



THAIS MARTINS MENDES

**MONITORAMENTO MULTIDIMENSIONAL DA QUALIDADE
DE ENERGIA ELÉTRICA BASEADO NO CONCEITO DE
DETECÇÃO DE NOVIDADE**

LAVRAS – MG

2017

THAIS MARTINS MENDES

**MONITORAMENTO MULTIDIMENSIONAL DA QUALIDADE DE ENERGIA
ELÉTRICA BASEADO NO CONCEITO DE DETECÇÃO DE NOVIDADE**

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

Prof. DSc. Danton Diego Ferreira
Orientador

LAVRAS – MG

2017

**Ficha catalográfica elaborada pela Coordenadoria de Processos Técnicos
da Biblioteca Universitária da UFLA**

Mendes, Thais Martins

Monitoramento multidimensional da qualidade de energia elétrica baseado no conceito de detecção de novidade / Thais Martins Mendes. – Lavras : UFLA, 2017.

67 p. : il.

Dissertação(mestrado)–Universidade Federal de Lavras, 2017.

Orientador: Prof. DSc. Danton Diego Ferreira.

Bibliografia.

1.Qualidade de energia elétrica. 2.Detecção de distúrbios.
3.Classificação de distúrbios. I. Ferreira, Danton Diego.
II.Título.

THAIS MARTINS MENDES

**MONITORAMENTO MULTIDIMENSIONAL DA QUALIDADE DE ENERGIA
ELÉTRICA BASEADO NO CONCEITO DE DETECÇÃO DE NOVIDADE
MULTIDIMENSIONAL MONITORING OF POWER QUALITY BASED ON
NOVELTY DETECTION CONCEPT**

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

APROVADA em 17 de Fevereiro de 2017.

Prof. DSc. Danton Diego Ferreira	UFLA
Prof. DSc. Carlos Augusto Duque	UFJF
Prof. DSc. Bruno Henrique Groenner Barbosa	UFLA
Prof. DSc. Daniel Furtado Leite	UFLA

Prof. DSc. Danton Diego Ferreira
Orientador

**LAVRAS – MG
2017**

AGRADECIMENTOS

Agradeço à Deus por me dar forças e sabedoria.

Ao meu orientador Dr. Danton Diego Ferreira pela excelência na orientação, bem como pelos ensinamentos repassados, os quais foram essenciais tanto para a realização deste trabalho, como para minha formação profissional. Agradeço também pela amizade, pelo tempo e paciência dedicados a mim em todos os momentos.

À toda minha família, meus pais, em especial à minha mãe, fonte inesgotável de amor.

Ao Rafael, pelo amor, carinho e atenção.

Aos professores Dr. Carlos Augusto Duque, Dr. Bruno Henrique Groenner Barbosa e Dr. Daniel Furtado Leite, pelos conhecimentos repassados e por se disporem a participar como membro na banca examinadora.

Ao colega Eduardo que forneceu boas contribuições para o desenvolvimento do trabalho.

Ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação (UFLA) e professores do Departamento de Engenharia (UFLA) pela oportunidade concedida e atenção a mim dedicadas.

RESUMO

Qualidade de Energia Elétrica (QEE) tem emergido como um importante campo de pesquisa. Este fato é justificado pelo uso crescente de conversores de alta potência e o aumento de cargas não lineares com potência elevada que causam alterações não desejadas nos sinais elétricos. Tais alterações são denominadas distúrbios elétricos. Este trabalho propõe uma abordagem multidimensional para detecção e classificação de distúrbios de QEE. A inovação deste trabalho trata-se do desenvolvimento de métodos que aplicam o conceito de detecção de novidade ainda não propostos na literatura. Um método simples de detecção de distúrbios é proposto, onde um índice geral de QEE é fornecido. Esta abordagem tem a vantagem de utilizar apenas o cálculo de uma distância entre dois pontos em um espaço multidimensional para obter o resultado da detecção do distúrbio e fornecer um índice geral de QEE. Como resultados foram obtidos desempenhos superiores a 90% para dados simulados e eficiência de 100% para testes executados com dados reais e para o sistema de aquisição em tempo real. Foi proposta uma abordagem inovadora referente ao uso do classificador não supervisionado Máquina de Vetor de Suporte (SVM) para construir um envelope multidimensional que circunda as amostras de cada classe de distúrbios, fazendo a detecção e classificação das mesmas através do conceito de detecção de novidade. Um eficiência global de 100% foi alcançada pelo sistema de detecção e o desempenho alcançado pelo sistema de classificação situou-se acima de 99%. Uma das principais vantagens dos métodos aqui propostos é a facilidade de inclusão de uma nova classe de distúrbios.

Palavras-chave: Qualidade de energia elétrica. Detecção de novidade. Detecção de distúrbios. Classificação de distúrbios. Distúrbios elétricos.

ABSTRACT

Power Quality (PQ) has emerged as an important research field. This fact is explained by increasing use of high power converters and the increase of nonlinear loads with high power that cause unwanted changes in the electrical signals. These changes are called electrical disturbances. This work proposes a multidimensional approach for detecting and classifying PQ disturbances. The innovation of this work is the development of methods that apply the concept of novelty detection to PQ not yet proposed in the literature. A simple method for disturbance detection is proposed, where a general index of PQ is provided. This approach has the advantage of using the calculation of only a distance between two points in a feature space to obtain the result of the disturbance detection and to provide a general PQ index. As results we obtained performances greater than 90% for simulated data and of 100% for real data considering a the real time acquisition system. An innovative approach was proposed regarding the use of unsupervised classifier Support Vector Machine (SVM) to construct a multidimensional envelope to cover samples of each disturbances class, and to detect and classify them through the novelty detection concept. An accuracy of 100% was achieved by the detection system and the efficiency achieved by the classification system was above 99%. A the main advantage of the proposed method concerns is its ability to include new disturbance classes without the need of redesigning the classifier from scratch.

Keywords: Power quality. Novelty detection. Disturbance detection. Disturbance classification. Electric disturbances.

