento de uma bolsa de valores. Assim sendo, pode-se dizer que padrões são os meios pelos quais o mundo é interpretado e, com base nessa interpretação, tomam-se atitudes e decisões. Percebe-se, também, que, nos exemplos citados, essa facilidade no reconhecimento de padrões está vinculada aos estímulos aos quais o indivíduo foi exposto anteriormente. Isso leva a supor que a estrutura selecionada pela evolução biológica, para desempenhar bem a tarefa de reconhecimento de padrões, incorpora alguma forma de aprendizado e evolui com a

experiência. O grande desafio proposto, neste início de século, é o de desenvolver máquinas que tenham esses comportamentos (MARQUES, 1999).

Na área de sistemas de potência com foco em qualidade de energia, o reconhecimento de padrões tem sido cada vez mais usado para diferentes fins. Para detecção e classificação, destacam-se os trabalhos de Ferreira, Seixas e Cerqueira (2015) que usaram um método baseado na análise de componentes independentes de canal único, para classificação de múltiplos distúrbios de QEE; Behera e Nayak (2012) que usaram a transformada *S* para extrair parâmetros e sistemas *fuzzy* e *neuro-fuzzy* na etapa de classificação dos distúrbios de QEE; Ferreira et al. (2014) que usaram uma abordagem direta, baseada em Curvas Principais, para a detecção de distúrbios de qualidade de energia; Lazzaretti, Ferreira e Vieira Neto (2016) que usaram um método de clusterização não supervisionado, para detectar e classificar novos eventos de QEE, que não são previstos no modelo inicial, entre outros.

### **2.3.1 Padrão e Classe**

Entende-se por padrão as propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe ou categoria mediante a interpretação de dados de entrada (TOU; GONZÁLES, 1981). Entende-se por classe ou padrão um conjunto de atributos comuns do objeto de estudo. Assim, reconhecimento de padrões pode ser definido como sendo um procedimento, em que se busca a identificação de certas estruturas, nos dados de entrada em comparação a estruturas conhecidas e sua posterior classificação dentro de categorias. A ideia é de que o grau de associação seja maior entre dados da mesma categoria e menor entre dados de estruturas diferentes. Os dados de entrada são, geralmente, provenientes de sensores e selecionados segundo o conteúdo de informações relevantes para a decisão. Em geral, os dados passam por um processo de redução de dimensionalidade, para que possam ser usados por um classificador, que designará a classe que melhor o representa (MARQUES, 1999; MASCARENHAS, 1987; PRADO; ELFES, 1975).

### **2.3.2 Fases do Reconhecimento de Padrões**

Segundo Marques (1999), um sistema para reconhecimento de padrões engloba três grandes etapas: representação dos dados de entrada e sua mensuração, extração das características e, finalmente, identificação e classificação do objeto em estudo. A primeira etapa refere-se à representação dos dados de entrada que podem ser mensurados a partir do objeto a ser estudado. Essa mensuração deverá descrever padrões característicos do objeto possibilitando sua posterior classificação em uma determinada classe. O vetor que caracteriza perfeitamente um objeto seria de dimensionalidade finita, descrito por um vetor  $\mathbf{x}$ :

$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_n \end{bmatrix} \quad (1)$$

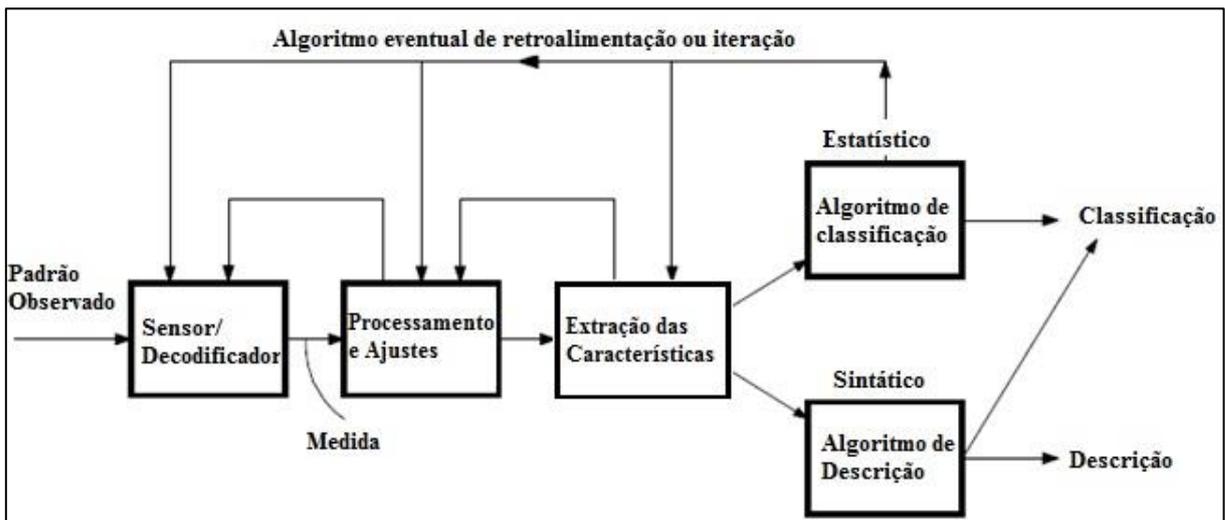
em que  $x_1, x_2, x_3, \dots, x_n$  são suas características.

A segunda etapa consiste na extração de características intrínsecas e atributos do objeto e conseqüente redução da dimensionalidade do vetor padrão. É a fase da extração das características. A escolha das características é de fundamental importância para um bom desempenho do classificador. Esta escolha é feita em vista dos fenômenos que se pretende classificar. Exige-se, portanto um conhecimento específico sobre o problema em estudo. Nesta etapa, os objetivos básicos são: a redução da dimensionalidade do vetor característico, sem que isso implique perda significativa de informação que possa ser relevante à classificação. O objetivo é a redução do esforço computacional e a seleção das características relevantes para a tarefa de classificação (MARQUES, 1999).

A terceira etapa em reconhecimento de padrões envolve a determinação de procedimentos que possibilitem a identificação e classificação do objeto em uma classe. De modo diferente da segunda etapa, aqui a concepção do classificador pode ser abordada de forma abstrata e independente da natureza do problema. Em outras palavras, os métodos usados em reconhecimento de voz, análise de imagens, processamento de sinais de radar, inspeção de materiais, visão por computador ou detecção de anomalias são, muitas vezes, os mesmos. A aplicação de técnicas de reconhecimento de padrões se dá em contextos variados, sem perda de eficiência.

Classificação pressupõe a designação de um objeto a uma determinada classe. O classificador “aprende” a distinguir, entre as classes, aquela à qual o objeto pertence. Padrões de uma mesma classe aglomeram-se em agrupamentos. A Figura 8 apresenta uma estrutura típica de um sistema de reconhecimento de padrões (MARQUES, 1999).

Figura 8 - Esquema geral de um sistema de reconhecimento de padrões



Fonte: Schalkoff (1992).

O sistema, ilustrado na Figura 8, consiste de sensores e um procedimento de aquisição e tratamento de dados, um algoritmo de extração de características e um algoritmo de descrição ou classificação, a depender da aplicação. Complementarmente, é usual que alguns dados, que já tenham sido classificados ou descritos, estejam disponíveis para realizar ajustes no sistema. Esse conjunto de dados é chamado de conjunto de treinamento. A validação da eficácia na utilização de um sistema de Reconhecimento de Padrões é testada, a partir de um conjunto de dados, que não foi usado para o treinamento. A grande dificuldade, na implementação de um classificador de padrões, está justamente na escolha da técnica adequada, para que as fases do reconhecimento de padrões ocorram de modo a representar satisfatoriamente os fenômenos do mundo real (MARQUES, 1999; MASCARENHAS, 1987; PRADO; ELFES, 1975; TODESCO, 1995).

#### 2.4 Filtro de Hodrick e Prescott

Hodrick e Prescott (1997) propuseram um método, um filtro, conhecido pelas iniciais de seus nomes (HP). O método consiste de uma análise estatística, para tratamento de dados indexados no tempo, sinais ou séries temporais. A ideia básica é decompor 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 de que, nessa separação, a variabilidade de baixa frequência representa a tendência em prazo mais longo e a variabilidade de frequência mais alta representa os ciclos mais curtos e/ou aleatórios.

A análise HP é utilizada, para obter uma representação suavizada e não linear de um sinal temporal, sensível a variações tanto em longo como em curto prazo. Ou seja, obtém-se

uma série de tendência não linear suavizada; porém a informação retirada do sinal original pela suavização é mantida, separadamente e pode ser retomada, para análises específicas, se assim for desejado. A análise HP é muito usada, em ciclos reais de negócios (macroeconomia), para extrair a tendência de sequências de dados como, por exemplo, dados de produto interno bruto e de ações. Mais raramente a análise HP é empregada, no contexto de previsão de séries temporais, em geral.

Variáveis extraídas dos sinais decompostos são importantes na distinção entre diferentes tipos de distúrbios. Em um sinal temporal, a componente de tendência é a mudança gradual observada, por meio da variação dos valores de amplitude, ao longo do tempo e que se mantém ao se remover os componentes de ciclos, sazonalidades e fatores aleatórios. Ciclos e sazonalidades são comportamentos estocásticos que acontecem de maneira recorrente ao longo de um período definido. 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, por meio da minimização com respeito a  $\tau_t$  da seguinte expressão:

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

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

Na equação (2),  $T$  é a quantidade de amostras de dados em questão, e  $\lambda$  é um parâmetro que penaliza a variabilidade da tendência. O parâmetro  $\lambda$  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 da equação (2) 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.

Hodrick e Prescott (1997) afirmam que, quando  $\lambda$  aumenta, o desvio padrão da sequência  $c_t$  aumenta e existe uma maior persistência com relação a valores anteriores. Quanto maior  $\lambda$ , mais suave será a tendência. Sendo assim, temos:

- a) Se  $\lambda = 0$ , primeiro termo da equação (2) deve ser zero, para minimizar a função objetivo e, então, resulta que  $\tau_t$  é igual à série de tempo original e  $c_t = 0$ .
- b) Se  $\lambda$  tende ao infinito, o segundo termo da equação (2) deve ser zero para minimizar a função objetivo. Então,  $\tau_t$  será uma tendência linear, isto é, os valores tendencializados são representados por uma linha reta dos mínimos quadrados ordinários e se obtém a máxima ciclicidade possível para  $c_t$ .

Para Hodrick e Prescott (1997), se o componente de tendência e as segundas diferenças do componente de crescimento são variáveis normais idêntica e independentemente distribuídas com média zero e variância  $\sigma_1^2$  e  $\sigma_2^2$  (não o são na realidade), então, a expectativa condicional da tendência no tempo  $t$ , dadas as observações, seria a solução do problema (2), quando  $\sqrt{\lambda} = \sigma_1/\sigma_2$ .

Com base em investigações empíricas, para dados trimestrais, Hodrick e Prescott chegam ao valor de 1.600 para o parâmetro de suavização  $\lambda$ .

## 2.5 Transformada Rápida de Fourier

A Transformada de Fourier é uma das ferramentas mais utilizadas na análise de sinais no domínio da frequência. Foi desenvolvida pelo matemático francês Jean-Baptiste Joseph Fourier (1768-1830) em 1807. Ele propôs que qualquer sinal periódico pode ser descrito por um somatório de senos e cossenos.

Existem duas abordagens, quando é necessária a análise do espectro de frequências: (i) a análise é feita de posse da função analítica; e contínua e (ii) somente se dispõe dos dados coletados em medições, isto é, uma função discreta. Para estes casos, pode-se utilizar a Transformada de Fourier Contínua e Discreta, respectivamente. As equações (3) e (4) representam as definições clássicas da Transformada de Fourier Contínua e sua inversa. Já (5) e (6) representam as definições da Transformada de Fourier Discreta e sua inversa (GAO; YAN, 2011).

$$F(j\omega) = \int_0^{\infty} f(t)e^{-j\omega t} dt \quad (3)$$

$$F(j\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(j\omega) e^{j\omega t} d\omega \quad (4)$$

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

$$x_k = \frac{1}{\Delta t} \sum_{f_n=0}^{(1-N)/T} TFD(f_n) e^{j2\pi f_n k \Delta t} \quad (6)$$

em que  $\omega$  é a frequência angular,  $x_k$  é o sinal discreto,  $T$  é o intervalo de tempo total medido,  $\Delta t$  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.

Conforme Diniz, Silva e Lima Netto (2004), a Transformada Discreta de Fourier (DFT) é muito utilizada, no processamento digital de sinais, com o objetivo de estimar a amplitude e a fase da componente fundamental de um sinal. Esta ferramenta pode extrair características dos espectros dos eventos de qualidade de energia que são interessantes para sua classificação. Neste trabalho, a característica que é extraída, a partir da transformada, é o valor do coeficiente da série de Fourier da frequência fundamental do sinal. A Transformada Rápida de Fourier (FFT) é uma implementação eficiente do algoritmo da DFT no qual sua velocidade, resultado de um número menor de operações, é considerada uma importante vantagem. Com esta ferramenta é possível obter uma estimação da amplitude da componente fundamental e dos harmônicos com razoável precisão. O bom desempenho da FFT é observado na estimacão de amplitude e fase de sinais estacionários, o mesmo não ocorre, quando o sinal sofre mudanças repentinas em suas características como, por exemplo, em transitórios e afundamentos rápidos. Outra desvantagem da FFT é que sua resolução em frequência depende do comprimento da janela de dados ( $N$ ). Quanto maior a janela de dados maior será a resolução em frequência.

## 2.6 Valor Eficaz da Tensão

A raiz do valor quadrático médio ou 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 da

tensão de um sinal elétrico é um bom parâmetro, para detecção de distúrbios, que possuem variações na amplitude do sinal como afundamento de tensão, interrupções e elevação de tensão. O valor eficaz, para uma coleção de  $N$  valores  $\{x_1, x_2, \dots, x_N\}$ , é dado pela seguinte equação:

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2} \quad (7)$$

Para uma função variável contínua  $f(t)$  definida no intervalo  $T_1 \leq t \leq T_2$  o RMS é dado por:

$$x_{RMS} = \sqrt{\frac{1}{T_2 - T_1} \int_{T_1}^{T_2} [f(t)]^2 dt} \quad (8)$$

### 3 SISTEMAS INTELIGENTES EVOLUTIVOS

Nos dias atuais, sistemas computacionais são utilizados em, praticamente, todas as áreas que envolvam trabalho humano. Desde pequenos sistemas utilizados em residências até grandes sistemas utilizados nas empresas, os sistemas computacionais tornaram-se quase imprescindíveis para que as pessoas consigam realizar suas atividades com eficiência. Em muitos casos, os sistemas computacionais substituem a ação humana, para realização de algumas tarefas, tornando o processo em questão automatizado, com o objetivo de oferecer às pessoas mais segurança, conforto ou, então, liberá-las para a realização de outras tarefas. Entretanto, com a evolução tecnológica, muitos problemas do mundo real se tornam cada vez mais complexos, exigindo, para sua solução, sistemas computacionais com características ditas “inteligentes”, tais como aprendizado e raciocínio baseado em conhecimento.

Nas últimas décadas, sistemas computacionais inteligentes, baseados em redes neurais artificiais, sistemas fuzzy e algoritmos evolucionários têm sido propostos (LOPES; TAKAHASHI, 2011; TANSCHKEIT, 2004). 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 essa 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 (ANGELOV; KASABOV, 2006; KASABOV, 2007; LEITE, 2012; LUGHOFER, 2011a) 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.

#### 3.1 Conceitos

Sistemas inteligentes evolutivos são sistemas, baseados em redes neurais artificiais, regras *fuzzy*, ou redes *neuro-fuzzy*, capazes de, a partir de dados de entrada adquiridos em modo *on-line* e, muitas vezes, em tempo real, determinar gradualmente tanto a sua estrutura quanto seus parâmetros (ANGELOV; KASABOV, 2006). A aplicação de sistemas inteligentes evolutivos tem crescido, nos últimos anos, visto que muitos trabalhos na literatura apresentam casos de aplicação com sucesso, em problemas complexos do mundo real, envolvendo modelagem, controle, classificação ou previsão (ANGELOV; FILEV; KASABOV, 2010; BOUCHACHIA, 2010; GABRYS; PETRAKIEVA, 2004; LEITE, 2012).

Esses sistemas evolutivos são diferentes de sistemas ditos adaptativos. Os últimos visam apenas adaptar parâmetros dos modelos em questão. Sistemas evolutivos, também, são diferentes de sistemas que empregam algoritmos evolucionários (LOPES; TAKAHASHI, 2011). Os últimos empregam um processo, baseado em operadores de seleção, cruzamento e mutação, para evolução de uma população de indivíduos, que tem desempenho melhor na resolução de um problema (ABRAHAM; GROSAN, 2008). Sistemas adaptativos são mais apropriados para aplicações cujas mudanças no ambiente são relativamente lentas. Sistemas evolucionários se adaptam/evoluem, em geral, em modo *off-line* e, portanto, não são convenientes para tratamento do problema em questão neste trabalho (ANGELOV; KASABOV, 2006).