LISTA DE FIGURAS

Figura 1.1 – Número de artigos publicados por ano na área de Qualidade de Energia.	14
Figura 2.1 – Exemplos de transitórios impulsivos (positivo e negativo).	18
Figura 2.2 – Exemplos de transitórios oscilatórios na forma de onda da tensão.	19
Figura 2.3 – Exemplos de variações de tensão: (a) Afundamento de tensão; (b) Elevação de tensão e; (c) Interrupção.	20
Figura 2.4 – Exemplos de deformações de tensão: (a) Harmônicos e (b) Notches.	21
Figura 3.1 – Representação das amostras da classe de sinais nominais em 3D.	26
Figura 3.2 – Limiares em torno da circunferência que modela um sinal nominal.	26
Figura 3.3 – Valores de média \pm desvio padrão do quadrado da distância euclidiana dos eventos nominais até a origem, ponto multidimensional c , em função da SNR.	27
Figura 3.4 – Sistema de Aquisição: 1- Placa NI cDAQ-9178 2- CompactRIO (modelo 9076), 3- Fonte de Energia.	28
Figura 3.5 – Fluxograma do algoritmo de aquisição	30
Figura 3.6 – SubVI <i>Select</i> que realiza a execução do método proposto.	31
Figura 3.7 – Ilustração da aplicação do método proposto na Abordagem B.	31
Figura 3.8 – SubVI de seleção dos limiares.	32
Figura 3.9 – Esquema geral do método de detecção proposto baseado em AG e SVM.	34
Figura 3.10 – Abordagem proposta para seleção genética de parâmetros.	37
Figura 3.11 – Hiperplano SVM ótimo de separação de duas classes.	38
Figura 3.12 – Modelo do detector proposto baseado em SVM <i>one class</i>	39
Figura 3.13 – Resultado da melhor combinação de parâmetros obtida pelo AG.	40
Figura 4.1 – Principais Técnicas de Classificação de distúrbios de QEE.	42
Figura 4.2 – Método de Classificação Proposto.	45
Figura 4.3 – Sistema de Classificação Especialista baseado em SVM.	46
Figura 4.4 – FDR para <i>sags</i>	47
Figura 4.5 – FDR para <i>swells</i>	47
Figura 4.6 – FDR para harmônicos.	48
Figura 4.7 – FDR para interharmônicos.	48
Figura 4.8 – FDR para transitórios impulsivos.	49
Figura 4.9 – FDR para transitórios oscilatórios.	49
Figura 4.10 – FDR para interrupção.	50

Figura 4.11 – FDR para <i>notches</i>	50
Figura 4.12 – FDR para sinais normais.	51

LISTA DE TABELAS

Tabela 2.1 – Características de alguns distúrbios de qualidade de energia.	17
Tabela 3.1 – Desempenho de Detecção de Distúrbios em % para Sinais Simulados. . . .	33
Tabela 3.2 – Desempenho de Detecção de Distúrbios em % para o Sistema de Detecção em Tempo Real proposto usando a abordagem B (dados de validação). . . .	34
Tabela 3.3 – Desempenho do detector para dados de validação em função dos parâmetros selecionados	40
Tabela 4.1 – Desempenho dos Sistemas de Classificação Especialista em %.	51

SUMÁRIO

1	Introdução	12
1.1	Motivação	13
1.2	Organização do Trabalho	14
2	Qualidade de Energia Elétrica	16
2.1	Distúrbios em QEE	16
2.1.1	Transitórios	17
2.1.1.1	Transitórios Impulsivos	18
2.1.1.2	Transitórios Oscilatórios	18
2.1.2	Variações de tensão de curta duração	19
2.1.3	Variações de tensão de longa duração	19
2.1.4	Deformação da forma de onda da tensão	20
2.1.5	Tipos de Desbalanceamentos	20
3	Deteção de Distúrbios de QEE	22
3.1	Deteção de Distúrbios	22
3.2	Estado da Arte de Técnicas de Deteção	23
3.3	Sistema de Deteção baseado na Distância Euclidiana	24
3.3.1	Base de Dados	28
3.3.2	Sistema de Deteção de Distúrbios em Tempo Real	28
3.3.3	Resultados e Discussões	32
3.3.3.1	Resultados para Sinais Simulados	32
3.3.3.2	Resultados para Sinais Reais	33
3.3.3.3	Resultados do Sistema de Aquisição	33
3.4	Sistema Deteção baseado em Algoritmos Genéticos e Máquina de Vetor de Suporte	34
3.4.1	Dados de Entrada	34
3.4.2	Extração de Parâmetros	35
3.4.3	Seleção dos Parâmetros	36
3.4.4	Algoritmo de Deteção via SVM	38
3.4.5	Resultados e Discussões	39
4	Classificação de Distúrbios de QEE	41
4.1	Classificação de Distúrbios	41

4.2	Estado da Arte de Técnicas de Classificação	42
4.3	Sistema de Classificação Especialista baseado em Máquina de Vetor de Suporte	44
4.3.1	Resultados e Discussões	46
5	Conclusões e Perspectivas	52
5.1	Sistemas de Detecção de Distúrbios	52
5.1.1	Sistema de Detecção baseado na Distância Euclidiana	52
5.1.2	Sistema de Detecção baseado em Algoritmos Genéticos e Máquina de Vetor de Suporte	53
5.1.3	Sistema de Classificação Especialista baseado em Máquina de Vetor de Suporte	53
5.2	Perspectivas	54
	REFERÊNCIAS	55
	Apêndice A – SVM <i>one class</i>	60
	Apêndice B – Algoritmos Genéticos	63
	Apêndice C – Discriminante Linear de Fisher	65
	Apêndice D – Lista de Publicações	67

LISTA DE ABREVIATURAS

AG	Algoritmos Genéticos
DMA	<i>Direct Memory Access</i>
DN	Detecção de Novidade
DSP	<i>Digital Signal Processor</i>
DWT	Transformada Wavelet Discreta
EDCM	<i>Enhanced Data Compression Method</i>
EOS	Estatística de Ordem Superior
FDR	Discriminante linear de Fisher
FFT	<i>Fast Fourier Transform</i>
FIFO	<i>First In, First Out</i>
FIR	<i>Finite Impulse Response</i>
FPGA	<i>Field-programmable Gate Array</i>
IA	Inteligência Artificial
MMF	Morfologia Matemática
MPNN	<i>Modular Probabilistic Neural Network</i>
NI	National Instruments
PCI	<i>BUS Peripheral Component Interconnect Bus</i>
Pd	Probabilidade de Detecção
Pf	Probabilidade de Falso Alarme
PSO	<i>Particle Swarm Optimization</i>
QEE	Qualidade de Energia Elétrica
RBF	<i>Radial Basis Function</i>
RMS	<i>Root Mean Square</i>
RNA	Redes Neurais Artificiais
RT	<i>Real Time</i>

SAR	<i>Sucessive Aproximation Register</i>
SCE	Sistema de Classificação Especialista
SK	Kurtosis Espectral
SNR	<i>Signal-to-Noise Ratio</i>
SVM	Máquina de Vetor de Suporte
THD	<i>Total Harmonic Distortion</i>
TW	<i>Transformada Wavelet</i>
Vi	<i>Virtual Instrument</i>

1 INTRODUÇÃO

O estudo da Qualidade de Energia Elétrica (QEE) em todos os seus aspectos compreende um campo de grande interesse para a comunidade científica. O sistema de energia elétrica está constantemente sujeito a transformações. Mudanças na produção, no consumo ou na própria rede de distribuição de energia, comprovam tal afirmação (RÖNNBERG; BOLLEN, 2016). Este cenário de mudanças gera consequências ao desempenho dos equipamentos ligados à rede, e portanto, afetam a QEE. A finalidade do sistema de energia elétrica é fornecer alimentação para estes equipamentos, por conseguinte, essas consequências, imprevistas, exigem atenção.

O termo QEE é muito empregado nos dias atuais, embora não exista ainda um consenso quanto ao seu emprego, podendo ter significados diferentes dependendo do referencial. De forma geral, QEE compreende na qualidade das formas de onda da tensão e corrente elétricas em um sistema elétrico (BOLLEN et al., 2009). É importante considerar o contexto das *Smart Grids* (redes inteligentes), onde a QEE tem se tornado um aspecto importante e não deve ser negligenciada (RIBEIRO et al., 2013). Conforme Bollen et al. (2010), a QEE adequada garante a compatibilidade necessária entre todos os equipamentos conectados à rede. É, portanto, uma questão crucial para o funcionamento bem-sucedido e eficiente das *Smart Grids*.

As *Smart Grids* podem ser consideradas como um moderno sistema de alimentação capaz de melhorar a eficiência, confiabilidade e segurança da rede elétrica; reduzir picos de energia; oferecer benefícios ambientais; localizar e reparar falhas facilmente; acomodar recursos renováveis; entre outros (EL-HAWARY, 2014). Ela pode ser definida como um sistema de geração, transmissão e distribuição equipada com uma comunicação de duas vias controlada pelo operador da rede do sistema (SANTO et al., 2015). Uma das exigências dessa rede é a presença de uma fonte de alimentação de qualidade de acordo com as necessidades da rede, assim como a adequação da geração e armazenamento de energia.

Independente da causa das distorções presentes nos sinais elétricos, elas podem gerar perdas consideráveis aos consumidores de energia, uma vez que tais distúrbios podem causar o funcionamento incorreto ou até mesmo a queima dos equipamentos conectados à rede elétrica e, conseqüentemente, interromper um processo de produção (KANIRAJAN; KUMAR, 2015). Com isso, se desperta uma preocupação por parte das concessionárias de energia elétrica em garantir a qualidade do produto e, por outro lado, se desperta também o interesse dos usuários de energia em monitorar a qualidade da energia elétrica recebida.

Diante das inevitáveis mudanças que ocorrem no sistema elétrico, e considerando o surgimento desta nova configuração de rede, as *Smart Grids*, o aparecimento de novidades no sinal elétrico pode não ser necessariamente decorrente de perturbações típicas de QEE, mas qualquer novo desvio/variação no sinal. Neste caso, os detectores convencionais, focados em detectar apenas os distúrbios de QEE já bem conhecidos (variações de tensão, harmônicos, transientes) podem não funcionar muito bem. Desta forma, algoritmos de detecção que baseiam-se no conceito de detecção de novidade (DN) (SILVA et al., 2016; PIMENTEL et al., 2014), se encaixam muito bem neste novo panorama dos sistemas de energia elétrica, uma vez que buscam por "anormalidades" presentes no sinal.

Este trabalho propõe o monitoramento de QEE em um espaço multidimensional em que o conceito de detecção de novidade é inserido no contexto de QEE a fim de detectar e classificar os diferentes tipos de distúrbios elétricos. Neste sentido, o trabalho apresentará diferentes contribuições: i) Um método simples de detecção de distúrbios, inspirado no método de (FERREIRA et al., 2014) é proposto. Neste método um índice geral de QEE é fornecido. Esta abordagem tem a vantagem de utilizar o cálculo de apenas uma distância entre dois pontos para obter o resultado da detecção do distúrbio e fornecer um índice geral de QEE; ii) Uma abordagem inovadora referente ao uso de um classificador não supervisionado SVM (*Support Vector Machine* – Máquinas de Vetor de Suporte) para construir um envelope multidimensional que circunda as amostras de cada classe de distúrbios, fazendo a detecção e classificação das mesmas através do conceito de detecção de novidade. Ambas as abordagens i) e ii), se caracterizam por operar em um espaço multidimensional, onde características de relações mútuas entre variáveis são evidenciadas. Dessa forma, as abordagens consideradas neste trabalho apresentam certas vantagens em comparação com métodos convencionais.

1.1 Motivação

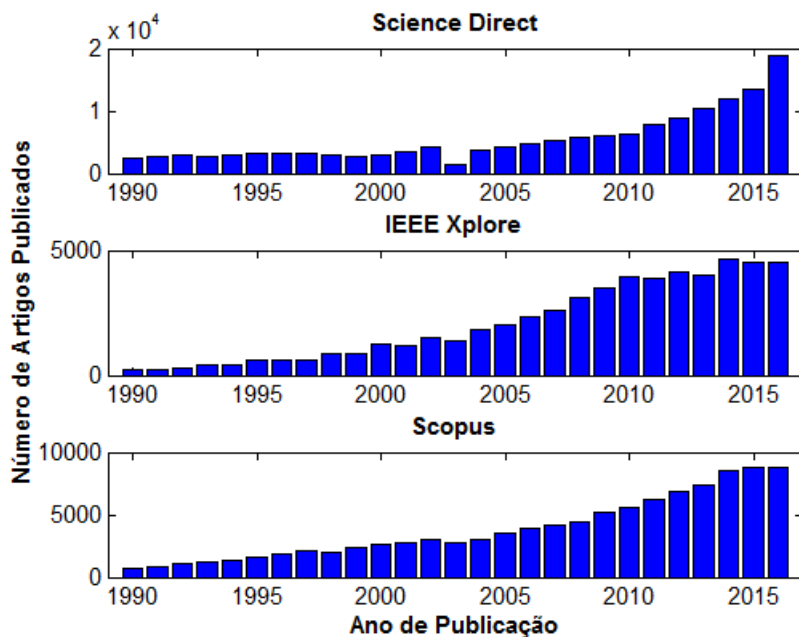
A detecção de novidade pode ser definida basicamente como uma tarefa de detecção em que os dados de teste diferem em algum aspecto dos dados apresentados durante o treinamento. A importância prática e natureza desafiadora dos conceitos que envolvem DN, levaram a sua aplicação em diversas áreas, tais como: problemas de diagnóstico médico (CLIFTON et al., 2011), detecção de falhas em sistemas industriais (TARASSENKO et al., 2009), redes de sensores (ZHANG; MERATNIA; HAVINGA, 2010), robótica móvel (NETO; NEHMZOW, 2007;

SOFMAN et al., 2011), sistemas de segurança eletrônica, como detecção de fraude de cartão ou telefone celular (PATCHA; PARK, 2007; JYOTHSNA; PRASAD; PRASAD, 2011).