Um aspecto importante de sistemas inteligentes evolutivos é que há diferentes abordagens teóricas e práticas que podem ser utilizadas à sua implementação, tais como os sistemas baseados em redes neurais artificiais, em regras *fuzzy*, em agentes inteligentes ou, ainda, sistemas híbridos (ANGELOV; FILEV; KASABOV, 2010). Independentemente da abordagem a ser utilizada, as principais características de modelos evolutivos são:

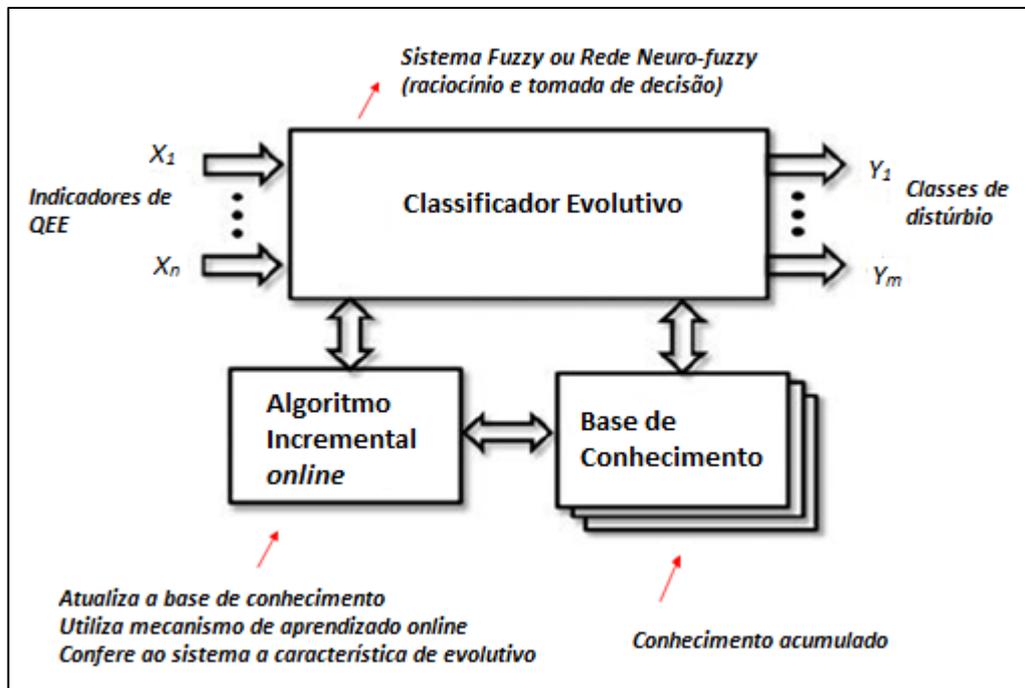
- a) A sua estrutura não é fixa e não é definida *a priori*: ela se desenvolve (expande ou retrai) naturalmente à medida que o sistema evolui;
- b) Os seus parâmetros são ajustados conforme o sistema se desenvolve;
- c) O seu funcionamento é contínuo, ocorrendo aprendizado em modo *on-line* e, muitas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

O desenvolvimento dos sistemas evolutivos é inspirado na forma de evolução natural de indivíduos, especialmente humanos. Na natureza, os indivíduos evoluem, durante a sua vida, de forma gradual e contínua, a partir do aprendizado e da utilização do conhecimento acumulado. As experiências vividas pelo indivíduo permitem que ele se torne cada vez mais apto a superar as dificuldades impostas pelas mudanças no ambiente e assim ser capaz de resolver problemas cada vez mais difíceis (INÁCIO, 2014; KASABOV, 2007).

A Figura 9 ilustra de forma genérica o esquema de um sistema evolutivo. O principal componente da estrutura é o sistema inteligente em si (por exemplo, uma rede neural artificial, um sistema *fuzzy* ou uma rede *neuro-fuzzy*). 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 *on-line*, o que confere ao sistema a característica de evolutivo e certa capacidade de resolver novos problemas.

Figura 9 - Esquema de um sistema inteligente evolutivo.



Fonte: Adaptado de Inácio (2014).

De acordo com Angelov, Filev e Kasabov (2010), sistemas evolutivos podem ser vistos como uma sinergia entre sistemas inteligentes com estrutura expansível para representação da informação (como as estruturas dos sistemas *fuzzy* e das redes *neuro-fuzzy*, mas não necessariamente essas) e métodos incrementais de aprendizado de máquina. A pesquisa para o desenvolvimento de sistemas inteligentes evolutivos tem como foco processos não estacionários, algoritmos de aprendizado computacionalmente eficientes para aplicações em tempo real e modelos flexíveis aos dados, isto é, modelos que possam ser empregados em tarefas tais como modelagem, controle, classificação ou previsão em ambiente *on-line*.

Pode-se afirmar que os principais objetivos a serem alcançados, na implementação de sistemas evolutivos, são o aprendizado contínuo, a capacidade de autoadaptação 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.

### 3.2 O Paradigma da Inteligência Evolutiva

Inácio (2014) declara que o paradigma dos sistemas evolutivos surgiu, a partir de estudos, que tinham como objetivo descobrir novos métodos e técnicas que permitissem tornar sistemas inteligentes conhecidos (especialmente as redes neurais artificiais e os sistemas *fuzzy*) em sistemas cuja estrutura fosse expansível (evolutiva), de forma a se ajustar ao problema em questão, visando a maior desempenho.

Os primeiros trabalhos da área, datados da década de 1990, baseavam-se em redes neurais artificiais e redes *neuro-fuzzy* (KASABOV, 1998). Nesses modelos de redes, a estrutura é flexível e alterada durante o processo evolutivo. Basicamente, duas abordagens, para construção da rede, foram propostas: os neurônios da rede já existem antes do treinamento e somente as conexões entre os neurônios são criadas, durante o treinamento, ou tanto os neurônios quanto as conexões são criadas durante o treinamento. Os primeiros modelos foram aperfeiçoados, em trabalhos seguintes e deram origem a uma variedade de modelos de redes evolutivas (KASABOV, 2007; KASABOV; SONG, 2002).

Nos últimos anos, muitos outros trabalhos sobre sistemas inteligentes evolutivos foram publicados, tratando tanto do desenvolvimento teórico quanto das aplicações desses sistemas aos problemas do mundo real (LUGHOFER, 2011a; LEITE, 2012; ANGELOV; FILEV; KASABOV, 2010; LEITE et al., 2011a), entretanto o número de publicações anuais, ainda, não é tão expressivo. Isso torna a área bastante atrativa em termos de pesquisa e exploração de tópicos.

### 3.3 Sistemas Fuzzy Evolutivos

Sistemas *fuzzy* evolutivos (eFS, *evolving Fuzzy Systems*) (ANGELOV; KASABOV, 2006; KASABOV, 2007; LEITE, 2012; LUGHOFER, 2011a) 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; FILEV; KASABOV, 2010). Para processar

esses dados, novas metodologias foram propostas, principalmente, na linha modelagem *fuzzy* funcional do tipo Takagi-Sugeno. Estas metodologias são, fundamentalmente, capazes de extrair parâmetros e determinar a estrutura de modelos *fuzzy* autonomamente, a partir dos dados, em tempo real (ANGELOV; KASABOV, 2006; GOMIDE; PEDRYCZ, 2007; KASABOV, 1998).

### 3.3.1 Modelo Fuzzy Takagi-Sugeno Evolutivo

Os sistemas *fuzzy* (ZADEH, 1965), baseados em regras do tipo Takagi-Sugeno (TS), são sistemas *fuzzy* nos quais os antecedentes das regras são termos linguísticos e os consequentes são funções das variáveis antecedentes (TAKAGI; SUGENO, 1985). O modelo Takagi-Sugeno evolutivo (eTS, *evolving Takagi-Sugeno*) propõe uma atualização do sistema de forma recursiva. Proposto por Angelov (2002), o modelo eTS determina os antecedentes das regras por um processo de agrupamento não supervisionado e os consequentes por meio de alguma variação de algoritmo de Quadrados Mínimos Recursivo (INÁCIO, 2014; LEMOS, 2011).

A estrutura do modelo 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:

$$R_i : \text{SE } x_1 \text{ é } A_{i1} \text{ E } \dots \text{ E } x_m \text{ é } A_{im} \text{ ENTÃO } y_i = a_{i0} + a_{i1}x_1 + \dots + a_{im}x_m \quad (9)$$

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 consequente 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 esses 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; FILEV, 2004):

$$\mu_{ij} = \exp\left(-\frac{4}{r^2} \|x_j - \check{x}_{ij}\|^2\right) \quad (10)$$

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 segue:

$$\tau_i = \prod_{j=1}^n \mu_{ij}(x_j) = \mu_{i_1}(x_1) \times \dots \times \mu_{i_n}(x_n), i = 1, \dots, g^k \quad (11)$$

A saída do modelo é definida como a média ponderada da saída de cada regra, i.e.:

$$y = \sum_{i=1}^{g^k} \lambda_i y_i, \quad (12)$$

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, 1994a).

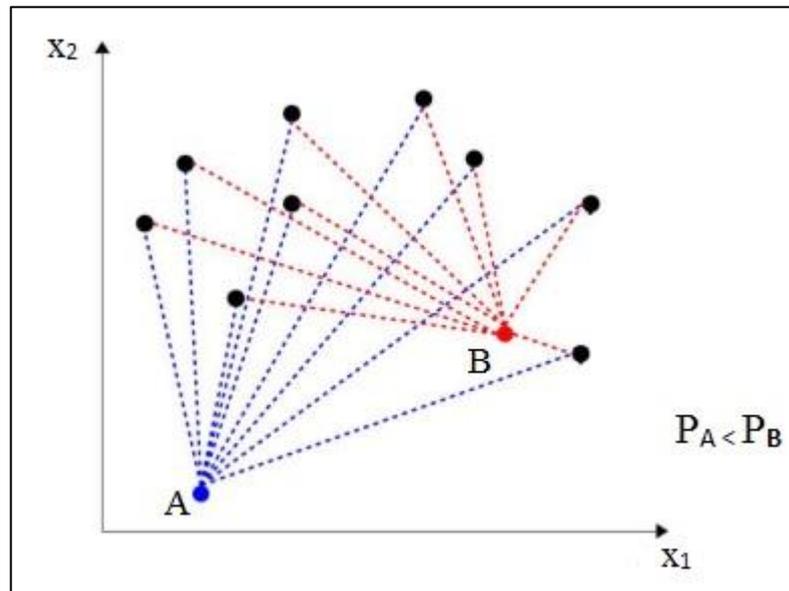
A função potencial de um dado,  $z^k$ , depende de todos os outros dados, por meio de uma medida de proximidade como (ANGELOV; FILEV, 2004):

$$P(z^k) = \frac{1}{k-1} \sum_{i=1}^{k-1} \exp\left(-r \|z^k - z^i\|^2\right), \quad (13)$$

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 10 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 10 - Demonstração da função potencial.



Fonte: Adaptado de Lemos (2011).

Angelov e Filev (2004) propõem uma maneira de calcular o potencial de maneira recursiva, como segue:

$$P^k(z^k) = \frac{k-1}{(k-1)(\vartheta^k + 1) + \gamma^k - 2\nu^k}, \quad (14)$$

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

Os parâmetros  $\vartheta^k$  e  $\nu^k$  são computados, a partir de  $z^k$ , enquanto  $\beta_j^k$  e  $\gamma^k$  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, de acordo com (ANGELOV; FILEV, 2004):

$$P^k(\bar{z}_l) = \frac{(k-1)P^{k-1}(\bar{z}_l)}{k-2 + P^{k-1}(\bar{z}_l) + P^{k-1}(\bar{z}_l) \sum_{j=1}^{m+1} d_j^{k(k-1)}}, \quad (15)$$

em que  $\bar{z}_l$  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 Quadrados Mínimos Recursivo (LJUNG, 1999; YOUNG, 1984) é usado para ajustar os coeficientes das funções consequentes locais ativadas por um vetor de dados de entrada. O Algoritmo 1 apresenta o procedimento de atualização da estrutura do modelo eTS (LEMOS, 2011).

---

Algoritmo 1 - Algoritmo de atualização da estrutura do modelo eTS

---

ler primeiro dado

inicializar primeiro grupo com centro no primeiro dado

**while** existirem entradas **do**

ler novo dado

calcular o potencial,  $P(z^k)$ , do novo dado

**for**  $j = 1, \dots, g^k$  **do**

atualizar o potencial do centro  $\bar{z}_l$ ,  $P^t(\bar{z}_l)$

**end for**

**if**  $P(z^k) > P(\bar{z}_l)$ , **then**

**if**  $z^k$  é próximo o suficiente do centro de algum grupo  $j$  **then**

$z^k$  substitui  $\bar{z}_l$  como centro do grupo  $j$

**else**

criar um novo grupo com centro  $z^k$

**end if**

**else**

atualizar os parâmetros do consequente da regra com centro de grupo com menor distância Euclidiana até o vetor de entrada via Quadrados Mínimos Recursivo.

**end if**

**end while**

---

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 e Filev (2004). Caso contrário, o novo dado irá originar um novo grupo e será centro desse 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  $y$  é uma classe, i.e., 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.

### 3.3.2 Modelagem Evolutiva Granular Baseada em Conjuntos Fuzzy

Segundo Leite (2012), modelagem evolutiva, baseada em conjuntos *fuzzy* (FBeM, *Fuzzy set Based evolving Modeling*), 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 intergranulares. 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 sistemas *fuzzy* linguísticos são mais interpretáveis. Pela combinação destes, FBeM aproveita as vantagens de ambos os sistemas simultaneamente. Em nível prático, especialistas, usualmente, preferem que sistemas on-line deem resultados aproximados tão bem quanto limites de tolerância nas aproximações (LEITE, 2012).

#### 3.3.2.1 Modelagem Fuzzy Evolutiva

FBeM é uma abordagem de modelagem incremental com base em 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 (LEITE, 2012; LEITE et al., 2011b). FBeM lida com questões como bases de dados ilimitadas e escalabilidade (LEITE et al., 2011b).

Modelos FBeM consistem de regras obtidas a partir de um sistema complexo. A aprendizagem em FBeM não requer pré-concepção de regras. Regras são criadas e adaptadas, dinamicamente, consoante 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. Especialistas podem desejar prover uma descrição verbal sobre o processo a partir da intuição e experiência (LEITE, 2012; LEITE et al., 2011a).

Em modelos FBeM, regras  $R^i$  governando grânulos de informação  $\gamma^i$  são do tipo:

$$SE (x_1 \text{ é } A_1^i) E \dots E (x_j \text{ é } A_j^i) E \dots E (x_n \text{ é } A_n^i)$$

$$ENTÃO (y_1 \text{ é } B_1^i) E \bar{y}_1 = p_1^i (x_j \forall j) E$$

...

$$(y_k \text{ é } B_k^i) E \bar{y}_k = p_k^i (x_j \forall j)$$

...

$$(y_m \text{ é } B_m^i) E \bar{y}_m = p_m^i (x_j \forall j)$$

Em que  $x_j$  e  $y_k$  são variáveis do fluxo de dados  $(x, y)^{[h]}$ ,  $h = 1, \dots$ ;  $A_j^i$  e  $B_k^i$  são funções de pertinência construídas a partir dos dados disponibilizados; e  $p_k^i$  são polinômios de aproximação.

As regras  $R^i$ ,  $i = 1, \dots, c$  formam a base de regras. Nota-se que uma regra FBeM combina consequentes linguístico e funcional. O consequente linguístico envolve funções e provê interpretabilidade aos resultados. O consequente funcional oferece aproximação singular e precisão. Com esta estrutura, FBeM toma vantagem de ambos, sistemas linguísticos e funcionais, em uma plataforma de modelagem única.

Um aspecto a ser levado em conta em granulação tipo espalhamento refere-se à busca por uma quantidade factível de partições, posições e tamanhos de grânulos. Essencialmente, FBeM emprega funções de pertinência Gaussianas como objetos granulares formais para envolver a incerteza dos dados (LEITE, 2012; LEITE et al., 2011a).

Conforme Leite et al. (2011a), um conjunto *fuzzy* Gaussiano  $A_j^i = \mathcal{G}(\mu_j^i, \sigma_j^i)$  é caracterizado pelo valor modal  $\mu_j^i$  e espalhamento  $\sigma_j^i$ . Características que fazem esta representação apropriada incluem: (i) facilidade de aquisição dos parâmetros. Os valores modal e de espalhamento são capturados diretamente a partir do fluxo de dados; (ii) suporte infinito. Visto que o domínio dos dados é desconhecido anteriormente ao aprendizado, o suporte de Gaussianas estende-se ao longo de todo o domínio; (iii) suavidade e superfície continuamente diferenciável. O consequente de regras FBeM inclui funções locais afins do tipo:

$$p_k^i = a_{0k}^i + \sum_{j=1}^n a_{jk}^i x_j \quad (16)$$

Em geral, funções  $p_k^i$  podem ser de tipos diferentes e não requerem linearidade. O algoritmo Quadrados Mínimos Recursivo (RLS) é usado para determinar os coeficientes locais  $a_{jk}^i$ . A representação Gaussiana permite sobreposição de todos os grânulos. Consequentemente, cada regra FBeM contribui à saída do sistema. A saída singular de FBeM é determinada como um valor médio ponderado sobre todas as regras:

$$p_k = \frac{\sum_{i=1}^c \min(A_1^i, \dots, A_n^i) p_k^i}{\sum_{i=1}^c \min(A_1^i, \dots, A_n^i)} \quad (17)$$

Isto assegura transição suave entre funções de pertinência.

De forma similar, a abordagem para agrupar dados em conjuntos antecedentes  $A_j^i$ , conjuntos consequentes  $B_k^i$  usam granulação tipo espalhamento, por exemplo, funções Gaussianas  $B_k^i = \mathcal{G}(\mu_k^i, \sigma_k^i)$ . A saída granular  $B_k^i$  provê informação mais importante que a saída numérica  $p_k$ . Não obstante, em problemas de classificação, o termo consequente de uma regra FBeM, de forma similar a uma regra eTS, é essencialmente uma classe.

### 3.3.2.2 Aprendizagem Recursiva *On-line*

Segundo Leite (2012), FBeM aprende a partir de um fluxo  $(x, y)^{[h]}$ ,  $h = 1, \dots$ , em que  $y^{[h]}$  é conhecido dado  $x^{[h]}$  ou se tornará conhecido alguns passos adiante. Cada par  $(x, y)$  é uma observação da função  $f$ . Quando  $f$  muda com o tempo, dizemos que a função é não

estacionária. O procedimento de aprendizagem, para evoluir modelos FBeM, é sumarizado como segue:

---

Início

Faça

- 1: Ler amostra  $(x, y)^{[h]}$ ,  $h = 1, \dots$
- 2: Acomodar possíveis novas informações
  - 2.1: Criar um novo grânulo e uma regra
  - 2.2: Adaptar grânulos e regras existentes
- 3: Descartar a amostra  $(x, y)^{[h]}$
- 4: Otimizar a estrutura granular resultante

Fim

---

Os passos 1 e 3 enfatizam a essência de algoritmos dirigidos a fluxos, isto é, amostras são lidas e descartadas uma por vez. Dados históricos são descartados. Modelos granulares evoluem sempre que novas informações surgem nos dados, passo 2. Quando uma nova amostra não condiz com o conhecimento atual, o procedimento cria um grânulo e uma regra, passo 2.1. Ao contrário, se uma nova amostra ajusta-se ao conhecimento atual, o procedimento adapta grânulos e regras existentes, passo 2.2. Eventualmente, a estrutura resultante pode ser otimizada de acordo com relações intergranulares, passo 4.

### 3.3.2.2.1 Criação de Regras

Em FBeM, regras não existem *a priori*. Elas são criadas e evoluem a medida que os dados são disponibilizados. Um novo grânulo  $\gamma^{c+1}$  e a regra  $R^{c+1}$  que o governa são criados, quando as regras existentes não são suficientemente ativadas, para uma amostra  $x^{[h]}$ . FBeM assume que a amostra traz uma nova informação sobre o processo. Seja  $\rho \in [0, 1]$  um limiar que determina quando criar ou adaptar regras (LEITE, 2012). Se

$$\min(A_1^i, \dots, A_n^i) \leq \rho \quad \forall i \quad (18)$$

então a estrutura FBeM é expandida.

Nota-se que se  $\rho$  é 0, então, o sistema é estruturalmente estável e incapaz de capturar mudanças de conceito. Ao contrário, se  $\rho$  é 1, FBeM cria uma regra, para cada nova amostra, o que não é prático. Adaptabilidade é alcançada em situações intermediárias (compromisso estabilidade-plasticidade) (LEITE, 2012).

O papel de  $\rho$  é fundamental na determinação da granularidade de modelos FBeM. Escolhas de  $\rho$  impactam na precisão e transparência de modelos, resultando em diferentes visões granuladas e níveis de detalhes do mesmo processo. Um novo grânulo  $\gamma^{c+1}$  é inicialmente representado por funções de pertinência,  $A_j^{c+1}$  e  $B_k^{c+1}$ , com parâmetros:

$$\mu_j^{c+1} = x_j^{[h]}, \quad (19)$$

$$\mu_k^{c+1} = y_k^{[h]} \quad (20)$$

$$\sigma_j^{c+1} = \sigma_k^{c+1} = 1/2\pi \quad (21)$$

Esta é a abordagem de Stigler para funções Gaussianas padrões (STIEGLER, 1982).

Os coeficientes de polinômios locais  $p_k^{c+1}$  são:

$$a_{0k}^{c+1} = y_k^{[h]} \quad (22)$$

$$a_{jk}^{c+1} = 0, j \neq 0 \quad (23)$$

Com esta parametrização inicial, a preferência é dada ao projeto de grânulos balanceados, ao longo de suas dimensões, em vez de grânulos com geometria desbalanceada. Consequentemente, FBeM implementa o princípio da granularidade justificada (BARGIELA; PEDRYCZ, 2003) e tende a desenvolver conjuntos *fuzzy* mais específicos no sentido de Yager (2008).

### 3.3.2.2.2 Adaptação de Regras

De acordo com Leite (2012), a adaptação de regras consiste em (i) expandir ou contrair  $A_j^i$  e  $B_k^i$  para acomodar novos dados; (ii) mover grânulos  $\gamma^i$  na direção de regiões de

dados mais densas; e (iii) ajustar os coeficientes de funções locais  $p_k^i$ . Uma regra  $R^i$  é adaptada sempre que é suficientemente ativada por uma amostra  $x^{[h]}$  de acordo com:

$$\min(A_1^i, \dots, A_n^i) > \rho \quad (24)$$

Geometricamente, a amostra pertence a uma região influenciada pelo grânulo  $\gamma^i$ . Para incluir  $x^{[h]}$ , FBeM atualiza o valor modal e o espalhamento das funções de pertinência  $A_j^i$  correspondentes como segue:

$$\mu_j^i(novo) = \frac{(\varpi - 1)\mu_j^i(velho) + x_j}{\varpi^i} \quad (25)$$

$$\sigma_j^i(novo) = \frac{(\varpi^i - 1)}{\varpi^i} \sigma_j^i(velho) + \frac{1}{(\varpi^i - 1)} (x_j - (\mu_j^i(novo)))^2 \quad (26)$$

em que  $\varpi^i$  refere-se ao número de vezes que o  $i$ -ésimo grânulo foi ativado pelo fluxo de dados.

Observa-se que os valores são calculados, recursivamente e, portanto não demandam acumulação de dados. Apenas a regra mais ativa para  $x^{[h]}$  é escolhida para adaptação. A adaptação de conjuntos *fuzzy* consequentes  $B_k^i$  usa dados de saída  $y_k^{[h]}$ . Coeficientes polinomiais  $a_{jk}^i$  são atualizados usando o algoritmo RLS.

### 3.3.2.2.3 Ajuste da Granularidade

O limiar  $\rho$  assume valores no intervalo unitário de acordo com erros de predição. Níveis de ativação de regras para uma dada entrada  $x^{[h]}$  são comparados com o valor de  $\rho^{[h]}$  e definem mudança paramétrica ou estrutural de modelos FBeM. Valores de  $\rho$  influenciam a granularidade e inteligibilidade de modelos. No caso mais geral, FBeM começa a aprender, a partir de uma base de regras vazia, sem qualquer conhecimento sobre a propriedades dos dados. Conseqüentemente, é justo iniciar  $\rho$ , em uma condição intermediária, para permitir estabilidade e plasticidade estrutural igualmente. Usa-se  $\rho^{[0]} = 0.5$  como valor padrão (LEITE, 2012).

Seja  $E$  o erro quadrado máximo entre predições  $p_k(x^{[h]})$  e valores reais  $y_k^{[h]}$ , então:

$$e_k = \left( y_k^{[h]} - p_k(x^{[h]}) \right)^2 \quad k = 1, \dots, m \quad (27)$$

e

$$E = \max(e_1, \dots, e_k, \dots, e_m) \quad (28)$$

admitindo  $E_D$  como o erro máximo aceitável.  $\rho$  aprende valores para si mesmo a partir de:

$$\rho(\text{novos}) = \rho(\text{velho}) + \alpha(E_D - E), \quad (29)$$

em que  $\alpha$  é a taxa de aprendizagem.

Especialistas têm autoridade sobre o valor de  $E_D$  e podem desejar que ele seja zero. Valores muito pequenos de  $E_D$  conduzem  $\rho$  a zero e o levam a sobre ajuste de modelos. A prática sugere abrir mão de certa precisão para alcançar um erro de aproximação aceitável, abstrações granulares úteis e compactação da base de dados em regras interpretáveis. A adaptação recursiva da granularidade alivia escolhas arbitrárias do quão rápido e quão frequente a estrutura dos dados muda (LEITE, 2012).

#### 3.3.2.2.4 Compactação da Estrutura Resultante

Segundo Leite (2012), relacionamentos entre pares de grânulos podem ser fortes o suficiente, para justificar a formação de um grânulo maior e mais abstrato, que herda a essência e natureza de grânulos menores e mais detalhados. A análise de relações intergranulares requer uma métrica para medir a distância entre objetos *fuzzy*. A distância entre dois grânulos,  $\gamma^{i1}$  e  $\gamma^{i2}$ , pode ser calculada da seguinte forma:

$$D(\gamma^{i1}, \gamma^{i2}) = \frac{1}{n} \sum_{j=1}^n \|\mu_j^{i1} - \mu_j^{i2}\|^2 + \sigma_j^{i1} + \sigma_j^{i2} - 2\sqrt{\sigma_j^{i1} \sigma_j^{i2}} \quad (30)$$

Esta medida considera objetos Gaussianos e a especificidade da informação que, por vez, é inversamente proporcional ao espalhamento. FBeM combina grânulos que apresentam o menor valor de  $D(\cdot)$  para qualquer par de grânulos da coleção atual e um critério de decisão. A decisão pode ser baseada em valor limiar  $\Delta$  ou julgamento especialista a respeito da conveniência da mescla destes grânulos.

Um novo grânulo  $\gamma^i$ , combinação de  $\gamma^{i1}$  e  $\gamma^{i2}$ , é construído por funções de pertinência Gaussianas com valor modal:

$$\mu_j^i = \frac{\frac{\sigma_j^{i1}}{\sigma_j^{i2}} \mu_j^{i1} + \frac{\sigma_j^{i2}}{\sigma_j^{i1}} \mu_j^{i2}}{\frac{\sigma_j^{i1}}{\sigma_j^{i2}} + \frac{\sigma_j^{i2}}{\sigma_j^{i1}}}, j = 1, \dots, n \quad (31)$$

e espalhamento

$$\sigma_j^i = \sigma_j^{i1} + \sigma_j^{i2}, j = 1, \dots, n \quad (32)$$

Estas são relações heurísticas que, basicamente, levam em conta a proporção de incerteza, em cada grânulo, para determinar a localização e tamanho do novo grânulo. As mesmas relações de combinação valem para variáveis de saída  $k$ . Os coeficientes dos novos polinômios locais são:

$$a_{jk}^i = \frac{1}{2} (a_{jk}^{i1} + a_{jk}^{i2}), j = 0, \dots, n \quad (33)$$

Naturalmente, combinação de grânulos reduz o número de regras e redundância (LEITE, 2012).

### 3.3.2.2.5 Remoção de Grânulos

Um grânulo deve ser removido da estrutura de FBeM se ele parece ser inconsistente com o conceito atual. Estratégias comuns de remoção consideram (i) apagar grânulos criados a muitas iterações; (ii) excluir grânulos baseados em valores de erro local ou (iii) apagar grânulos inativos. Neste trabalho, optou-se pela estratégia de remover grânulos inativos. Grânulos antigos, ainda, podem ser úteis no ambiente atual enquanto grânulos que geram erros podem ser revistos por um procedimento de adaptação de parâmetros.

Grânulos FBeM são excluídos, quando se tornam inativos, durante um número de iterações,  $h_r$ . Se a aplicação requer memorização de eventos raros ou se sazonalidades são esperadas, então, pode ser o caso de não excluir grânulos. Remover os grânulos inativos, periodicamente, ajuda a manter a base de regras atualizada (LEITE, 2012).

## 4 METODOLOGIA

### 4.1 Obtenção de Sinais para Análise

O presente trabalho baseia-se na análise de sinais de tensão com a presença ou não de distúrbios de qualidade de energia elétrica. Os sinais foram gerados, de forma sintética, de acordo com a regulamentação do IEEE (IEEE, 2009). Todos os sinais gerados apresentam frequência fundamental igual a 60Hz, frequência do sistema elétrico brasileiro. A frequência de amostragem implementada 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<sup>®</sup> 2011 (uso acadêmico - individual), são contaminados por ruído branco gaussiano, com média nula. Configuração do computador utilizado: processador Intel(R) Pentium(R) Dual CPU T2390 1.86GHz, memória RAM 2,00 GB, HDD de 160 GB e sistema operacional de 32 bits. O ruído branco foi definido de modo que atenda a relação sinal-ruído <sup>2</sup> (SNR - *signal-to-noise ratio*) desejada:

$$SNR = 20 \log \frac{A}{\sqrt{2}\sigma} [dB] \quad (34)$$

em que A é a amplitude do sinal fundamental e  $\sigma$  é o desvio padrão do ruído.

Na prática, sinais de tensão medidos nos sistemas elétricos possuem relação sinal-ruído entre 50dB e 70dB (TOMIC; KUSLJEVIC; VUJICIC, 2007). Neste trabalho, são 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 20.000 vetores de dados, variando o número de ciclos da senoide entre um, quatro e dez ciclos, dos quais:

- a) 2.000 não possuem distúrbios.
- b) 2.000 possuem distúrbio transitório oscilatório.
- c) 2.000 possuem distúrbio interrupção curta.

---

<sup>2</sup> A relação sinal-ruído (SNR) pode ser definida como a razão da potência de um sinal e a potência do ruído sobreposto ao sinal, geralmente, expressa em Decibel (dB).

- d) 2.000 possuem distúrbio inter-harmônico.
- e) 2.000 possuem distúrbio harmônico.
- f) 2.000 possuem distúrbio sub-harmônico.
- g) 2.000 possuem distúrbio *spike*.
- h) 2.000 possuem distúrbio *notching*.
- i) 2.000 possuem distúrbio afundamento de tensão.
- j) 2.000 possuem distúrbio elevação de tensão.

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

Sinais com a presença de afundamento ou elevação de tensão possuem amplitudes, sorteadas aleatoriamente, com variação em dois intervalos uniformemente distribuídos:  $[0.1; 0.9]$  pu e  $[1.1; 1.8]$  pu, para afundamento e elevação de tensão, respectivamente.

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 estes múltiplos são maiores que um, tem-se a presença do inter-harmônico, quando são menores que um, tem-se a presença de sub-harmônicos. As frequências e amplitudes dos distúrbios são sorteadas de maneira aleatória. Neste trabalho, as frequências dos sub-harmônicos de interesse estão compreendidas, na faixa entre 5Hz e 55Hz, e dos inter-harmônicos entre 64Hz e 116Hz, já as amplitudes estão uniformemente distribuídas entre  $[0.25; 0.75]$  pu, para ambos os casos.

Sinais com a presença de interrupção 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 *spikes*, 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 0.6pu 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. Este valor é definido como sendo 50% do valor da amplitude da componente fundamental.

Para o distúrbio transitório oscilatório, foram considerados apenas os eventos que ocorrem quando o valor da amplitude do sinal monitorado é superior a 0.45pu de seu valor de pico. A fase de ocorrência do evento é selecionada de maneira aleatória, dentro dos intervalos considerados, seguindo uma distribuição uniforme. A componente oscilatória do distúrbio é modelada como uma senoide amortecida que tem como amplitude inicial o valor da componente fundamental no momento em que ocorre o evento. Uma constante de amortecimento é sorteada, a partir de um intervalo de valores, que proporcionam uma duração do evento entre 5 e 10ms, a distribuição da constante de amortecimento, neste intervalo, segue uma distribuição uniforme, que garante que a duração dos eventos não apresente uma tendência, que seria uma característica específica de um sistema elétrico particular. A frequência de oscilação do evento, também, é definida de forma aleatória, dentro de um intervalo de valores, com distribuição uniforme que varia de 1.000 a 2.500Hz.

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 0.7pu. A duração de cada *notch* é de 0,52ms. 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

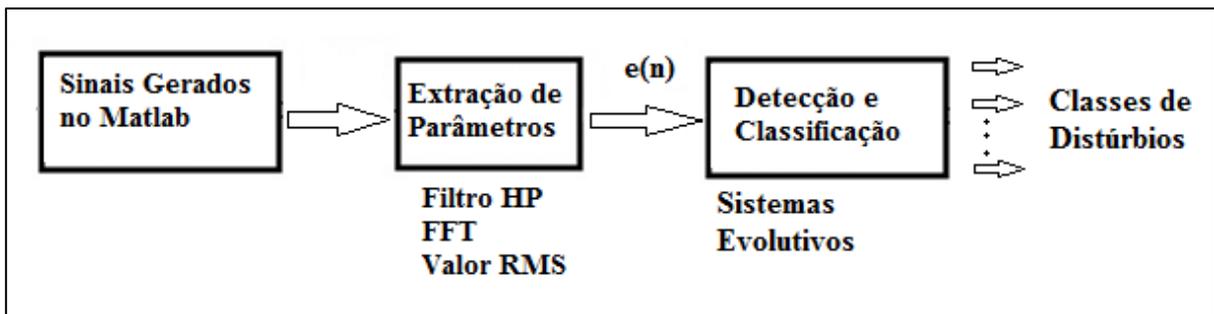
Uma das principais atribuições do monitoramento da qualidade de energia elétrica é a análise dos distúrbios elétricos. Para isso, os sinais de tensão do sistema monitorado devem ser primeiramente armazenados. No entanto o seu armazenamento gera bases de dados de grande extensão. Portanto torna-se importante desenvolver sistemas de monitoramento que armazenem apenas as informações essenciais dos sinais elétricos originais. Espera-se que estes sistemas de monitoramento identifiquem padrões de distúrbios, classifiquem estes padrões e identifiquem a sua fonte geradora. Em geral, esta análise tem sido realizada de forma *off-line* (BEHERA; NAYAK, 2012), baseando-se nos sinais armazenados. De qualquer forma, a detecção deve ser realizada, em tempo real, o que demanda sistemas com rápido processamento de sinais e bom desempenho (FERREIRA, 2010).

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 indicadoras da existência de distúrbios. Neste trabalho, a obtenção

de variáveis indicadoras de distúrbios é feita a partir dos resultados obtidos do emprego do filtro Hodrick-Prescott, da FFT e do valor eficaz. A construção do modelo detector/classificador é realizada em modo *on-line* a partir de um fluxo de dados (dados das variáveis indicadoras). Para isso, são considerados algoritmos estado da arte da teoria de inteligência computacional evolutiva. A construção e adaptação de detectores/classificadores em modo *on-line* é uma clara contribuição do trabalho à área de qualidade de energia.

O esquema geral do sistema de monitoramento, proposto neste trabalho, é ilustrado pelo diagrama em blocos da Figura 11. Assim como nas análises de distúrbios discutidas, nos itens anteriores, o sinal a ser processado pelo classificador é o vetor resultante  $e(n)$  da filtragem do componente fundamental, via filtro Hodrick e Prescott, Transformada Rápida de Fourier e o RMS do sinal.

Figura 11 - Sistema de monitoramento proposto.



Fonte: Do autor (2017).

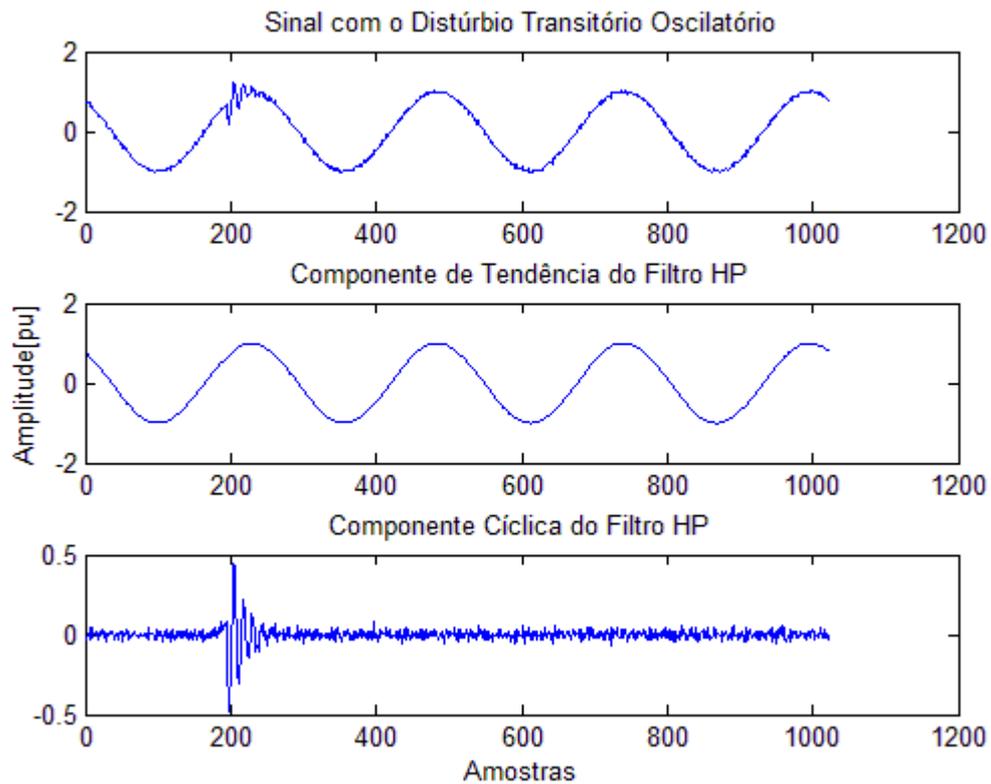
### 4.3 Filtro Hodrick-Prescott

O filtro HP é usado para decompor o sinal elétrico em suas componentes de tendência e cíclica na etapa de extração de parâmetros. As características que são extraídas são as amplitudes máximas e mínimas das duas componentes, que compõem os quatro primeiros dados do vetor de entrada no detector/classificador.