Nos últimos anos, essas e outras aplicações nas mais diversas áreas têm motivado o desenvolvimento de uma série de algoritmos para DN. Neste contexto, o monitoramento da Qualidade de energia elétrica (QEE) constitui uma importante área de pesquisa na qual algoritmos de DN podem oferecer uma relevante contribuição.

A preocupação com a QEE se faz a cada dia mais presente no cotidiano de engenheiros, concessionárias, empresas e pesquisadores, por este motivo, o interesse em pesquisas na área QEE tem se mostrado crescente (KHOKHAR et al., 2015). Este fato pode ser observado imediatamente a partir da Figura 1.1, que mostra os resultados de uma pesquisa na base de dados do Science Direct, IEEE Xplore e Scopus, realizada no dia 9 de janeiro de 2017, em que o termo “Power Quality” foi utilizado para a busca no título dos artigos. Observe que o número de publicações na área apresentou aumento significativo com o passar dos anos.

Figura 1.1 – Número de artigos publicados por ano na área de Qualidade de Energia.



1.2 Organização do Trabalho

Este documento está organizado da seguinte maneira: o Capítulo 2 define o termo “Qualidade de Energia Elétrica”, os principais distúrbios de QEE, assim como suas características e os fatores desencadeadores de cada um deles.

O Capítulo 3 discute sobre a detecção de distúrbios que afetam a QEE. Inicialmente introduz um método simples de monitoramento de QEE, que opera em um espaço multidimensional, com dimensão igual à janela de sinal processado. O método detecta os distúrbios elétricos e proporciona um índice de QEE utilizando apenas o cálculo do quadrado da distância euclidiana como parâmetro para detectar os distúrbios. O índice de QEE obtido pode ser aplicado no conceito de detecção de novidade. O método proposto é avaliado utilizando sinais simulados e sinais reais com implementações em MatLab e em FPGA (*Field-programmable gate array*) com interface em LabVIEW, e comparado com o método baseado em filtragem digital e morfologia matemática (MMF) (Radil et al., 2008).

Posteriormente, neste mesmo capítulo, outra abordagem de detecção de distúrbios elétricos é proposta. O método faz uso inovador da chamada Máquina de Vetor de Suporte *one class*, que é um método de classificação não-supervisionado. Utiliza este algoritmo para construir um envelope multidimensional que circunda as amostras dos sinais sem distúrbios elétricos, realizando a detecção através do conceito de detecção de novidade. Utiliza Estatística de Ordem Superior (EOS) para construir um compacto e representativo vetor de assinaturas dos eventos de QEE. Algoritmos Genéticos são utilizados para selecionar os melhores parâmetros e simplificar o algoritmo de detecção. Este sistema foi testado em simulações para oito classes de distúrbios ocorrendo isoladamente, i.e de forma não simultânea. Neste contexto o sistema apresentou uma eficiência global de 100%.

No Capítulo 4 um sistema de classificação de distúrbios foi proposto. O sistema consiste no desenvolvimento de classificadores especialistas, utilizando ferramentas similares ao detector apresentado anteriormente, onde o algoritmo de classificação baseia-se em SVM *one class* e utiliza-se EOS como ferramenta extratora de parâmetros. A diferença deste sistema de classificação em relação ao detector proposto está no fato de se utilizar o Discriminante Linear de Fisher (FDR) para selecionar os parâmetros mais representativos dos sinais analisados. Nesta abordagem o classificador não supervisionado SVM constrói um envelope multidimensional que circunda as amostras de cada classe de distúrbios, fazendo a classificação das mesmas baseado no conceito de detecção de novidade.

Por fim, no Capítulo 5, as conclusões gerais deste trabalho são apresentadas. Conjuntamente, as perspectivas de continuidade são apontadas, mostrando os possíveis caminhos a serem seguidos como continuidade deste trabalho.

2 QUALIDADE DE ENERGIA ELÉTRICA

O termo QEE (*Power Quality -PQ*) pode ser definido de diferentes maneiras. Referindo-se a aplicações de processamento de sinais uma definição mais abrangente do termo QEE é encontrada em (BOLLEN; GU, 2006), o qual define que QEE corresponde a medida do desvio sinal de tensão entregue à carga em relação a sua forma de onda ideal, um sinal senoidal, com frequência fundamental igual a 60Hz (ou 50Hz) e sem alteração da amplitude nominal. Esta definição está diretamente relacionada à habilidade do sistema elétrico de operar cargas sem danificá-las e à habilidade de cargas operarem no sistema sem perturbar ou reduzir a eficiência do sistema elétrico.

O Conselho Europeu de Regulação de Energia (*Council of European Energy Regulators, CEER*) associa a qualidade do fornecimento de energia elétrica com os seguintes aspectos:

- qualidade comercial - relação entre concessionárias e clientes;
- continuidade no fornecimento - supressão de interrupções; e
- qualidade de energia - tensão livre de distúrbios.

2.1 Distúrbios em QEE

Entende-se como distúrbio de QEE qualquer falha ou desvio das condições desejadas de funcionamento do sistema elétrico em regime permanente. De acordo com a norma do *Institute of Electrical and Electronics Engineers (QUALITY, 1995)* e o PRODIST da Agência Nacional de Energia Elétrica (ELÉTRICA, 2012), os diversos tipos de distúrbios em QEE se enquadram em 7 diferentes categorias: transitórios, variações de curta duração, variações de longa duração, desequilíbrios de tensão, distorções na forma de onda, flutuações de tensão e variações da frequência do sistema. A Tabela 2.1 mostra um resumo, baseado na norma do IEEE (QUALITY, 1995), das principais características dos principais distúrbios elétricos. Em (BOLLEN, 2009), os distúrbios são divididos em duas categorias, que requerem diferentes tipos de processamento: variações e eventos de QEE. As variações de QEE são pequenos desvios da tensão nominal, tais como: variações de tensão, variações de frequência, desbalanceamentos trifásicos, presença de harmônicos e interharmônicos e flutuações de tensão. As definições básicas das variações de QEE estão bem documentadas e padronizadas em (BOLLEN; GU, 2006). Já os eventos de QEE correspondem aos desvios maiores no sinal de tensão, tais como: interrupções, afundamentos de tensão, transitórios oscilatórios e transitórios impulsivos. A seguir será

apresentada uma breve descrição de alguns distúrbios. Neste trabalho as deformidades nas formas de onda de tensão e/ou corrente do sinal elétrico são sempre referenciadas como distúrbios elétricos.