A Figura 12 exemplifica um sinal elétrico típico. O sinal mostrado na figura tem frequência de 60Hz, amplitude de 1pu e relação sinal-ruído (SNR) de 30dB. Porém o sinal está contaminado com o distúrbio transitório oscilatório proveniente do chaveamento de banco de capacitores. O filtro HP decompôs o sinal original, em duas componentes, a saber: 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

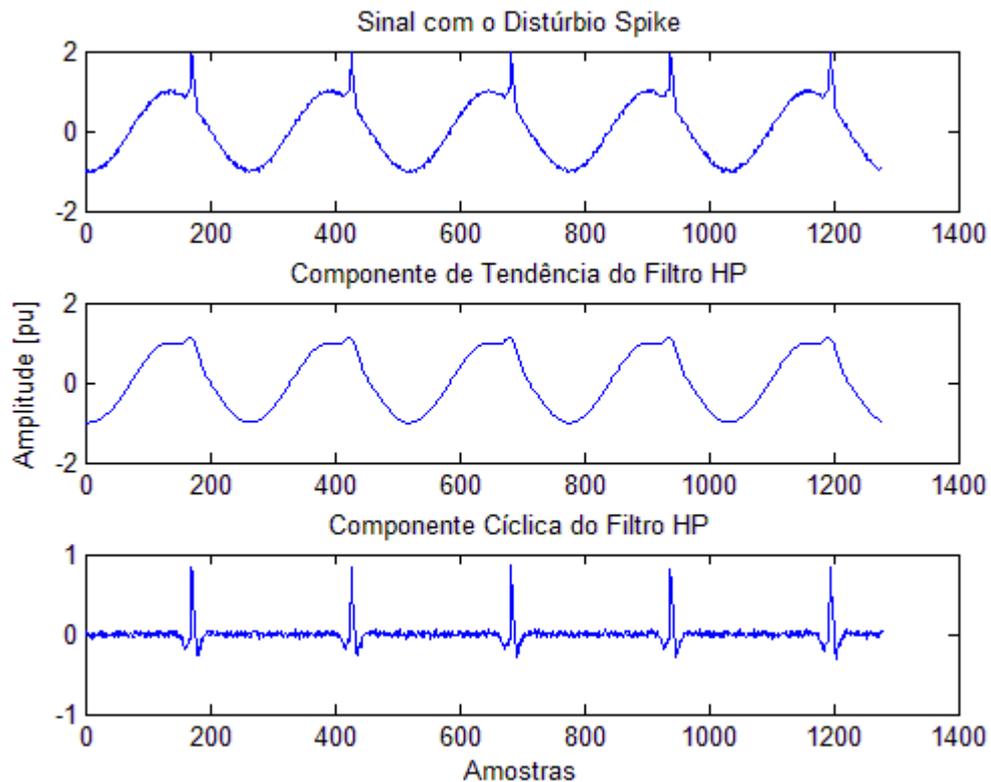
tendência, apresentou-se o sinal de frequência fundamental em 60Hz sem distúrbio e sem ruído também. Portanto a análise das amplitudes dos sinais decompostos se torna bastante viável após a aplicação do filtro.

Figura 12 - Filtro HP para distúrbio transitório oscilatório.



Fonte: Do autor (2017).

Para se realizar uma comparação da aplicação do filtro HP, considera-se o distúrbio *spike* nas mesmas condições que o transitório oscilatório. Percebe-se, na Figura 13, principalmente na componente cíclica do filtro HP, que é possível extrair padrões nos dados, portanto sua aplicação é justificável no modelo proposto neste trabalho.

Figura 13 - Filtro HP para distúrbio *spike*.

Fonte: Do autor (2017).

#### 4.4 Transformada Rápida de Fourier

A FFT é utilizada para extrair o coeficiente da Transformada Discreta de Fourier, para a frequência fundamental, que é o quinto dado do vetor de entrada. Este coeficiente tem seu valor alterado, de acordo com alguns tipos de distúrbios como *sag*, *swell*, interrupção curta.

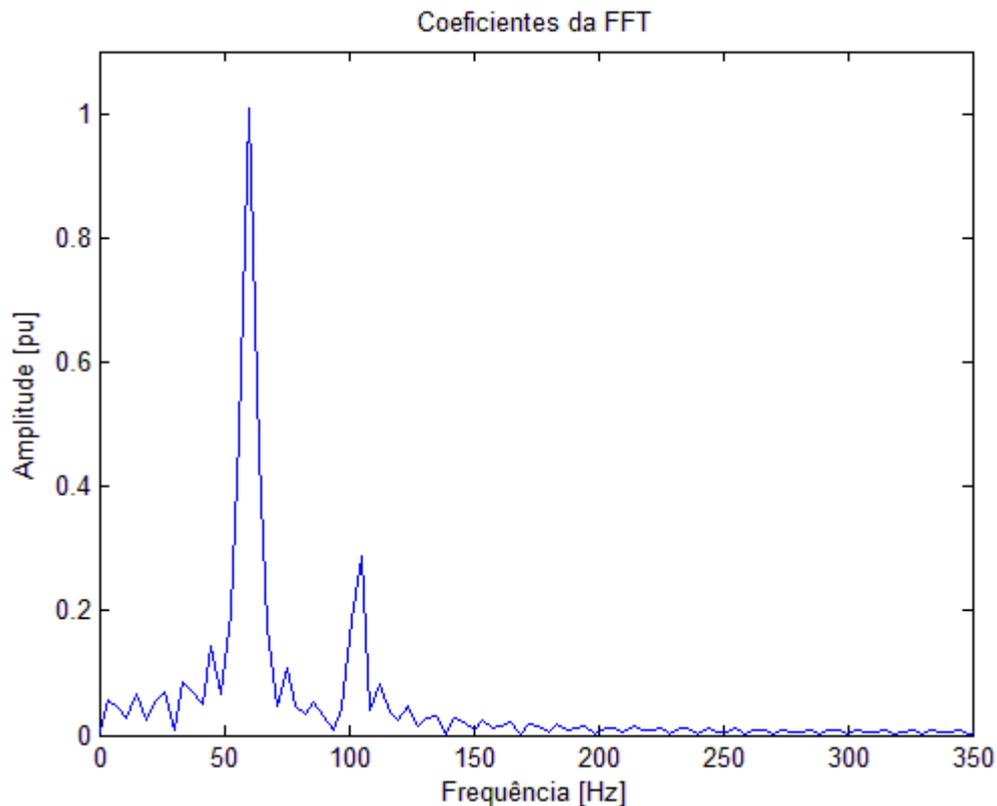
Neste trabalho, foi utilizada a função *fft* do Matlab, que calcula a Transformada de Fourier Discreta utilizando o algoritmo da FFT. Esta função, contudo exige que o número de amostras seja do formato  $2^n$ , podendo gerar alguns problemas. Quando o número de amostras é menor que a potência de 2 mais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

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 em 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, utilizam-se as Figuras 14 e 15. Na Figura 14, tem-se o distúrbio inter-harmônico na frequência de 113Hz. Percebe-se que o valor do coeficiente da FFT, para frequência fundamental do sistema, é 1.

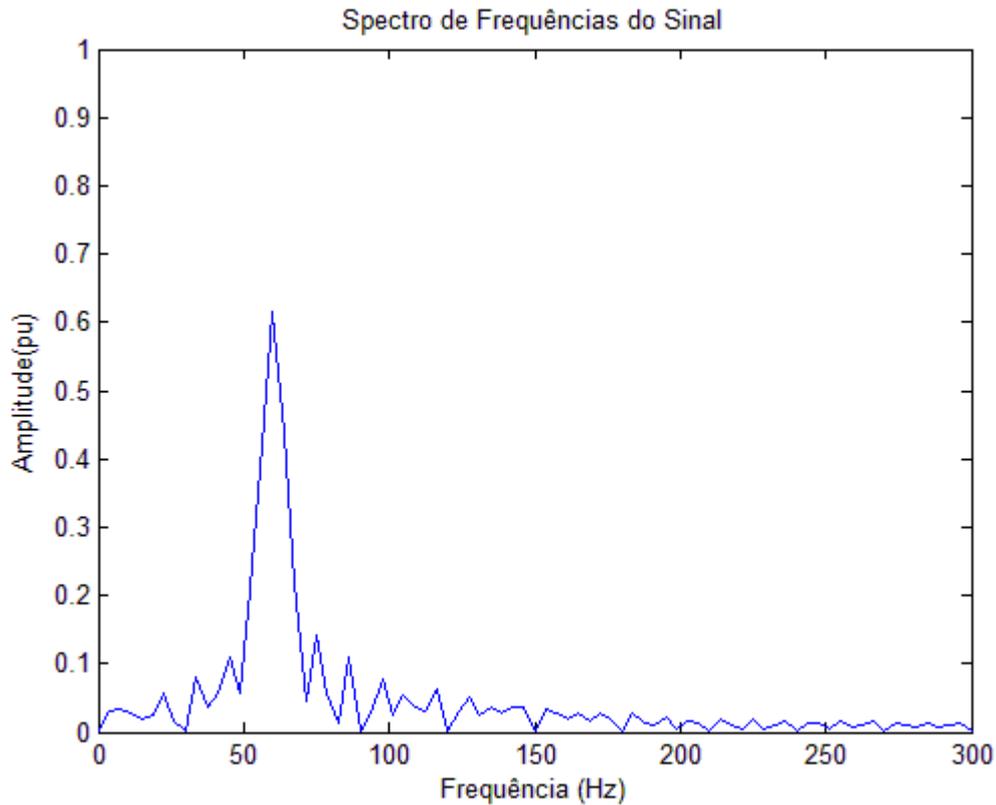
Figura 14 - Coeficientes da Série de Fourier para o distúrbio inter-harmônico.



Fonte: Do autor (2017).

Na Figura 15 tem-se um sinal com a presença do distúrbio interrupção curta. Percebe-se que o valor do coeficiente da FFT, para frequência fundamental do sistema, é 0,61. Portanto esta variável pode ser utilizada, para o modelo proposto, pois consegue extrair padrões em dados.

Figura 15 - Coeficientes da Série de Fourier para o distúrbio interrupção curta.



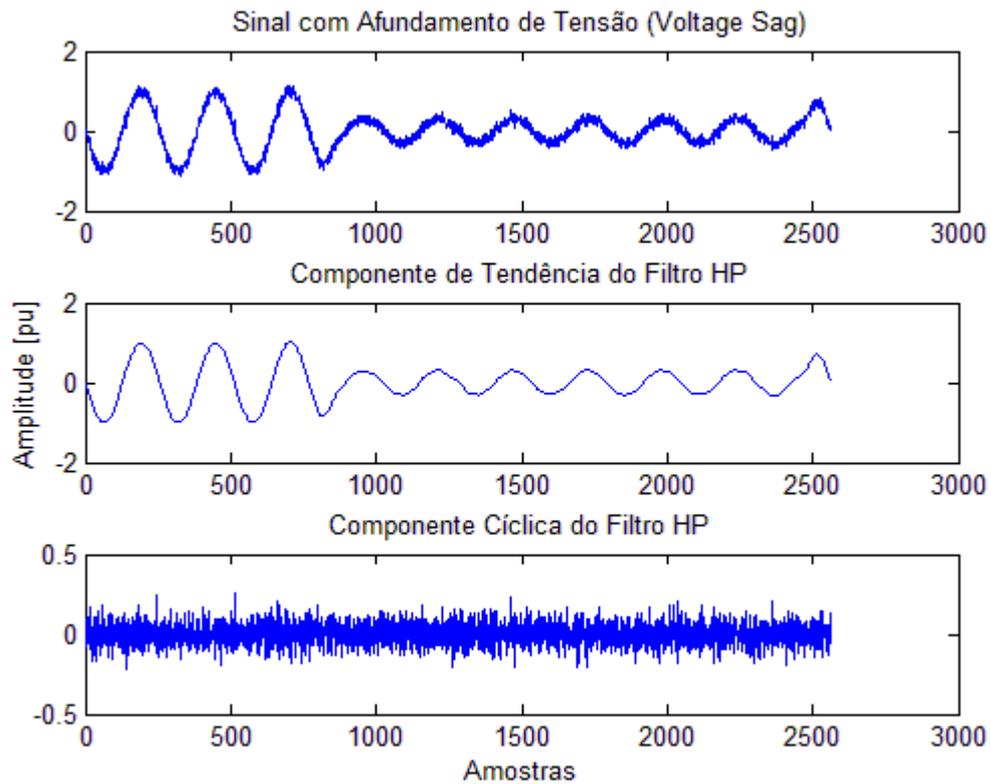
Fonte: Do autor (2017).

#### 4.5 Valor Eficaz da Tensão da Componente de Tendência

Neste trabalho, o valor eficaz da tensão da componente de tendência é utilizado como um dos parâmetros a serem analisados pelos detectores/classificadores propostos. É 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 Figura 16. Isto é de fundamental importância, na análise proposta, pois foram considerados baixos valores de SNR.

Os distúrbios harmônicos, inter-harmônicos e sub-harmônicos, além dos distúrbios que alteram a amplitude do sinal (*sag*, *swell*, interrupção curta), também, provocam variações nos valores RMS da componente de tendência do filtro HP, portanto se justifica sua aplicação como um dado do vetor resultante  $e(n)$  que é apresentado aos sistemas de detecção/classificação *fuzzy*.

Figura 16 - Componentes do filtro HP para sinal com 20 dB de SNR.



Fonte: Do autor (2017).

Gu et al. (2004) propuseram uma técnica que utiliza monitoramento, em tempo real, do valor eficaz da tensão da rede, para a detecção dos distúrbios, comprovando a eficácia deste parâmetro, na análise de distúrbios de QEE. Com estes seis parâmetros selecionados, os sistemas de detecção/classificação propostos mostraram-se eficientes.

## 5 RESULTADOS E DISCUSSÃO

Neste capítulo, os sistemas de detecção e classificação, apresentados no capítulo anterior, são avaliados. Diferente da maioria dos trabalhos de detecção e classificação de distúrbios de QEE conhecidos na literatura, na qual uma base de dados é conhecida *a priori* e os sistemas são implementados de forma *off-line*, o presente trabalho apresenta uma análise de forma *on-line* por um fluxo de dados em tempo real. Desta forma, não há conhecimento *a priori* dos dados a serem analisados. Portanto as técnicas de seleção de variáveis *off-line* não são empregadas. Recentemente metodologias de seleção incremental de variáveis de entrada foram propostas (LUGHOFER, 2011b; SILVA et al., 2012), porém elas não são abordadas neste trabalho.

### 5.1 Detecção de distúrbios de QEE

Neste item, é analisado o desempenho de detecção utilizando os modelo *fuzzy* eTS e FBeM. É simulado um fluxo de dados por classe, a fim de avaliar a capacidade de detecção do distúrbio. Assim, para testar a classe de harmônicos, cria-se um fluxo de dados contendo apenas harmônicos e sinais nominais (sem distúrbios). A escolha da sequência é feita de forma aleatória. Este procedimento é repetido, para todas as classes, de modo que o fluxo de dados conterá apenas distúrbios da classe avaliada e de sinais nominais.

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 terá variação entre 20dB a 60dB, conforme item 4.1 desta dissertação. O índice de desempenho, utilizado pelos modelos propostos, é calculado como se segue

$$Acc(\%) = \frac{acertos}{(acertos + erros)} \cdot 100\% \quad (35)$$

em que 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 2 resume o desempenho de detecção, para os distúrbios considerados neste trabalho, em virtude da relação sinal-ruído e do número de ciclos da senoide considerando o modelo eTS.

Tabela 2 - Desempenho de detecção considerando o modelo eTS.

Distúrbios	Ciclos	20 dB	30 dB	40 dB	50 dB	60 dB
<b>Transitório oscilatório</b>	Dez	98.35	99.29	99.60	99.75	99.76
	Um	99.01	99.42	99.80	99.80	99.90
	Quatro	99.36	99.80	99.65	99.80	99.50
<i>Spike</i>	Dez	99.23	99.70	99.61	99.80	99.90
	Um	95.94	99.80	99.81	99.83	99.85
	Quatro	99.00	99.68	99.88	99.80	99.88
<i>Notching</i>	Dez	99.78	99.80	99.80	99.80	99.90
	Um	99.66	99.80	99.80	99.81	99.88
	Quatro	99.80	99.84	99.80	99.88	99.90
<b>Interrupção curta</b>	Dez	99.80	99.80	99.80	99.80	99.80
	Um	99.70	99.70	99.75	99.78	99.81
	Quatro	99.87	99.88	99.89	99.90	99.91
<b>Sag</b>	Dez	92.20	92.31	92.50	92.72	94.20
	Um	97.82	98.71	98.22	99.00	99.56
	Quatro	95.16	96.67	97.14	98.88	99.00
<i>Swell</i>	Dez	97.24	98.22	98.85	97.73	98.35
	Um	90.61	94.61	96.75	98.40	98.80
	Quatro	97.75	98.50	98.66	98.27	98.04
<b>Harmônico</b>	Dez	97.78	98.78	99.27	99.30	99.46
	Um	92.32	98.28	99.07	99.21	99.38
	Quatro	98.00	98.60	99.30	99.45	99.75
<b>Sub-harmônico</b>	Dez	99.54	99.22	99.60	98.70	98.86
	Um	80.20	85.04	85.54	89.57	98.41
	Quatro	98.12	98.70	98.66	98.15	98.88
<b>Inter-harmônico</b>	Dez	98.23	98.63	98.80	99.09	94.00
	Um	74.97	77.00	80.15	82.52	85.62
	Quatro	94.80	96.48	97.17	97.47	98.11

Fonte: Do autor (2017).