Tabela 2.1 – Características de alguns distúrbios de qualidade de energia.

Categoria	Conteúdo espectral	Duração típica	Amplitude típica
Transitórios			
Transitórios Impulsivos	Tempo de subida entre 5 ns e 1 ms	<1ms	
Sag (afundamento)		0,5 ciclo - 1 min.	0,1 - 0,9 pu
Swell (sobretensão)		0,5 ciclo - 1 min.	1,1 ciclo - 1,8 pu
Interrupção		<1min	0,1 pu
Variações de longa Duração			
Sub-tensão		>1 min.	0,8-0,9 pu
Sobre-tensão		>1 min.	1,1-1,8 pu
Interrupção sustentada		>1 min.	0,0 pu
Distorções da forma de onda			
DC offset		Regime permanente	0-0,1%
Harmônicos	0-1000 harmônico	Regime permanente	0-20%
Inter harmônicos	0-6 KHz	Regime permanente	0-2%
Notching		Regime permanente	-
Ruído	Toda banda	Regime permanente	0-1%

2.1.1 Transitórios


Fenômenos eletromagnéticos provenientes de alterações repentinas nas condições operacionais de um sistema de energia elétrica. O termo transitório é empregado para caracterizar a ocorrência de um evento de curta duração no sistema elétrico, mas de grande importância, uma vez que podem submeter equipamentos a grandes solicitações de tensão e/ou corrente. Muitos transitórios são decorrentes de variações instantâneas na corrente, as quais interagem com a impedância do sistema, resultando em elevadas tensões instantâneas. Transitórios podem também ser consequência de cargas com operação intermitente, chaveamento de bancos de capacitores, faltas fase-terra, operação de dispositivos de semicondutores e falhas em condutores.

De acordo com (QUALITY, 1995), descargas atmosféricas são um caso especial de transitórios devido aos níveis extremamente altos de energia e intervalo de tempo bastante reduzido. Os tipos de transitórios são: impulsivos e oscilatórios.

2.1.1.1 Transitórios Impulsivos

Os transitórios impulsivos são causados por descargas atmosféricas e, geralmente, são caracterizados pelo tempo de subida e de descida do impulso. Sua definição pode ser dada por uma alteração repentina nas condições de regime permanente da tensão, corrente ou ambas, caracterizando-se por apresentar impulsos unidirecionais em polaridade (positivo ou negativo) e com frequência bastante diferente daquela da rede elétrica. A Figura 2.1 mostra dois exemplos típicos de transitórios impulsivos gerados sinteticamente.


Figura 2.1 – Exemplos de transitórios impulsivos (positivo e negativo).



2.1.1.2 Transitórios Oscilatórios

Conforme a norma (QUALITY, 1995), os transitórios oscilatórios consistem em uma rápida variação nos valores e na polaridade da tensão e corrente. São decorrentes de energização de linhas, corte de carga indutiva, eliminação de faltas, chaveamento de bancos de capacitores e transformadores. A Figura 2.2 ilustra dois transitórios oscilatórios gerados sinteticamente.

Figura 2.2 – Exemplos de transitórios oscilatórios na forma de onda da tensão.




2.1.2 Variações de tensão de curta duração

As variações de tensão de curta duração são caracterizadas pela elevação (*swell*), ou redução (*sag*) da amplitude da tensão no sistema durante um curto intervalo de tempo (LATRAN; TEKE, 2015). A redução da amplitude da tensão a valores inferiores a 0,1 p.u. caracteriza uma interrupção momentânea do sistema. Os limites de tempo de ocorrência e intervalo de variação da amplitude da tensão para estes eventos são mostrados na Tabela 2.1. Tais variações de tensão são, geralmente, causadas por condições de falta, energização de grandes cargas as quais requerem altas correntes de partida, curtos-circuitos, ou por falhas intermitentes nas conexões dos cabos do sistema. A Figura 2.3 ilustra variações de tensão com afundamento de tensão em (a), elevação de tensão em (b) e interrupção de tensão em (c).

2.1.3 Variações de tensão de longa duração

As variações de tensão de longa duração são caracterizadas pela alteração do valor RMS (do inglês *Root Mean Square*) da tensão na frequência fundamental do sistema por um período maior que 1 minuto. Estas variações podem ser positivas, caracterizando uma sobre tensão, ou negativas, ocasionando uma sub tensão. Todas elas são geralmente causadas por variações de carga e operações de chaveamento no sistema.

Figura 2.3 – Exemplos de variações de tensão: (a) Afundamento de tensão; (b) Elevação de tensão e; (c) Interrupção.




2.1.4 Deformação da forma de onda da tensão

As distorções das formas de onda de tensão são definidas como desvios da forma senoidal da tensão na frequência fundamental do sistema. Estas distorções se apresentam em regime permanente no sistema e são causadas em sua grande maioria pela presença de tensão de offset, harmônicos, interharmônicos, notches e ruído no sistema elétrico (KHOKHAR et al., 2014). Harmônicas podem ser definidas como deformação de uma senóide fundamental, por meio de outras senóides com frequências e amplitudes diferentes e divididas em ordens: 2^a, 3^a, 4^a, 5^a etc. A terminologia, estabelecida em 2000 pela IEC-61000-2-2, definiu interharmônicos como qualquer distúrbio de distorção de forma de onda com frequência múltipla não-inteira da fundamental. Essa definição inclui, portanto, distúrbios subharmônicos, cujas frequências além de múltiplas não inteiras são inferiores à da fundamental. O efeito 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. As principais características destes tipos de distúrbios são apresentadas na Tabela 2.1. A Figura 2.4 ilustra dois exemplos típicos de deformações da forma de onda da tensão.

2.1.5 Tipos de Desbalanceamentos

São considerados, em nível de classificação, conforme (ARRILLAGA; BOLLEN; WATSON, 2000), quatro tipos de desbalanceamento trifásico, o tipo A que é devido a uma falta trifá-

Figura 2.4 – Exemplos de deformações de tensão: (a) Harmônicos e (b) Notches.



sica e os tipos B, C e D, que são devidos a faltas monofásicas e fase-fase. Basicamente, o tipo A é uma falta trifásica, isto é, um afundamento nas 3 fases. O tipo B é um afundamento em apenas uma das fases. O tipo C é um afundamento em duas das fases e o tipo D é um afundamento em uma das fases e deslocamento de fase das outras duas. Os outros tipos de desbalanceamentos não serão considerados neste trabalho.

3 DETECÇÃO DE DISTÚRBIOS DE QEE

Neste capítulo, dois sistemas de detecção de distúrbios elétricos são propostos. Ambos trabalham no espaço multidimensional dos dados e podem atuar no contexto de DN. Um sistema utiliza apenas cálculo do quadrado da distância Euclidiana para detecção, e o outro utiliza EOS como ferramenta extratora de parâmetros (FERREIRA et al., 2009b), Algoritmo Genético (AG) como selecionador de parâmetros (RAY et al., 2014) e o algoritmo não-supervisionado SVM *one class* (YONG; BHOWMIK; MAGNAGO, 2015) para detecção dos distúrbios de QEE.

3.1 Detecção de Distúrbios

A análise dos distúrbios elétricos refere-se a uma das principais atribuições do monitoramento da qualidade de energia elétrica. Para realizar tal análise, os sinais de tensão e/ ou corrente do sistema monitorado devem ser armazenados para posterior análise ou analisados em tempo real. No entanto, o armazenamento destes gera arquivos de dados de grande extensão. Portanto, torna-se importante utilizar sistemas de detecção que possam armazenar (ou processar no caso de monitoramento em tempo real) apenas os sinais elétricos com distúrbios e, posteriormente, analisá-los realizando a classificação, identificação e localização das fontes geradoras dos mesmos. A detecção deve ser realizada por sistemas com reduzida complexidade computacional e, conseqüentemente, rápido processamento de sinais.

Considera-se que a detecção de distúrbios, compreende basicamente na extração de parâmetros e a aplicação de um algoritmo que realize a detecção baseada nos parâmetros extraídos. A extração de parâmetros consiste em uma transformação dos dados para um novo espaço onde as características dos distúrbios são destacadas em relação aos sinais sem distúrbios. Estas características são então selecionadas e apresentadas à técnica de detecção. Assim, o compromisso em projetar um detector com alto desempenho e rápido processamento está na escolha das técnicas de extração de parâmetros e de detecção.

O problema de detecção pode ser formulado matematicamente pelas hipóteses:

$$H_0 : v = f + r, \quad (3.1)$$

$$H_1 : v = f_c + i + t + h + r, \quad (3.2)$$

em que f , f_c , i , t , h e r correspondem, respectivamente, ao sinal fundamental nominal (frequência e amplitude fixa), ao sinal fundamental corrompido por alguma variação na frequência ou amplitude, interharmônicos, transitórios, harmônicos e ruído. A hipótese (3.1) está associada à operação nominal do sistema elétrico e a hipótese (3.2) está associada às condições anormais do sistema elétrico, isto é, a presença de distúrbios elétricos.

3.2 Estado da Arte de Técnicas de Detecção

A detecção de distúrbios é uma importante etapa na análise do problema de QEE, visto que a correta detecção da presença destes facilita o emprego das técnicas de classificação, identificação e compactação de sinais. Neste contexto, diversos trabalhos de detecção de distúrbios no sinal de tensão têm sido publicados nos últimos anos. Técnicas baseadas na Transformada-S (HUANG et al., 2014), Transformada de Wavelet (KANIRAJAN; KUMAR, 2015; SINGH; JAIN; JAIN, 2016) e Transformada de Hilbert Huang (SHUKLA; MISHRA; SINGH, 2009) têm sido aplicadas para fins de detecção de distúrbios em QEE. Em (CERQUEIRA et al., 2006), a detecção dos eventos é realizada com base na análise de características estatísticas da energia do sinal de erro. É importante mencionar também trabalhos que apresentam técnicas para a detecção de distúrbios de natureza harmônica (MOREIRA; FERREIRA; DUQUE, 2016). Neste trabalho foi proposto um sistema de detecção, classificação e identificação de distúrbios de qualidade de energia, especialmente, harmônicos, subharmônicos e interharmônicos, baseado em EOS.

As EOS têm sido frequentemente utilizadas como ferramenta de extração de parâmetros do sinal, através dos cálculos dos chamados ‘cumulantes’ e aplicadas em diversas áreas (NANDI, 1998). Nos trabalhos propostos em Ferreira et al. (2009b) e Ribeiro et al. (2006), sistemas de detecção de distúrbios elétricos apresentando desempenhos satisfatórios e baixa complexidade computacional foram propostos. Nestes trabalhos, o detector de Bayes é aplicado em um vetor contendo dois parâmetros obtidos utilizando estatísticas de ordem superior (EOS). Adicionalmente, é mostrado nestes trabalhos, que com poucos parâmetros EOS, selecionados utilizando o critério de Fisher (DUDA; HART; STORK, 2000), pode-se caracterizar bem os distúrbios elétricos, no que tange a detecção e a classificação, maximizando então as fronteiras de separação entre os mesmos.

Nos trabalhos de Duque et al. (2005), Ribeiro, Romano e Duque (2004) e Ramos et al. (2002) técnicas baseadas no princípio Dividir e Conquistar são propostas. Em (DUQUE

et al., 2005), foi apresentada, além de uma nova técnica de detecção de distúrbios em baixa, média e alta tensão, uma nova solução para medir o índice de distorção harmônica (THD), que não requer a utilização da Transformada Rápida de Fourier (Fast Fourier Transform - FFT). Em (RIBEIRO; ROMANO; DUQUE, 2004), foi proposto um método (EDCM - *enhanced data compression method*) que utiliza processamento adaptativo de sinais para estimar o componente fundamental do sinal de tensão monitorado e separá-lo da parte transitória, onde foi aplicada a Transformada Wavelet para a análise e representação dos distúrbios. Já em (RAMOS et al., 2002), foi proposta uma nova técnica para detecção e compressão de eventos de QEE em que a técnica EDCM modificada foi introduzida juntamente com a utilização de filtros “notch” e FIR (*Finite Impulse Response*).

É importante ressaltar o atual interesse dos pesquisadores na utilização de técnicas baseadas na DN para o monitoramento da QEE (PIMENTEL et al., 2014). Neste contexto, destacam-se os trabalhos propostos em (RAMOS et al., 2008; ZHANG; MERATNIA; HAVINGA, 2010), que apresentaram resultados interessantes na detecção de distúrbios elétricos, utilizando o conceito de DN. Uma importante contribuição é apresentada por (SILVA et al., 2016). A metodologia proposta divide o sinal em janelas de comprimento fixo, baseando-se na comparação da janela atual com uma janela de referência.