Percebe-se pela Tabela 2 que os melhores resultados foram para os distúrbios transitório oscilatório, *notching*, *spike* e *interrupção curta*, 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 senoide analisados. Para o distúrbio harmônico, o resultado ficou acima dos 99% para SNR de 40dB a 60dB independente do número de ciclos, indicando que a relação sinal-ruído baixa interfere na detecção deste distúrbio. Para os distúrbios *sag* e *swell*, os resultados, também, foram expressivos, ou seja, acima de 95%, porém o desempenho varia, de acordo com a quantidade de ciclos da senoide analisadas, independente da relação sinal-ruído. As menores taxas de

acertos foram encontradas, para os distúrbios inter-harmônicos, sub-harmônicos, para um ciclo de análise. Isto ocorre, porque esses distúrbios alteram, minimamente, a forma de onda do sinal de tensão, o que dificulta sua detecção. Por outro lado, percebe-se que, dependendo da quantidade de ciclos da senoide analisada, os resultados são bons, acima de 95%.

A Tabela 3 resume o desempenho de detecção, para os distúrbios considerados neste trabalho, em função da relação sinal-ruído e do número de ciclos da senoide considerando o modelo FBeM.

Tabela 3 - Desempenho de detecção considerando o modelo FBeM.

Distúrbios	Ciclos	20 dB	30 dB	40 dB	50 dB	60 dB
<b>Transitório oscilatório</b>	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
<i>Spike</i>	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
<i>Notching</i>	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
<b>Interrupção curta</b>	Dez	99.95	99.95	99.97	99.95	99.95
	Um	99.95	99.97	99.95	99.95	99.95
	Quatro	99.95	99.97	99.95	99.95	99.95
<b>Sag</b>	Dez	92.20	90.37	91.82	93.90	93.25
	Um	98.05	97.87	98.27	98.20	97.67
	Quatro	93.42	93.50	95.10	95.10	95.72
<i>Swell</i>	Dez	97.92	98.27	98.42	98.65	98.10
	Um	97.22	97.89	98.25	97.67	97.60
	Quatro	98.85	97.75	98.02	99.00	98.97
<b>Harmônico</b>	Dez	98.20	99.15	99.37	99.27	99.27
	Um	91.91	97.72	98.17	98.90	99.00
	Quatro	97.85	99.27	99.60	99.62	99.55
<b>Sub-harmônico</b>	Dez	99.90	99.95	99.95	99.97	99.85
	Um	92.75	91.12	92.15	90.35	99.92
	Quatro	97.97	99.02	99.32	98.95	99.32
<b>Inter-harmônico</b>	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

Fonte: Do autor (2017).

Nota-se pela Tabela 3, assim como no modelo eTS, que os melhores resultados foram para os distúrbios transitório oscilatório, *notching*, *spike* e *interrupção curta*, mas com uma pequena superioridade do FBeM em relação ao eTS. Para o distúrbio harmônico, o resultado ficou acima dos 99%, para SNR de 30dB a 60dB e quatro e dez para o número de ciclos da senoide (evidenciando a robustez do modelo à baixa relação sinal-ruído), indicando-nos que a análise realizada com um ciclo da senoide somente interfere no desempenho para esse distúrbio. Para os distúrbios *sag*, *swell*, inter-harmônicos e sub-harmônicos, o desempenho foi satisfatório, com o FBeM se saindo melhor que o eTS, principalmente, considerando um ciclo da senoide.

## 5.2 Classificação de distúrbios de QEE

Este item contém a análise de classificação. Considere, inicialmente, o distúrbio *spike*, por ele se manifestar de forma periódica no sinal monitorado e ocorrer em regime permanente no sistema elétrico. Em seguida, é inserido um distúrbio por vez, simulando como o fluxo de dados ocorreria na prática, em que os distúrbios são apresentados, no decorrer do tempo, ao sistema de detecção/classificação. Os algoritmos evolutivos, propostos neste trabalho, realizarão a detecção e a classificação dos distúrbios de maneira recursiva e *on-line*. Estes processos acontecerão ao mesmo tempo, ou seja, os distúrbios são sempre apresentados em uma sequência aleatória, com os sinais sem distúrbios, aos algoritmos evolutivos que realizam a sua detecção e classificação. 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.

A Tabela 4 resume o desempenho de classificação, para o distúrbio *spike*, comparado com o sinal sem distúrbio, e o tempo computacional requerido (em segundos) pelos dois modelos propostos. Os modelos utilizados para a classificação foram o eTS e o FBeM. O índice de desempenho é o mesmo utilizado no item 5.1 desta dissertação, o Acc descrito na Equação (37).

Percebe-se pela Tabela 4 que o desempenho ficou acima de 99% para a maioria dos casos. Somente para 20dB de SNR que o patamar atingido, em todos os casos, não foi alcançado. Isto se deve ao fato de que a baixa relação sinal-ruído, associada a poucos ciclos da senoide, escondem o distúrbio *spike* na forma de onda, prejudicando a detecção/classificação do distúrbio. O tempo médio requerido pelo modelo eTS, para os

quinze casos, foi de 26.01 segundos. O tempo médio requerido pelo modelo FBeM foi de 6.99 segundos. Isso significa que o FBeM tem um tempo de processamento e adaptação do modelo muito menor que aquele demandado pelo eTS. Isto é especialmente importante, na modelagem de processos complexos e de grande porte, uma vez que o número de operações é pequeno e envolve a computação de funções simples.

Tabela 4 - Desempenho de detecção e tempo requerido para distúrbio *spike*.

Distúrbio	Dados	Acc eTS	Acc FBeM	Tempo eTS	Tempo FBEM
<i>Spike</i>	20dB_10ciclos	99.23	99.60	24.4	10.34
	20dB_1ciclo	95.94	92.17	58.3	8.20
	20dB_4ciclos	99.00	99.22	89.4	8.03
	30dB_10ciclos	99.70	99.95	14.3	7.42
	30dB_1ciclo	99.80	99.97	21.8	6.78
	30dB_4ciclos	99.68	99.97	12.5	6.45
	40dB_10ciclos	99.61	99.95	30.5	6.84
	40dB_1ciclo	99.81	99.95	4.1	6.96
	40dB_4ciclos	99.88	99.95	14.5	6.61
	50dB_10ciclos	99.80	99.97	13.0	6.79
	50dB_1ciclo	99.83	99.95	10.3	6.48
	50dB_4ciclos	99.80	99.92	12.9	6.67
	60dB_10ciclos	99.90	99.97	45.3	6.11
	60dB_1ciclo	99.85	99.95	12.4	5.49
	60dB_4ciclos	99.88	99.97	26.5	5.70

Fonte: Do autor (2017).

Os experimentos computacionais foram executados de forma *on-line*, isto é, os parâmetros e a estrutura dos modelos evoluem para todas as amostras do conjunto de dados. 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:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (36)$$

$$NDEI = \frac{RMSE}{\sigma(y_i)} \quad (37)$$

Sendo:  $n$  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.

A Tabela 5 apresenta a medida de erro de classificação dos modelos eTS e FBeM.

Tabela 5 - Medidas de erro de detecção do distúrbio *spike*.

Distúrbio	Dados	RMSE eTS	RMSE FBeM	NDEI eTS	NDEI FBeM
<i>Spike</i>	20dB_10ciclos	0.0438	0.0632	0.0875	0.1265
	20dB_1ciclo	0.1329	0.2779	0.2658	0.5558
	20dB_4ciclos	0.0711	0.0880	0.1421	0.1760
	30dB_10ciclos	0.0270	0.0224	0.0541	0.0447
	30dB_1ciclo	0.0224	0.0158	0.0448	0.0316
	30dB_4ciclos	0.0282	0.0158	0.0564	0.0316
	40dB_10ciclos	0.0313	0.0224	0.0627	0.0447
	40dB_1ciclo	0.0268	0.0224	0.0536	0.0447
	40dB_4ciclos	0.0170	0.0224	0.0340	0.0447
	50dB_10ciclos	0.0224	0.0158	0.0448	0.0316
	50dB_1ciclo	0.0438	0.0224	0.0876	0.0447
	50dB_4ciclos	0.0224	0.0274	0.0447	0.0548
	60dB_10ciclos	0.0158	0.0158	0.0317	0.0316
	60dB_1ciclo	0.0224	0.0224	0.0447	0.0447
	60dB_4ciclos	0.0367	0.0158	0.0735	0.0316

Fonte: Do autor (2017).

De acordo com a Tabela 5, verifica-se que o melhor resultado, no geral, foi obtido pelo modelo FBeM. O menor erro foi obtido para as análises, considerando 10 ciclos e 60dB, 4 ciclos e 60dB, 10 ciclos e 50dB, 1 ciclo e 30dB e 4 ciclos e 30dB de relação sinal-ruído, para o modelo FBeM, evidenciando a robustez do modelo perante diversos valores de SNR e ciclos da senoide analisados.

A partir deste momento, são inseridos os demais distúrbios (um de cada vez), no sistema de classificação, para simular como o fluxo de dados é, na prática, iniciando pelo *notching*, a fim de que se possa avaliar a capacidade dos modelos propostos, na fase de classificação, na qual os distúrbios deverão se diferenciar do sinal sem distúrbio e entre si, também. Nesta etapa, têm-se três classes: dois distúrbios e o sinal sem distúrbio. A Tabela 6 apresenta o desempenho de classificação dos distúrbios *spike* e *notching* e o tempo

computacional, em segundos, requerido pelos dois modelos propostos. A Tabela 7 apresenta as medidas de erro de classificação.

Tabela 6 - Desempenho de classificação e tempo requerido: distúrbios *spike* e *notching*.

<b>Distúrbios</b>	<b>Dados</b>	<b>Acc eTS</b>	<b>Acc FBeM</b>	<b>Tempo eTS</b>	<b>Tempo FBeM</b>
<i>Spike e Notching</i>	20dB_10ciclos	99.36	99.81	36.7	9.16
	20dB_1ciclo	94.06	94.08	48.9	10.81
	20dB_4ciclos	97.64	99.08	76.9	11.19
	30dB_10ciclos	99.29	99.93	33.0	9.18
	30dB_1ciclo	99.75	99.90	19.3	9.66
	30dB_4ciclos	99.22	99.95	64.3	9.15
	40dB_10ciclos	99.11	99.95	29.1	9.76
	40dB_1ciclo	99.76	99.95	33.2	9.62
	40dB_4ciclos	99.85	99.95	23.8	9.86
	50dB_10ciclos	99.73	99.95	26.2	9.57
	50dB_1ciclo	99.39	99.95	19.0	10.01
	50dB_4ciclos	99.57	99.93	13.1	9.78
	60dB_10ciclos	99.63	99.96	24.6	9.92
	60dB_1ciclo	99.71	99.95	29.4	9.67
	60dB_4ciclos	99.62	99.95	32.3	9.75

Fonte: Do autor (2017).

Tabela 7 - Medidas de erro de classificação dos distúrbios *spike* e *notching*.

<b>Distúrbios</b>	<b>Dados</b>	<b>RMSE eTS</b>	<b>RMSE FBeM</b>	<b>NDEI eTS</b>	<b>NDEI FBeM</b>
<i>Spike e Notching</i>	20dB_10ciclos	0.0325	0.0413	0.0797	0.1012
	20dB_1ciclo	0.0995	0.2425	0.2436	0.5939
	20dB_4ciclos	0.0627	0.0944	0.1537	0.2313
	30dB_10ciclos	0.0343	0.0233	0.0841	0.0570
	30dB_1ciclo	0.0204	0.0274	0.0500	0.0671
	30dB_4ciclos	0.0362	0.0158	0.0886	0.0387
	40dB_10ciclos	0.0384	0.0158	0.0942	0.0387
	40dB_1ciclo	0.0199	0.0158	0.0488	0.0387
	40dB_4ciclos	0.0158	0.0158	0.0388	0.0387
	50dB_10ciclos	0.0213	0.0158	0.0521	0.0387
	50dB_1ciclo	0.0319	0.0158	0.0780	0.0387
	50dB_4ciclos	0.0269	0.0233	0.0659	0.0570
	60dB_10ciclos	0.0248	0.0144	0.0607	0.0354
	60dB_1ciclo	0.0221	0.0158	0.0540	0.0387
	60dB_4ciclos	0.0253	0.0158	0.0620	0.0387

Fonte: Do autor (2017).

Nota-se pela Tabela 6 que os modelos se apresentaram bastante robustos com relação às variações dos ciclos de análise e relação sinal-ruído, apresentando queda de desempenho somente na faixa de 20dB. O FBeM apresentou ligeira vantagem com relação ao eTS no desempenho, mas grande vantagem no tempo computacional requerido.

O próximo distúrbio a ser inserido é o inter-harmônico. A ideia é verificar se haverá alguma queda no desempenho de classificação com a inserção de um distúrbio com diferentes características dos anteriores. Nas Tabelas 8 e 9, apresentam-se o desempenho de classificação/tempo requerido e medidas de erro, respectivamente. Neste momento, temos quatro classes.

Tabela 8 - Desempenho de classificação e tempo requerido considerando três distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>Acc eTS</b>	<b>Acc FBeM</b>	<b>Tempo eTS</b>	<b>Tempo FBeM</b>
<i>Spike, Notching e Inter-harmônico</i>	20dB_10ciclos	97.69	99.41	156.2	15.25
	20dB_1ciclo	88.02	91.96	128.0	21.35
	20dB_4ciclos	95.92	96.58	74.1	24.59
	30dB_10ciclos	99.01	98.55	79.1	14.86
	30dB_1ciclo	97.13	98.03	185.0	25.29
	30dB_4ciclos	98.26	96.95	138.2	24.97
	40dB_10ciclos	99.60	99.52	30.8	15.80
	40dB_1ciclo	97.90	97.73	43.5	26.06
	40dB_4ciclos	99.51	98.83	93.1	21.29
	50dB_10ciclos	99.68	99.71	53.7	17.86
	50dB_1ciclo	97.69	97.51	57.1	26.45
	50dB_4ciclos	98.92	99.27	33.4	22.94
60dB_10ciclos	99.77	99.82	40.6	19.32	
60dB_1ciclo	97.66	97.38	104.7	26.60	
60dB_4ciclos	99.24	99.48	182.0	22.72	

Fonte: Do autor (2017).

Tabela 9 - Medidas de erro de classificação considerando três distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>RMSE eTS</b>	<b>RMSE FBeM</b>	<b>NDEI eTS</b>	<b>NDEI FBeM</b>
<b><i>Spike, Notching e Inter-harmônico</i></b>	20dB_10ciclos	0.0566	0.0727	0.1519	0.1952
	20dB_1ciclo	0.1291	0.2067	0.3464	0.5545
	20dB_4ciclos	0.0753	0.1051	0.2021	0.2819
	30dB_10ciclos	0.0387	0.0412	0.1038	0.1104
	30dB_1ciclo	0.0632	0.0487	0.1695	0.1308
	30dB_4ciclos	0.0492	0.0599	0.1319	0.1606
	40dB_10ciclos	0.0237	0.0261	0.0635	0.0700
	40dB_1ciclo	0.0541	0.0516	0.1451	0.1386
	40dB_4ciclos	0.0261	0.0394	0.0701	0.1058
	50dB_10ciclos	0.0211	0.0190	0.0567	0.0510
	50dB_1ciclo	0.0567	0.0540	0.1521	0.1449
	50dB_4ciclos	0.0388	0.0323	0.1041	0.0866
	60dB_10ciclos	0.0180	0.0186	0.0483	0.0500
	60dB_1ciclo	0.0570	0.0553	0.1531	0.1483
	60dB_4ciclos	0.0325	0.0269	0.0871	0.0721

Fonte: Do autor (2017).

Percebe-se pela Tabela 8 que houve uma queda, no desempenho dos classificadores, considerando um ciclo da análise da senoide. Isto se deve ao fato de que o distúrbio inter-harmônico é difícil de caracterizar com apenas um ciclo pelos sistemas obtenção de variáveis indicadoras de distúrbios utilizados neste trabalho. Os modelos apresentaram desempenho bem próximos e, no tempo computacional requerido, o FBeM continua melhor.

A seguir, tem-se a inserção do distúrbio transitório oscilatório. Este distúrbio é bem comum, nos sistemas de energia, tanto no sistema supridor quanto no sistema consumidor de energia elétrica, pois é proveniente, principalmente, do chaveamento de bancos de capacitores para correção do fator de potência. Nesta etapa do processo, os modelos de classificação terão que identificar cinco classes:

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

A seguir, têm-se as Tabelas 10 e 11, os desempenhos de classificação/tempo requerido e medidas de erro, considerando quatro distúrbios.

Tabela 10 - Desempenho de classificação e tempo requerido considerando quatro distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>Acc eTS</b>	<b>Acc FBeM</b>	<b>Tempo eTS</b>	<b>Tempo FBeM</b>
<b>Spike, Notching, Inter- harmônico e Transitório oscilatório</b>	20dB_10ciclos	97.34	98.83	156.2	35.15
	20dB_1ciclo	80.71	84.39	128.0	45.58
	20dB_4ciclos	93.59	91.51	74.1	33.84
	30dB_10ciclos	97.56	99.67	79.1	27.78
	30dB_1ciclo	93.82	96.73	185.0	37.78
	30dB_4ciclos	98.10	96.47	138.2	30.93
	40dB_10ciclos	99.17	99.71	30.8	30.86
	40dB_1ciclo	94.86	97.85	43.5	37.79
	40dB_4ciclos	99.14	99.14	93.1	29.60
	50dB_10ciclos	99.18	99.78	53.7	29.44
	50dB_1ciclo	95.25	97.31	57.1	36.74
	50dB_4ciclos	99.11	99.48	33.4	31.04
	60dB_10ciclos	99.22	99.74	40.6	28.34
	60dB_1ciclo	96.05	97.33	104.7	38.44
	60dB_4ciclos	99.10	99.48	182.0	30.31

Fonte: Do autor (2017).

Tabela 11 - Medidas de erro de classificação considerando quatro distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>RMSE eTS</b>	<b>RMSE FBeM</b>	<b>NDEI eTS</b>	<b>NDEI FBeM</b>
<b>Spike, Notching, Inter-harmônico e Transitório oscilatório</b>	20dB_10ciclos	0.0577	0.0602	0.1631	0.1701
	20dB_1ciclo	0.1553	0.2358	0.4392	0.6668
	20dB_4ciclos	0.0895	0.1682	0.2532	0.4757
	30dB_10ciclos	0.0553	0.0289	0.1564	0.0818
	30dB_1ciclo	0.0879	0.0914	0.2487	0.2585
	30dB_4ciclos	0.0489	0.0942	0.1383	0.2665
	40dB_10ciclos	0.0323	0.0288	0.0913	0.0815
	40dB_1ciclo	0.0802	0.0734	0.2267	0.2076
	40dB_4ciclos	0.0329	0.0467	0.0930	0.1321
	50dB_10ciclos	0.0409	0.0233	0.1156	0.0660
	50dB_1ciclo	0.0771	0.0830	0.2181	0.2346
	50dB_4ciclos	0.0405	0.0368	0.1145	0.1042
	60dB_10ciclos	0.0312	0.0272	0.0882	0.0768
	60dB_1ciclo	0.0703	0.0822	0.1988	0.2326
	60dB_4ciclos	0.0336	0.0358	0.0950	0.1012

Fonte: Do autor (2017).

Verifica-se pelas Tabelas 10 e 11 que o desempenho dos modelos FBeM e eTS não se alteraram muito com relação à análise realizada com três distúrbios, ou seja, o transitório oscilatório que foi inserido nesta etapa não afetou o desempenho dos classificadores. Isto porque este distúrbio é bem caracterizado pelos sistemas obtenção de variáveis indicadoras de distúrbios, discutidos no Capítulo 4 desta dissertação. Com relação ao tempo computacional requerido pelos modelos, o FBeM continua a se destacar.

A seguir, tem-se a inserção do distúrbio interrupção de curta duração. Este distúrbio é bem comum nos sistemas supridores de energia elétrica, em razão, principalmente, das faltas que ocorrem por diversos motivos. Nesta etapa do processo, os modelos de classificação terão que identificar seis classes:

- a) Classe 1: distúrbio *spike*.
- b) Classe 2: distúrbio *notching*.
- c) Classe 3: distúrbio inter-harmônico.
- d) Classe 4: distúrbio transitório oscilatório.
- e) Classe 5: distúrbio interrupção de curta duração.
- f) Classe 6: sinal sem distúrbio.

Tabela 12 - Desempenho de classificação e tempo requerido considerando cinco distúrbios.

Distúrbios	Dados	Acc eTS	Acc FBeM	Tempo eTS	Tempo FBeM
<b>Spike, Notching, Inter- harmônico, Transitório oscilatório e Interrupção curta</b>	20dB_10ciclos	86.00	96.01	78.9	41.80
	20dB_1ciclo	74.29	82.63	383.7	62.14
	20dB_4ciclos	85.47	91.43	329.4	46.25
	30dB_10ciclos	98.00	99.60	155.9	38.24
	30dB_1ciclo	86.74	86.10	115.6	47.70
	30dB_4ciclos	91.02	98.11	121.8	41.83
	40dB_10ciclos	98.75	99.68	110.3	42.95
	40dB_1ciclo	91.40	91.40	232.3	50.61
	40dB_4ciclos	94.48	98.90	107.1	42.19
	50dB_10ciclos	98.34	99.72	107.4	39.49
	50dB_1ciclo	95.04	92.95	262.2	52.63
	50dB_4ciclos	98.68	99.00	102.9	41.72
	60dB_10ciclos	99.00	99.74	166.5	38.69
	60dB_1ciclo	94.52	92.15	362.4	51.59
	60dB_4ciclos	97.41	99.10	63.5	39.79

Fonte: Do autor (2017).

Tabela 13 - Medidas de erro de classificação considerando cinco distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>RMSE eTS</b>	<b>RMSE FBeM</b>	<b>NDEI eTS</b>	<b>NDEI FBeM</b>
<b>Spike, Notching, Inter-harmônico, Transitório oscilatório e Interrupção curta</b>	20dB_10ciclos	0.1280	0.3719	0.3746	0.1270
	20dB_1ciclo	0.1732	0.2654	0.5071	0.7770
	20dB_4ciclos	0.1302	0.1571	0.3812	0.4598
	30dB_10ciclos	0.0489	0.0457	0.1431	0.1337
	30dB_1ciclo	0.1244	0.2135	0.3642	0.6249
	30dB_4ciclos	0.1024	0.0816	0.2998	0.2390
	40dB_10ciclos	0.0382	0.0318	0.1117	0.0932
	40dB_1ciclo	0.1001	0.1643	0.2931	0.4811
	40dB_4ciclos	0.0803	0.0542	0.2351	0.1586
	50dB_10ciclos	0.0440	0.0319	0.1287	0.0935
	50dB_1ciclo	0.0761	0.1493	0.2227	0.4370
	50dB_4ciclos	0.0392	0.0515	0.1149	0.1509
60dB_10ciclos	0.0355	0.0298	0.1039	0.0873	
60dB_1ciclo	0.0800	0.1561	0.2342	0.4571	
60dB_4ciclos	0.0549	0.0502	0.1608	0.1469	

Fonte: Do autor (2017).

Mais uma vez, os modelos se mostraram bastante eficazes na classificação dos distúrbios. Nota-se que de 60dB até 30dB de relação sinal-ruído o desempenho de classificação de ambos os modelos, praticamente, não sofreu alterações, evidenciando a robustez dos sistemas a baixos valores de SNR. A inserção de mais um distúrbio (interrupção curta), também, não afetou o desempenho dos classificadores. Pode-se verificar isto comparando as Tabelas 10 e 12. Na Tabela 13, verifica-se que a menor medida de erro foi para 60dB de SNR e dez ciclos de análise da senoide para o FBeM; e a maior medida de erro foi para 20dB e um ciclo de análise para o modelo eTS. Com relação ao tempo computacional requerido pelos modelos, o FBeM continua melhor que o eTS.

O próximo distúrbio a ser inserido é o *swell* (elevação de tensão de curta duração). Este distúrbio, na maioria dos casos, também, está relacionado às faltas no sistema de distribuição de energia, nas quais as fases não envolvidas com curto-circuito sofrem elevação momentânea de tensão. Nas Tabelas 14 e 15, apresentam-se o desempenho de classificação/tempo requerido e medidas de erro, respectivamente. Neste momento, sete classes são classificadas.

- a) Classe 1: distúrbio *spike*.
- b) Classe 2: distúrbio *notching*.
- c) Classe 3: distúrbio inter-harmônico.
- d) Classe 4: distúrbio transitório oscilatório.
- e) Classe 5: distúrbio interrupção de curta duração.
- f) Classe 6: distúrbio *swell*.
- g) Classe 7: sinal sem distúrbio.

Tabela 14 - Desempenho de classificação e tempo requerido considerando seis distúrbios.

Distúrbios	Dados	Acc eTS	Acc FBeM	Tempo eTS	Tempo FBeM
<b>Spike, Notching, Inter- harmônico, Transitório oscilatório, Interrupção curta e Swell</b>	20dB_10ciclos	72.98	89.64	274.1	78.41
	20dB_1ciclo	64.81	80.15	111.4	138.21
	20dB_4ciclos	73.56	89.95	126.5	76.21
	30dB_10ciclos	94.19	98.12	103.4	73.19
	30dB_1ciclo	87.10	92.75	239.7	150.74
	30dB_4ciclos	94.62	97.19	99.9	75.12
	40dB_10ciclos	96.06	98.62	187.5	75.84
	40dB_1ciclo	90.25	92.62	301.4	151.17
	40dB_4ciclos	96.55	98.81	298.5	75.29
	50dB_10ciclos	95.83	98.57	394.0	67.69
	50dB_1ciclo	93.23	93.30	304.9	124.19
	50dB_4ciclos	96.34	98.62	114.8	66.58
	60dB_10ciclos	97.30	98.53	303.5	79.57
	60dB_1ciclo	94.71	92.44	112.2	100.60
	60dB_4ciclos	96.34	98.38	141.1	77.40

Fonte: Do autor (2017)

Tabela 15 - Medidas de erro de classificação considerando seis distúrbios.

Distúrbios	Dados	RMSE eTS	RMSE FBeM	NDEI eTS	NDEI FBeM
<b>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta e Swell</b>	20dB_10ciclos	0.1733	0.1583	0.5199	0.4750
	20dB_1ciclo	0.1977	0.2799	0.5932	0.8397
	20dB_4ciclos	0.1714	0.1809	0.5142	0.5427
	30dB_10ciclos	0.0804	0.0625	0.2411	0.1874
	30dB_1ciclo	0.1198	0.1420	0.3593	0.4260
	30dB_4ciclos	0.0773	0.0814	0.2320	0.2442
	40dB_10ciclos	0.0548	0.0560	0.1645	0.1681
	40dB_1ciclo	0.1041	0.1317	0.3123	0.3950
	40dB_4ciclos	0.0619	0.0541	0.1856	0.1624
	50dB_10ciclos	0.0681	0.0515	0.2043	0.1545
	50dB_1ciclo	0.0867	0.1261	0.2601	0.3782
	50dB_4ciclos	0.0637	0.0557	0.1912	0.1672
	60dB_10ciclos	0.0662	0.0569	0.1986	0.1706
	60dB_1ciclo	0.1121	0.1352	0.3362	0.4055
	60dB_4ciclos	0.0638	0.0601	0.1914	0.1802

Fonte: Do autor (2017).

Percebe-se pelas Tabelas 14 e 15 que o modelo FBeM é superior ao eTS tanto no desempenho quanto no tempo computacional requerido. Nota-se, também, que o modelo FBeM apresentou desempenho acima de 98%, considerando dez ciclos de análise da senoide, para relação sinal-ruído entre 30dB e 60dB. Para análise da senoide em quatro ciclos, o modelo FBeM, também, apresentou resultados satisfatórios. A inserção do distúrbio *swell*, nesta etapa, fez com que o desempenho caísse um pouco. Analisar-se-á o porquê desta queda, no próximo item deste capítulo, em que usaremos a Matriz de Confusão, com o intuito de que se compreenda como as amostras foram classificadas de maneira errada.

O próximo distúrbio a ser inserido é o sub-harmônico. Harmônicos são componentes espectrais nas frequências que são múltiplos inteiros da frequência fundamental do sistema. Inter-harmônicos são componentes espectrais em frequências que são múltiplos não inteiros da frequência fundamental do sistema. Sub-harmônicos são inter-harmônicos com frequências menores do que a frequência fundamental do sistema elétrico (60 ou 50 Hz). Conforme Testa e Langella (2005), sub-harmônicos são gerados por diversas cargas modernas: i) cicloconversores; ii) fornos a arco; iii) retificadores de tensão; iv) sistemas eletrônicos de controle; v) capacitores em série com linhas de transmissão; vi) geradores eólicos; vii) variadores de velocidade. A consequência direta da injeção do sinal de baixa frequência é

distorção da tensão na forma de onda da frequência fundamental do sistema. Nas Tabelas 16 e 17, apresentam-se o desempenho de classificação/tempo requerido e medidas de erro, respectivamente. Neste momento, têm-se oito classes a serem classificadas: *spike*, *notching*, inter-harmônico, transitório oscilatório, interrupção curta, *swell*, sub-harmônicos e sinal sem distúrbio.

Tabela 16 - Desempenho de classificação e tempo requerido considerando sete distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>Acc eTS</b>	<b>Acc FBeM</b>	<b>Tempo eTS</b>	<b>Tempo FBeM</b>
	20dB_10ciclos	85.35	89.11	245.1	124.75
	20dB_1ciclo	56.26	74.28	106.2	123.37
	20dB_4ciclos	69.05	80.95	123.6	121.97
<b>Spike,</b>	30dB_10ciclos	94.09	91.83	212.6	110.65
	30dB_1ciclo	86.93	87.91	246.1	125.50
	30dB_4ciclos	89.41	92.59	165.9	117.21
<b>Notching,</b>	40dB_10ciclos	94.30	93.68	200.9	135.69
	40dB_1ciclo	90.37	86.56	296.6	142.36
	40dB_4ciclos	93.36	94.58	188.1	122.63
<b>Inter-</b>	50dB_10ciclos	95.46	95.83	226.3	127.76
	50dB_1ciclo	90.57	85.22	126.3	130.33
	50dB_4ciclos	92.40	93.05	103.6	149.14
<b>harmônico,</b>	60dB_10ciclos	98.51	98.01	83.3	111.31
	60dB_1ciclo	92.73	90.56	208.2	107.72
	60dB_4ciclos	96.30	94.10	253.4	163.40
<b>Transitório</b>					
<b>oscilatório,</b>					
<b>Interrupção</b>					
<b>curta, Swell e</b>					
<b>Sub-</b>					
<b>harmônicos</b>					

Fonte: Do autor (2017).

Tabela 17 - Medidas de erro de classificação considerando sete distúrbios.

<b>Distúrbios</b>	<b>Dados</b>	<b>RMSE eTS</b>	<b>RMSE FBeM</b>	<b>NDEI eTS</b>	<b>NDEI FBeM</b>
<b>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta, Swell e Sub-harmônicos</b>	20dB_10ciclos	0.1252	0.1473	0.3826	0.4500
	20dB_1ciclo	0.2165	0.2798	0.6614	0.8547
	20dB_4ciclos	0.1821	0.2223	0.5563	0.6791
	30dB_10ciclos	0.0796	0.1345	0.2432	0.4109
	30dB_1ciclo	0.1183	0.1800	0.3615	0.5498
	30dB_4ciclos	0.1065	0.1380	0.3254	0.4217
	40dB_10ciclos	0.0782	0.1154	0.2388	0.3527
	40dB_1ciclo	0.1016	0.1533	0.3104	0.4683
	40dB_4ciclos	0.0843	0.1224	0.2575	0.3740
	50dB_10ciclos	0.0697	0.0747	0.2130	0.2282
	50dB_1ciclo	0.1243	0.1623	0.3799	0.4957
	50dB_4ciclos	0.0902	0.1217	0.2756	0.3719
	60dB_10ciclos	0.0399	0.0357	0.1220	0.1092
	60dB_1ciclo	0.0882	0.1611	0.2696	0.4922
	60dB_4ciclos	0.0629	0.0723	0.1923	0.2209

Fonte: Do autor (2017).

Observa-se, a partir das Tabelas 16 e 17, que o melhor desempenho e menor medida de erro se verificaram, considerando dez ciclos da análise da senoide e 60dB de SNR para os dois modelos considerados. Entre 30dB e 50dB os modelos apresentaram queda de desempenho em comparação com a análise em 60dB, evidenciando que, apesar de ainda ficar acima dos 90%, uma análise satisfatória do distúrbio sub-harmônico requer altos valores de relação sinal-ruído. A média do tempo computacional requerido pelo FBeM foi de 127.5 segundos, enquanto para o eTS a média foi de 185.7 segundos.

O próximo distúrbio a ser inserido é o harmônico. Harmônicos são componentes espectrais nas frequências que são múltiplos inteiros da frequência fundamental do sistema. Geralmente é causado por cargas não lineares. Uma das soluções mais eficazes e importantes, levando em consideração o custo versus benefício, consiste na instalação de filtros harmônicos em derivação nos circuitos de potência. Nas Tabelas 18 e 19, apresentam-se o desempenho de classificação/tempo requerido e medidas de erro, respectivamente. Neste momento, têm-se nove classes a serem classificadas: *spike*, *notching*, inter-harmônico, transitório oscilatório, interrupção curta, *swell*, sub-harmônicos, harmônicos e sinal sem distúrbio.

Tabela 18 - Desempenho de classificação e tempo requerido considerando oito distúrbios.

Distúrbios	Dados	Acc eTS	Acc FBeM	Tempo eTS	Tempo FBeM
	20dB_10ciclos	84.27	83.91	370.9	201.75
	20dB_1ciclo	48.93	67.83	135.4	272.11
	20dB_4ciclos	55.89	76.17	248.4	290.96
<i>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta, Swell, Sub-harmônicos e Harmônicos</i>	30dB_10ciclos	90.51	88.63	625.2	200.70
	30dB_1ciclo	72.25	80.92	379.0	268.66
	30dB_4ciclos	85.55	88.84	336.7	215.26
	40dB_10ciclos	92.37	89.65	182.6	169.59
	40dB_1ciclo	78.72	76.51	255.5	215.03
	40dB_4ciclos	88.19	91.01	313.0	204.79
	50dB_10ciclos	91.26	90.56	229.4	189.65
	50dB_1ciclo	83.70	76.92	319.3	217.13
	50dB_4ciclos	86.73	88.84	140.1	201.85
	60dB_10ciclos	96.74	97.10	272.9	187.56
	60dB_1ciclo	81.35	83.36	235.4	194.80
	60dB_4ciclos	91.72	89.15	411.2	174.34

Fonte: Do autor (2017).

Tabela 19 - Medidas de erro de classificação considerando oito distúrbios.

Distúrbios	Dados	RMSE eTS	RMSE FBeM	NDEI eTS	NDEI FBeM
	20dB_10ciclos	0.1280	0.1966	0.3966	0.6092
	20dB_1ciclo	0.2306	0.3294	0.7146	10.205
	20dB_4ciclos	0.2144	0.2571	0.6642	0.7965
<i>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta, Swell, Sub-harmônicos e Harmônicos</i>	30dB_10ciclos	0.0997	0.1743	0.3088	0.5399
	30dB_1ciclo	0.1539	0.2667	0.4770	0.8264
	30dB_4ciclos	0.1227	0.1931	0.3802	0.5981
	40dB_10ciclos	0.0891	0.1700	0.2761	0.5268
	40dB_1ciclo	0.1489	0.2861	0.4614	0.8865
	40dB_4ciclos	0.1109	0.1677	0.3437	0.5195
	50dB_10ciclos	0.0954	0.1583	0.2956	0.4903
	50dB_1ciclo	0.1303	0.2799	0.4038	0.8673
	50dB_4ciclos	0.1176	0.1865	0.3643	0.5778
	60dB_10ciclos	0.0583	0.0488	0.1806	0.1771
	60dB_1ciclo	0.1394	0.2658	0.4318	0.8236
	60dB_4ciclos	0.0928	0.1734	0.2877	0.5373

Fonte: Do autor (2017).

Percebe-se, mais uma vez, a partir das Tabelas 18 e 19, que o melhor desempenho e menor medida de erro se verificaram, considerando dez ciclos da análise da senoide e 60dB de SNR para os dois modelos considerados. A partir da inserção do distúrbio harmônico, nos sistemas de classificação, nota-se uma queda considerável, no desempenho dos classificadores, principalmente, considerando um ciclo de análise da senoide independente da relação sinal-ruído. Como se trata de um distúrbio com características semelhantes ao inter-harmônico e ao sub-harmônico, ou seja, são distúrbios caracterizados por inserirem componentes de outras frequências no sistema de energia, um ciclo somente de análise não consegue caracterizar bem o distúrbio. Na análise realizada em 10 ciclos da senoide, a diferença no desempenho não foi tão grande com relação aos dados antes da inserção do distúrbio. O melhor resultado de desempenho foi do FBeM, mas o eTS, também, mostrou-se bastante eficaz na classificação dos distúrbios. Com relação ao tempo computacional requerido pelos modelos, FBeM se saiu melhor.