A presente dissertação de mestrado difere dos trabalhos supracitados no sentido em que apresenta duas novas contribuições para a detecção de distúrbios que afetam a QEE. A primeira proposta trata-se de um método simples de detecção de distúrbios, inspirado no método de (FERREIRA et al., 2014). Esta abordagem caracteriza-se por utilizar apenas o cálculo da distância entre dois pontos em um espaço multidimensional para obter o resultado da detecção do distúrbio e fornecer um índice geral de QEE. A segunda proposta trata-se de uma abordagem inovadora referente ao uso de um classificador não supervisionado SVM para construir um envelope multidimensional que circunda as amostras da classe de sinais nominais, realizando a detecção de distúrbios através do conceito de detecção de novidade.

3.3 Sistema de Detecção baseado na Distância Euclidiana

Para o projeto do sistema, utiliza-se como referência para os sinais de tensão monitorados o centro do espaço d -dimensional, definido conforme (3.3).

$$\mathbf{c} = [0 \ 0 \ 0 \ \dots \ 0_d], \quad (3.3)$$

em que d é a dimensão dos dados, dado pelo número de amostras em cada janela de sinal monitorado.

Uma vez que a representação das amostras de eventos nominais formam uma hiperesfera de d dimensões no espaço métrico L2 (espaço euclidiano). Ou seja, devido à característica periódica dos sinais nominais, ao variar sua fase, sua forma corresponderá a uma hiperesfera com dimensão igual ao número de amostras do sinal.

Para a extração de características foi calculado o quadrado da distância euclidiana do ponto no espaço d -dimensional cujos eixos representam os atributos do sinal até a origem deste mesmo espaço (ponto multidimensional \mathbf{c}). O monitoramento é feito a partir do uso de janelas deslizantes de um ciclo do componente fundamental. Desta forma o espaço de origem dos sinais a serem detectados consiste de 256 dimensões, o que equivale a 256 amostras de segmento processado.

Para se ter uma ideia da distribuição dos dados no espaço, considere a representação em 3D, formada pelas amostras de número 30, 60 e 120 dos sinais nominais, mostrada na Figura 3.1. Observa-se, claramente, que os sinais elétricos, com fase variando de -180° a $+180^\circ$, constituem um círculo no espaço, cujo centro é o ponto multidimensional \mathbf{c} , conforme (3.3). Dessa forma, calculando-se a distância (D) de diferentes sinais nominais até a origem desse espaço, pode-se afirmar que um sinal sem distúrbio terá o mesmo valor D , independente da sua fase.

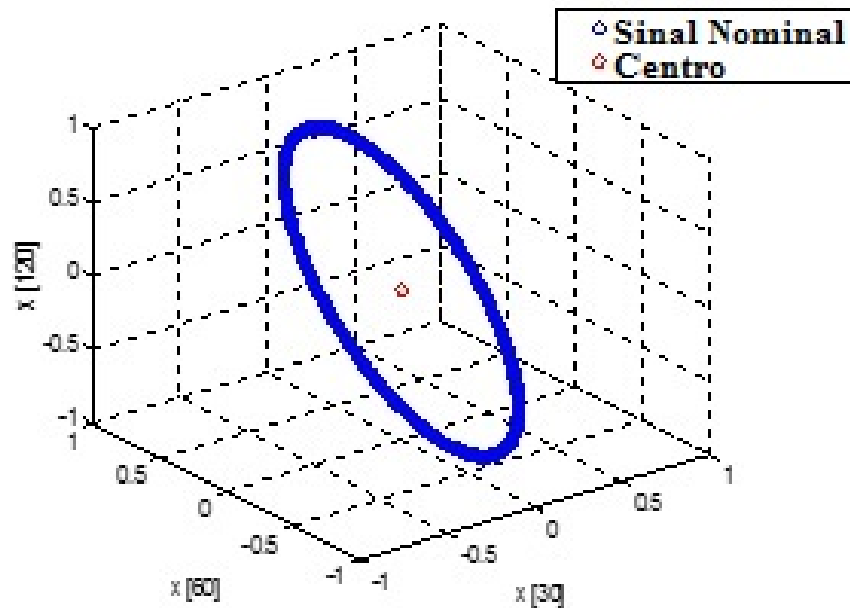
Na fase operacional do método proposto, mede-se o quadrado da distância euclidiana dos sinais monitorados ao centro (ponto multidimensional \mathbf{c}), conforme:

$$D(\mathbf{v}, \mathbf{c}) = E \left\{ \|\mathbf{v} - \mathbf{c}\|_2^2 \right\}, (3.4)$$

em que $E\{\cdot\}$ é o operador esperança.

Verifica-se se o valor da distância obtido está dentro de um intervalo definido por um par de limites (superior e inferior) previamente definido. Este intervalo de limiares define uma região fechada em torno da circunferência que modela os sinais nominais, de modo que os

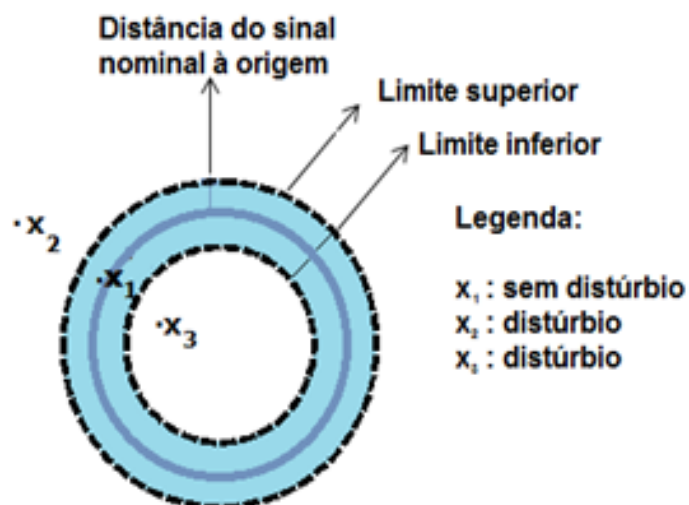
Figura 3.1 – Representação das amostras da classe de sinais nominais em 3D.



eventos no interior dessa região são atribuídos à operação nominal (sem perturbação) e eventos fora desta região são atribuídos a perturbações. A figura 3.2 ilustra o método proposto.