A seguir, é introduzido, nos sistemas de classificação, o último distúrbio: afundamento de tensão (*sag*). Este tipo de distúrbio está associado, principalmente, a curtos-circuitos ocorridos nos sistemas de energia. Porém ele pode, também, ser causado pela energização de grandes cargas, partida de grandes motores e pela corrente *inrush* de um transformador. Uma maneira de mitigar seus efeitos, principalmente em cargas eletrônicas, é a utilização de reguladores de tensão. Finalizando a inserção de distúrbios, têm-se dez classes a serem classificadas: *spike*, *notching*, inter-harmônico, transitório oscilatório, interrupção curta, *swell*, sub-harmônicos, harmônicos, *sag* e sinal sem distúrbio.

Tabela 20 - Desempenho de classificação e tempo requerido considerando nove distúrbios.

Distúrbios	Dados	Acc eTS	Acc FBeM	Tempo eTS	Tempo FBeM
	20dB_10ciclos	83.20	85.85	284.2	325.72
	20dB_1ciclo	51.98	64.74	265.0	312.13
	20dB_4ciclos	76.64	78.90	273.5	382.81
<i>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta, Swell, Sub-harmônicos, Harmônicos e Sag</i>	30dB_10ciclos	89.20	88.09	347.5	336.15
	30dB_1ciclo	76.21	80.07	354.1	363.30
	30dB_4ciclos	72.78	87.57	127.9	300.79
	40dB_10ciclos	88.37	90.63	382.1	317.75
	40dB_1ciclo	80.69	81.26	245.4	330.74
	40dB_4ciclos	87.63	93.40	277.1	366.72
	50dB_10ciclos	90.31	91.09	170.7	281.76
	50dB_1ciclo	81.09	81.67	260.9	276.28
	50dB_4ciclos	84.31	92.12	201.7	283.57
	60dB_10ciclos	93.98	96.29	277.3	266.78
	60dB_1ciclo	81.72	90.18	243.2	296.18
	60dB_4ciclos	85.34	91.97	228.5	292.20

Fonte: Do autor (2017).

Tabela 21 - Medidas de erro de classificação considerando nove distúrbios.

Distúrbios	Dados	RMSE eTS	RMSE FBeM	NDEI eTS	NDEI FBeM
	20dB_10ciclos	0.1308	0.1685	0.4100	0.5280
	20dB_1ciclo	0.2212	0.3153	0.6930	0.9879
	20dB_4ciclos	0.1542	0.2164	0.4832	0.6782
<i>Spike, Notching, Inter-harmônico, Transitório oscilatório, Interrupção curta, Swell, Sub-harmônicos, Harmônicos e Sag</i>	30dB_10ciclos	0.1049	0.1400	0.3288	0.4387
	30dB_1ciclo	0.1557	0.2252	0.4877	0.7057
	30dB_4ciclos	0.1665	0.1579	0.5217	0.4947
	40dB_10ciclos	0.1089	0.1176	0.3414	0.3685
	40dB_1ciclo	0.1403	0.2013	0.4395	0.6309
	40dB_4ciclos	0.1123	0.1216	0.3518	0.3810
	50dB_10ciclos	0.0993	0.1223	0.3112	0.3833
	50dB_1ciclo	0.1388	0.1992	0.4348	0.6242
	50dB_4ciclos	0.1264	0.1215	0.3960	0.3806
	60dB_10ciclos	0.0783	0.0668	0.2453	0.2092
	60dB_1ciclo	0.1364	0.1732	0.4275	0.5427
	60dB_4ciclos	0.1259	0.1101	0.3687	0.3449

Fonte: Do autor (2017).

As Tabelas 20 e 21 mostram o desempenho e a medida de erro dos classificadores considerando os nove distúrbios propostos nesta dissertação. Portanto são dez classes

envolvidas no processo de classificação. Nota-se que, apesar da quantidade de classes a serem identificadas, os modelos FBeM e eTS tiveram desempenho bastante satisfatório (BEHERA; NAYAK, 2012; FERREIRA et al., 2014), comprovando, desta forma, a eficiência dos sistemas de extração de atributos discutidos no Capítulo 4 desta dissertação.

O modelo FBeM obteve o melhor resultado (desempenho e medida de erro) de classificação (60dB e dez ciclos) e com tempo computacional requerido inferior ao eTS. O modelo FBeM apresentou desempenho acima dos 90%, para relação sinal-ruído de 40dB e 50 dB e quatro e dez ciclos de análise da senoide, evidenciando que, se o sinal a ser analisado, tiver uma queda na relação sinal-ruído para 40dB, o FBeM é capaz de classificar os nove distúrbios de maneira satisfatória.

### 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. O nome deriva do fato de que ela torna mais fácil ver se o sistema está confundindo as classes. 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  $C_j$ .

$$M(C_i, C_j) = \sum_{\{x,y\} \in N: y=C_i} \|h(x) = C_j\| \quad (38)$$

O número de acertos, para cada classe, localiza-se 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. 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 (TAN et al., 2006).

A matriz de confusão é utilizada, para avaliar o modelo FBeM (por este ter obtido o melhor desempenho de detecção/classificação) quanto ao erro (confusão), na classificação entre as diversas classes e verificar possibilidades que otimizem sua saída. As classes são distribuídas da seguinte forma:

- a) Classe 1: distúrbio *spike*.
- b) Classe 2: distúrbio *notching*.
- c) Classe 3: distúrbio inter-harmônico.
- d) Classe 4: distúrbio transitório oscilatório.
- e) Classe 5: distúrbio interrupção curta.
- f) Classe 6: distúrbio elevação de tensão (*swell*).
- g) Classe 7: distúrbio sub-harmônico.
- h) Classe 8: distúrbio harmônico.
- i) Classe 9: distúrbio afundamento de tensão (*sag*).
- j) Classe 10: sinal sem distúrbio.

A Figura 17 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 Figura 17 como cada amostra foi classificada (acertos e erros). Os acertos estão na diagonal principal da matriz em cor verde. Os erros estão identificados pela cor vermelha. As classes 1, 5 e 10 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 10 (sinal sem distúrbio), pois significa que o modelo é capaz de identificar quando o sinal não tem distúrbio de QEE.

A classe com o pior desempenho foi a afundamento de tensão com 19,1% de erro de classificação e 383 amostras classificadas erradas. Destas, 132 foram classificadas como sinal sem distúrbio e 251 classificadas com interrupção curta. Isto ocorre porque, se o afundamento for de muita intensidade e com alguns ciclos de duração, o distúrbio se confunde com uma interrupção curta; se o afundamento for de baixa intensidade e um ciclo de duração, o distúrbio se confunde com um sinal sem distúrbio. Há uma confusão entre o distúrbio inter-harmônico com os distúrbios sub-harmônico e *swell*, sendo a porcentagem maior com o sub-harmônico.

Figura 17 - Matriz de confusão do modelo FBeM para 60dB e 10 ciclos.

**Matriz de Confusão**

<b>Saída Estimada</b>	1	1999 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.0%	0 0.0%	0 0.0%	99.8% 0.2%
	2	0 0.0%	1992 10.0%	0 0.0%	41 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.0% 2.0%
	3	0 0.0%	0 0.0%	1930 9.7%	0 0.0%	0 0.0%	1 0.0%	14 0.1%	14 0.1%	0 0.0%	0 0.0%	98.5% 1.5%
	4	0 0.0%	8 0.0%	0 0.0%	1958 9.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.6% 0.4%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1999 10.0%	1 0.0%	0 0.0%	0 0.0%	251 1.3%	1 0.0%	88.8% 11.2%
	6	0 0.0%	0 0.0%	14 0.1%	0 0.0%	0 0.0%	1902 9.5%	105 0.5%	0 0.0%	0 0.0%	0 0.0%	94.1% 5.9%
	7	0 0.0%	0 0.0%	47 0.2%	0 0.0%	0 0.0%	60 0.3%	1881 9.4%	0 0.0%	0 0.0%	0 0.0%	94.6% 5.4%
	8	0 0.0%	0 0.0%	5 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	1981 9.9%	0 0.0%	0 0.0%	99.7% 0.3%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1617 8.1%	0 0.0%	100% 0.0%
	10	1 0.0%	0 0.0%	4 0.0%	1 0.0%	0 0.0%	36 0.2%	0 0.0%	1 0.0%	132 0.7%	1999 10.0%	92.0% 8.0%
		100.0% 0.0%	99.6% 0.4%	96.5% 3.5%	97.9% 2.1%	100.0% 0.0%	95.1% 4.9%	94.0% 5.9%	99.1% 0.9%	80.8% 19.1%	100.0% 0.0%	96.3% 3.7%
		1	2	3	4	5	6	7	8	9	10	
		<b>Saída Desejada</b>										

Fonte: Do autor (2017).

Observa-se, também, que distúrbio sub-harmônico se confunde mais com o distúrbio *swell* do que com o distúrbio inter-harmônico. A ocorrência deste fato se deve porque o sub-harmônico provoca distorções na forma de onda, aumentando a amplitude do sinal em certos ciclos da senoide, provocando a confusão com o distúrbio *swell*. Outra análise importante é que das amostras com distúrbio 566 amostras foram classificadas erradas como sendo outros distúrbios e 175 amostras foram classificadas erradas como sendo sinal sem distúrbio. É melhor, desta forma, pois uma análise posterior do especialista pode identificar o distúrbio correto.

A Figura 18 apresenta a matriz de confusão para a relação sinal-ruído de 50dB e 10 ciclos de análise da senoide do modelo FBeM. Nota-se que o padrão de confusão foi o mesmo, para a relação sinal-ruído de 60dB, porém com menor desempenho.

Figura 18 - Matriz de confusão do modelo FBeM para 50dB e 10 ciclos.

**Matriz de Confusão**

<b>Saída Estimada</b>	1	1994 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	50 0.3%	0 0.0%	0 0.0%	97.6% 2.4%
	2	0 0.0%	1985 9.9%	0 0.0%	17 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
	3	0 0.0%	0 0.0%	1551 7.8%	0 0.0%	0 0.0%	10 0.1%	82 0.4%	225 1.1%	0 0.0%	0 0.0%	83.0% 17.0%
	4	0 0.0%	15 0.1%	0 0.0%	1982 9.9%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1999 10.0%	0 0.0%	0 0.0%	0 0.0%	316 1.6%	0 0.0%	86.3% 13.7%
	6	0 0.0%	0 0.0%	13 0.1%	0 0.0%	0 0.0%	1823 9.1%	187 0.9%	1 0.0%	0 0.0%	1 0.0%	90.0% 10.0%
	7	0 0.0%	0 0.0%	332 1.7%	0 0.0%	0 0.0%	148 0.7%	1728 8.6%	0 0.0%	0 0.0%	0 0.0%	78.3% 21.7%
	8	6 0.0%	0 0.0%	93 0.5%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	1707 8.5%	0 0.0%	0 0.0%	94.4% 5.6%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1451 7.3%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	11 0.1%	1 0.0%	1 0.0%	18 0.1%	1 0.0%	17 0.1%	233 1.2%	1999 10.0%	87.6% 12.4%
		99.7% 0.3%	99.3% 0.7%	77.5% 22.5%	99.1% 0.9%	100.0% 0.0%	91.1% 8.9%	86.4% 13.6%	85.4% 14.6%	72.5% 27.4%	100.0% 0.0%	91.1% 8.9%
		1	2	3	4	5	6	7	8	9	10	
		<b>Saída Desejada</b>										

Fonte: Do autor (2017).

#### 5.4 Análise de Curvas ROC

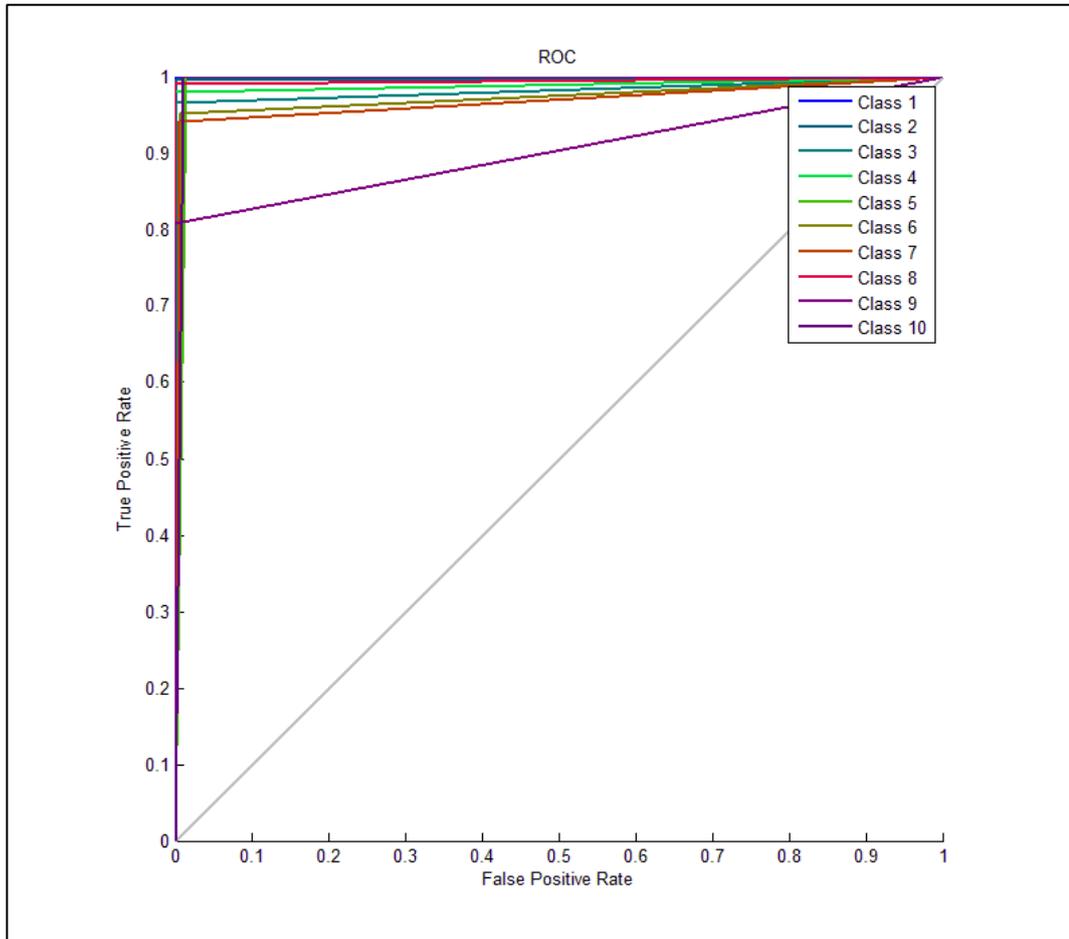
Análise ROC (*Receiver Operating Characteristic*) é um método gráfico para avaliação, organização e seleção de sistemas de diagnóstico e/ou predição. Gráficos ROC foram originalmente utilizados em detecção de sinais, para se avaliar a qualidade de transmissão de um sinal em um canal com ruído (EGAN, 1975). Conforme Prati et al. (2008), a análise ROC foi introduzida, recentemente, em aprendizagem de máquina e mineração de dados como uma ferramenta eficiente para a avaliação de modelos de classificação.

Ela é, particularmente útil, em sistemas nos quais existe uma grande desproporção entre as classes ou, quando se deve levar em consideração diferentes custos/benefícios, para os diferentes erros/acertos de classificação. Análise ROC, também, tem sido utilizada para a construção e refinamento de modelos (BRADLEY, 1997; FLACH; WU, 2005; SPACKMAN, 1989).

Assim como na matriz de confusão, a curva ROC é utilizada somente no modelo FBeM, a fim de se analisar graficamente o desempenho de classificação de cada classe de

distúrbio de QEE. Quanto maior o valor dos positivos verdadeiros e menor o valor dos falsos positivos melhor é o desempenho de classificação. A Figura 19 apresenta a análise da curva ROC para a relação sinal-ruído de 60dB e 10 ciclos de análise da senoide do modelo FBeM.

Figura 19 - Curva ROC do modelo FBeM para 60dB e 10 ciclos.

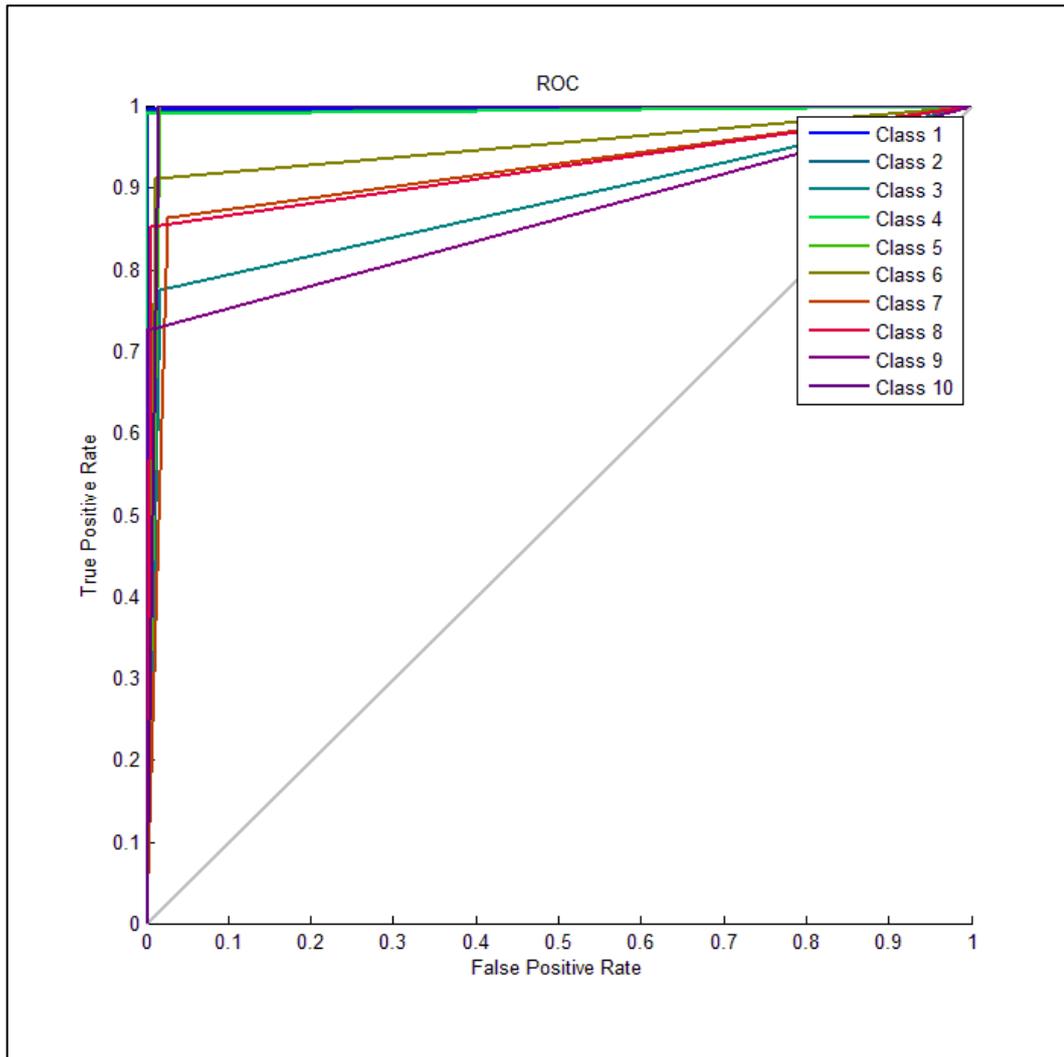


Fonte: Do autor (2017).

Percebe-se pela Figura 19 que a classe 9 (afundamento de tensão) foi a com menor valor de verdadeiros positivos, evidenciando a conformidade com a matriz de confusão, na qual este distúrbio apresentou a maior erro de classificação.

A Figura 20 apresenta a análise da curva ROC para a relação sinal-ruído de 50dB e 10 ciclos de análise da senoide considerando o modelo FBeM.

Figura 20 - Curva ROC do modelo FBeM para 50dB e 10 ciclos.



Fonte: Do autor (2017).

Nota-se uma grande diferença com relação à análise feita com SNR de 60dB, pois há outras classes (classes 3, 6, 7 e 8) com valores menores de verdadeiros positivos, mostrando, assim, como a matriz de confusão, que a diminuição do valor da relação sinal-ruído, considerando vários distúrbios, afeta o desempenho do classificador.

## 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. Neste contexto, este trabalho propôs duas abordagens *fuzzy* evolutivos para a detecção e classificação de distúrbios de QEE. O primeiro é o modelo Takagi-Sugeno evolutivo (eTS, *evolving Takagi-Sugeno*) que propõe a atualização do sistema de forma recursiva. Baseado em regras do tipo Takagi-Sugeno (TS), sistema *fuzzy* no qual os antecedentes das regras são termos linguísticos e os consequentes são funções das variáveis antecedentes. O modelo eTS determina os antecedentes das regras por um processo de agrupamento não supervisionado e os consequentes por alguma variação de algoritmo de Quadrados Mínimos Recursivo. O segundo é a modelagem evolutiva, baseada em conjuntos *fuzzy* (FBeM, *Fuzzy set Based evolving Modeling*), que emprega grânulos de informação tipo *fuzzy*, para construir mapas granulares que, de maneira geral associam dados granulares de entrada a dados granulares de saída. 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 sistemas *fuzzy* linguísticos são mais interpretáveis. Por meio da sua combinação, FBeM aproveita as vantagens de ambos os sistemas simultaneamente.

Os modelos foram avaliados, utilizando dados gerados de forma artificial no Matlab, seguindo padrões do IEEE. O desempenho dos modelos quanto à classificação de distúrbios de QEE foi aferido por uma acurácia e tempo computacional requerido; e medidas de erro RMSE (*Root Mean Squared Error*) e NDEI (*Non Dimensional Error Index*) foram utilizadas para avaliar a precisão dos modelos. O desempenho de classificação foi promissor, para ambos os modelos, mesmo considerando baixos níveis de relação sinal-ruído, poucos ciclos de análise da senoide e várias classes de distúrbios consideradas ao mesmo tempo. FBeM se mostrou superior ao eTS em todos os índices mencionados anteriormente.

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, a fim de se caracterizar melhor os distúrbios que tiveram resultados menos satisfatórios na detecção e classificação; empregar outros modelos evolutivos (redes neurais artificiais, regras *fuzzy* e redes *neuro-fuzzy*), para comparar com os resultados obtidos

nesta dissertação; desenvolvimento de modelos para detecção e classificação de inter-harmônicos em frequências superiores às propostas neste trabalho; abordar metodologias de seleção incremental de variáveis de entrada para tornar todo o sistema evolutivo; abordar múltiplos distúrbios simultaneamente.

## REFERÊNCIAS

ABRAHAM, A.; GROSAN, C. Engineering evolutionary intelligent systems: methodologies, architectures and reviews. In: ABRAHAM, A.; GROSAN, C.; PEDRYCZ, W. (Ed.). **Engineering evolutionary intelligent systems, studies in computational**. Germany: Springer Verlag, 2008. p. 1-22.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. **PRODIST**: procedimentos de distribuição de energia elétrica no sistema elétrico nacional: relatório São Paulo: ANEEL, 2012. 90 p.

AGUIRRE, L. A. **Introdução à identificação de sistemas**: técnicas lineares e não lineares aplicadas a sistemas reais. 3. ed. rev. e ampl. Belo Horizonte: Editora da UFMG, 2007. 730 p.

ANGELOV, P. et al. Architectures for evolving fuzzy rule-based classifiers. In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS, 2007, Montreal. **Proceedings...** Montreal: IEEE, 2007. p. 2050-2055.

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

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.; FILEV, D.; KASABOV, N. Evolving fuzzy systems – preface to the special section. **IEEE Transactions on Fuzzy Systems**, New York, v. 6, n. 6, p. 1390-1392, 2008.

\_\_\_\_\_. **Evolving intelligent systems**: methodology and applications. New York: John Willey & Sons, 2010. 442 p.

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

ANGELOV, P.; XIAOWEI, Z. Evolving fuzzy systems from data streams in real-time. In: INTERNATIONAL SYMPOSIUM ON EVOLVING FUZZY SYSTEMS, Lake District, 2006. **Proceedings...** Lake District: [s.n.], 2006. p. 29-35.

ANGELOV, P.; ZHOU, X. Evolving fuzzy-rule-based classifiers from data streams. **IEEE Transactions on Fuzzy Systems**, UK, v. 6, n. 6, p. 1462-1475, Dec. 2008.

BARBI, I. **Eletrônica de potência**. Florianópolis: Editora do Autor, 2006. 328 p.

BARGIELA, A.; PEDRYCZ, W. **Granular computing**: an introduction. Boston: Kluwer Academic Publishers, 2003. 452 p.

BEHERA, L. K.; NAYAK, M. Pattern recognition of power quality events using fuzzy neural network based rule generation. In: IEEE INTERNATIONAL CONFERENCE ON

- ADVANCES IN ENGINEERING, SCIENCE AND MANAGEMENT, 2012, Nagapattinam. **Proceedings...** Nagapattinam: IEEE, 2012.
- BOLLEN, M. H. J. et al. Bridging the gap between signal and power. **IEEE Signal Processing Magazine**, Göteborg, v. 23, n. 4, p. 12–31, July 2009.
- BOUCHACHIA, A. An evolving classification cascade with self-learning. **Evolving Systems**, New York, v. 1, n. 3, p. 143-160, Oct. 2010.
- BOUCHACHIA, A.; GABRYS, B.; SAHEL, Z. Overview of some incremental learning algorithms. In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 2007, London. **Proceedings...** London: [s.n.], 2007. p. 1-6.
- BRADLEY, A. P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. **Pattern Recognition**, Alberta, v. 30, n. 7, p. 1145–1159, 1997.
- DECKMANN, S. M.; POMILIO, J. A. **Avaliação da qualidade da energia elétrica**. 2010. Campinas: Universidade Estadual de Campinas, 2010. 10 p.
- DI SANTO, K. G. et al. A review on smart grids and experiences in Brazil. **Renewable and Sustainable Energy Reviews**, London, v. 52, p. 1072-1082, Dec. 2015.
- DINIZ, P. S. R.; SILVA, E. A. B.; LIMA NETTO, S. L. **Processamento digital de sinais: projeto e análise de sistemas**. Porto Alegre: Bookman, 2004. 590 p.
- DUGAN, R. C. et al. **Electrical power systems quality**. 2. ed. New York: McGraw-Hill, 2003. 521 p.
- EGAN, J. P. **Signal detection theory and ROC analysis**. New York: Academic Press, 1975. 277 p.
- EL-HAWARY, M. E. The smart grid: state-of-the-art and future trends. **Electric Power Systems Research**, UK, v. 42, n. 3/4, p. 42-239, Feb. 2014.
- 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.
- FERREIRA, D. D. et al. A direct approach for disturbance detection based on principal curves. In: INTERNATIONAL CONFERENCE ON, 16., 2014, Bucharest. **Proceedings...** Bucharest: IEEE, 2014. p. 747-751.
- FERREIRA, D. D.; SEIXAS, J. M.; CERQUEIRA, A. S. A method based on independent component analysis for single and multiple power quality disturbance classification. **Electric Power Systems Research**, UK, v. 119, p. 425-431, Feb. 2015.
- FLACH, P.; WU, S. Repairing concavities in ROC curves. In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 9., 2005, Edinburgh. **Proceedings...** Edinburgh: [s.n.], 2005. p. 702–707.

GABRYS, B.; PETRAKIEVA, L. Combining labelled and unlabelled data in the design of pattern classification systems. **International Journal of Approximate Reasoning**, Oxford, v. 35, n. 3, p. 251-273, Mar. 2004.

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, 2011. Chap. 2, p. 17-31.

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

GU, I. Y. H. et al. A statistical-based sequential method for fast online detection of fault-induced voltage dips. **IEEE Transactions on Power Delivery**, Amsterdam, v. 19, n. 2, p. 497-504, Mar. 2004.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 898 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.

INÁCIO, M. **Diagnóstico de falhas baseado em sistema inteligente evolutivo**. 2014. 132 p. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2014.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC. **Power quality measurement methods: relatório técnico**. New York: IEC, 2003. 130 p.

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

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

KASABOV, N.; SONG, Q. DENFIS: dynamic evolving neural-fuzzy inference system and its application for time-series prediction. **IEEE Transactions on Fuzzy Systems**, New York, v. 10, n. 2, p. 144-154, Abr. 2002.

LAZZARETTI, A. E.; FERREIRA, V. H.; VIEIRA NETO, H. New trends in power quality event analysis: novelty detection and unsupervised classification. **Journal of Control, Automation and Electrical Systems**, Amsterdam, v. 27, n. 6, p. 718-727, 2016.

LEITE, D. et al. Fuzzy granular evolving modeling for time series prediction. In: IEEE INTERNATIONAL CONFERENCE ON, 2011, New York. **Proceedings...** New York: IEEE, 2011b. p. 2794-2801.

\_\_\_\_\_. Modelagem evolutiva granular fuzzy. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 10., 2011, São João Del Rey. **Anais...** São João Del Rey: [s.n.], 2011a. p. 81-86.

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

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.], 2009b. p. 1736-1743.

\_\_\_\_\_. Evolving granular neural network for semi-supervised data stream classification. In: WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE - INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2010a, Barcelona. **Proceedings...** Barcelona: [s.n.], 2010a. p. 1877-1884.

\_\_\_\_\_. Evolving granular neural network for fuzzy time series forecasting. In: WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE – IEEE JOINT CONFERENCE ON NEURAL NETWORKS, 2012b, New York. **Proceedings...** New York, 2012b. p. 1-8.

\_\_\_\_\_. Granular approach for evolving system modeling. In: HULLERMEIER, E.; KRUSE, R.; HOFFMANN, F. (Ed.). **Lecture notes in artificial intelligence**: volume 6178. Berlin: Springer-Verlag Berlin Heidelberg, 2010b. p. 340-349.

\_\_\_\_\_. Interval approach for evolving granular system modeling. In: MOUCHAWEH, M. S.; LUGHOFER, E. (Ed.). **Learning in non-stationary environments**: methods and applications. New York: Springer New York, 2012a. p. 271-301.

\_\_\_\_\_. Sistemas conexionistas evolutivos. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 9., 2009, Brasília. **Anais...** Brasília: SBAI, 2009a. p. 1-6.

LEMONS, 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.

LJUNG, L. **System identification**: theory for the user. Englewood Cliffs: Prentice-Hall, 1999. 519 p.

LOPES, H. S.; TAKAHASHI, R. H. C. **Computação evolucionária em problemas de engenharia**. Curitiba: Omnipax, 2011. 385 p.

LUGHOFER, E. **Evolving fuzzy systems**: methodologies, advanced concepts and applications. Heidelberg: Springer-Verlag, 2011a. 460 p.

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

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.

MAMEDE FILHO, J. **Instalações elétricas industriais**. Rio de Janeiro. Editora LTC, 2002. 914 p.

MARQUES, J. **Reconhecimento de padrões métodos estatísticos e neuronais**. Portugal: IST Press, 1999. 284 p.

MASCARENHAS, N. A. Breve introdução ao reconhecimento estatístico de padrões. In: REUNIÃO ANUAL DA SOCIEDADE BRASILEIRA PARA O PROGRESSO DA CIÊNCIA, 39., 1987, Brasília. **Anais...** Brasília: SBPC, 1987.

MCGRANAGHAN, M.; ROETTGER, B. Economic evaluation of power quality. **IEEE Spectrum**, New York, v. 22, n. 2, p. 8-12, Feb. 2002.

MICHALEWICZ, Z.; FOGEL, D. B. **How to solve it: modern heuristics**. New York: Springer-Verlag, 2000. 554 p.

NGUYEN, N. N.; QUEK, C. Stock price prediction using Generic Self-Evolving Takagi-Sugeno-Kang (GSETSK) fuzzy neural network. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2010, Barcelona. **Proceedings...** Barcelona: IEEE, 2010. p. 1-8.

OLIVEIRA, J. C. **Qualidade da energia elétrica: definição e análise dos itens de qualidade**. Uberlândia: Universidade Federal de Uberlândia, 2000. 90 p.

ON POWER QUALITY, I. S. C. C. **IEEE recommended practice for monitoring electric power quality: relatório técnico**. New York: IEEE, 1995. 81 p.

POWER QUALITY IN EUROPEAN ELECTRICITY SUPPLY NETWORKS. **Union of the electricity industry**. Brussels: Eurelectric, 2004. 12 p.

PRADO, A. J.; ELFES, A. **Um projeto em reconhecimento de padrões de forma**. 1975. 125 p. Monografia (Graduação em Engenharia Eletrônica) - Instituto Tecnológico de Aeronáutica, São José dos Campos, 1975.

PRATI, R. C. et al. Curvas ROC para avaliação de classificadores. **Revista IEEE América Latina**, New York, v. 6, n. 2, p. 215-222, June 2008.

RIBEIRO, P. F. et al. **Power systems signal processing for smart grids**. Chichester: John Wiley & Sons, 2013. 448 p.

SCHALKOFF, R. J. **Pattern recognition: statistical, structural and neural approaches**. Chichester: John Wiley & Sons, 1992. 384 p.

SILVA, A. M. et al. **Evolving neural fuzzy network with adaptive feature selection**. In: INTERNATIONAL CONFERENCE ON, 11., 2012, Boca Raton. **Proceedings...** Boca Raton: IEEE, 2012. p. 440-445.

SOUZA, L. et al. Thermal modeling of power transformers using evolving fuzzy systems. **Engineering Applications of Artificial Intelligence**, Oxford, v. 25, n. 5, p. 980-988, Aug. 2012.

SPACKMAN, K. A. Signal detection theory: valuable tools for evaluating inductive learning. In: WORKSHOP ON MACHINE LEARNING, 6., 1989, Ithaca. **Proceedings...** Ithaca: Morgan Kaufmann, 1989. p. 160-163.

STEINER, M. T. A. **Uma metodologia para o reconhecimento de padrões multivariados com resposta dicotômica**. 1995. 158 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Santa Catarina, Florianópolis, 1995.

STIEGLER, S. M. A modest proposal: a new standard for the normal. **The American Statistician**, Washington, v. 36, n. 2, p. 137-138, Mar. 1982.

TAKAGI, T; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v. 15, n. 1, p. 116–132, Jan./Feb. 1985.

TAN, P.-N. et al. **Introduction to data mining**. Noida: Pearson Education India, 2006. 165 p.

TANSCHKEIT, R. **Sistemas fuzzy**. Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2004. 35 p.

TESTA, A.; LANGELLA, R. **Power system subharmonics**. San Francisco: IEEE Transaction on Power Delivery, 2005.

THE INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS - IEEE. **IEEE guide for the design and application of power electronics in electrical power systems on ships**. New York: IEEE, 2008. 72 p.

\_\_\_\_\_. **IEEE recommended practice for monitoring electric power quality**. New York: IEEE, 2009. 91 p.

THEODORIDIS, S.; KOUTOUMBAS, K. **Pattern recognition**. San Diego: Academic Press, 1999. 689 p.

TODESCO, J. L. **Reconhecimento de padrões usando rede neuronal artificial com uma função de base radial: uma aplicação na classificação de cromossomos humanos**. 1995. 154 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Santa Catarina, Florianópolis, 1995.

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.

TOU, J. T.; GONZALEZ, R. C. **Pattern recognition principles**. Massachusetts: Addison-Wesley Publishing Company, 1981. 399 p.

YAGER, R. R. Measures of specificity over continuous spaces under similarity relations. **Fuzzy Sets and Systems**, New Rochelle, v. 159, n. 17, p. 2193-2210, Sept. 2008.

YAGER, R. R.; FILEV, D. P. **Essentials of fuzzy modeling and control**. New York: Wiley Interscience, 1994b. 388 p.

\_\_\_\_\_. Approximate clustering via the mountain method. **IEEE Transactions on Systems, Man and Cybernetics**, Amsterdam, v. 24, n. 8, p. 1279, Aug. 1994a.

YOUNG, P. **Recursive estimation and time-series analysis: an introduction**. Inc., New York: Springer-Verlag New York, 1984. 500 p.

ZADEH, L. A. Fuzzy sets. **Fuzzy Sets, Information and Control**, Berkeley, v. 8, n. 3, p. 338–353, June 1965.