Este parâmetro de distância pode ser utilizado como um índice geral de QEE, medindo o quanto o sinal monitorado desviou de um sinal nominal. Esta abordagem está de acordo com a definição básica de QEE, que mede o desvio do sinal elétrico de uma onda senoidal perfeita (tensão e frequência nominal).

Figura 3.2 – Limiares em torno da circunferência que modela um sinal nominal.




Para o método proposto, duas abordagens foram consideradas:

- Abordagem A): utiliza uma distância do sinal nominal à origem do espaço multidimensional fixa e os limites superior e inferior também fixos, definidos pelo banco de sinais nominais com SNR de 60 dB e;
- Abordagem B): utiliza uma distância e limites superior e inferior ajustados para cada nível de SNR considerada neste trabalho.

A Figura 3.3 mostra a média dos quadrados das distâncias euclidianas dos eventos nominais (sem distúrbios) até o centro (ponto multidimensional c), para cada SNR considerada. À medida que a SNR aumenta, a distância tende a estabilizar, aproximando-se da distância de um sinal sem ruído ao centro. Para SNR pequena, a distância aumenta, e aumenta também o desvio padrão da média, ou seja, aumenta a variação da distância obtida dentro de um conjunto de eventos nominais com a mesma SNR. Logo, para o projeto do detector, devem-se ajustar dois limites de variação da distância, superior e inferior, seguindo os valores mostrados na Figura 3.3, tomando um par de limites para cada SNR.

Figura 3.3 – Valores de média \pm desvio padrão do quadrado da distância euclidiana dos eventos nominais até a origem, ponto multidimensional c , em função da SNR.



Na prática, já que os sistemas elétricos estão sujeitos a variações de SNR devido a interferências que podem ser causadas por diversas fontes, o ideal seria monitorar a relação SNR e ajustar o valor dos limites (superior e inferior) de acordo com as variações da SNR, conforme abordagem B do método proposto.

3.3.1 Base de Dados

Para avaliação de desempenho, sinais de tensão sintéticos foram gerados com uma frequência de amostragem igual a 15.360 Hz. Seis classes de distúrbios foram consideradas: harmônicos, afundamentos de tensão, elevação de tensão, interrupções, transitórios oscilatórios, transitórios impulsivos e notches. Um total de 500 eventos foi gerado para cada classe de distúrbios, e 500 sinais foram gerados sem distúrbios (classe de sinais nominais). Os sinais foram gerados com um ruído branco Gaussiano aditivo a SNRs (Signal-to-noise ratio) de 60 dB, 50 dB, 40 dB, 30 dB e 25 dB. Metade dos dados foi usada para o projeto do método e a outra metade para a avaliação de desempenho.


A fim de avaliar o desempenho do método para sinais reais, 60 formas de onda de distúrbios na tensão foram apresentadas ao método. Estes sinais foram fornecidos pelo grupo de trabalho do IEEE (P1159.3).

Para os testes do método proposto no sistema de aquisição em tempo real, utilizou-se sinais simulados e reais, conforme descritos acima.

3.3.2 Sistema de Detecção de Distúrbios em Tempo Real

Com o intuito de testar a praticidade e complexidade computacional do método em um sistema de aquisição real, foi desenvolvido um sistema de aquisição na plataforma LabVIEW (versão 2011 Professional) utilizando o *hardware* da National Instruments da linha CompactRIO modelo 9076-e, uma placa NI CompactDAQ-9178 e um módulo de entrada analógica NI9201 como mostra a Figura 3.4.

Figura 3.4 – Sistema de Aquisição: 1- Placa NI cDAQ-9178 2- CompactRIO (modelo 9076), 3- Fonte de Energia.



Para transferir as amostras do banco de dados, referente aos sinais simulados e reais descritos na Seção 3.3.1, para o sistema de aquisição, foi utilizada a placa NIcDAQ-9178 através do módulo de saídas analógicas NI9263. Essa placa faz comunicação com o computador por

USB e sua configuração pode ser feita de maneira simples no LabVIEW. No LabVIEW foi configurado que o módulo gerasse os pontos do arquivo de dados a uma frequência de 15,36kHz e escrevesse sempre 1536 pontos. Dessa forma, pode-se ter certeza que a onda entregue ao detector terá 60Hz com 6 ciclos completos de 256 pontos cada.

Para fazer a aquisição dos sinais, foi utilizado o *hardware* da linha CompactRIO modelo 9076-e, através do módulo de entradas analógicas NI 9201. A aquisição é feita a uma frequência constante de 15,36kHz. O sistema de aquisição foi criado baseado na arquitetura do conjunto de instrução pertencente a linha CompactRIO, no qual divide o projeto em basicamente três *targets*: FPGA, *Real Time target* (RT), *Remote Machine* (INSTRUMENTS, 2012), como mostrado na Figura 3.5.

A aquisição foi executada pelo módulo NI9201 que possui um conversor analógico digital interno do tipo SAR (*Successive Approximation Register*) acoplado ao chassis do núcleo de FPGA da *compact Rio*. O *Virtual instrument* (Vi) desenvolvido no FPGA utiliza uma FIFO (*First In, First Out*) do tipo DMA (*Direct Memory Access*) para enfileirar os dados provenientes da aquisição controlando a frequência de amostragem a uma taxa de 15,36kHz com o intuito de respaldar qualquer possível perda de comunicação entre o módulo e o FPGA. Os dados são transferidos para o *Real Time target* via PCI BUS (*Peripheral Component Interconnect Bus*) como mostrado na Figura 3.5.

O *Real Time target* foi programado através de um vi desenvolvido para comunicar-se com o FPGA *target*. Esse vi é responsável pelo ajuste de alguns parâmetros tais como a profundidade da FIFO e a quantidade de amostras a serem lidas. Foi desenvolvido também um sistema de *flush* para, caso ocorra um possível *overflow*, o sistema responda automaticamente esvaziando a fila e reiniciando a aquisição, garantindo assim uma aquisição intermitente via *software*.

Para aplicação do método proposto foi criado um SubVI chamado *Select* como mostrado na Figura 3.6. O SubVI *Select* executa o método proposto na abordagem B, apresentado na Figura 3.7, permitindo apenas o envio das janelas que contêm distúrbios, através da *Network Stream* que baseia-se em uma comunicação ethernet, para qualquer computador ligado a rede local. Isso permite que o usuário, especialista em QEE possa acompanhar o monitoramento do sistema elétrico de qualquer local que tenha acesso à internet.

Como visto na Figura 3.7, a abordagem proposta consiste em calcular o quadrado da distância euclidiana para cada ciclo de 256 pontos. Portanto, o algoritmo é executado seis

Figura 3.5 – Fluxograma do algoritmo de aquisição

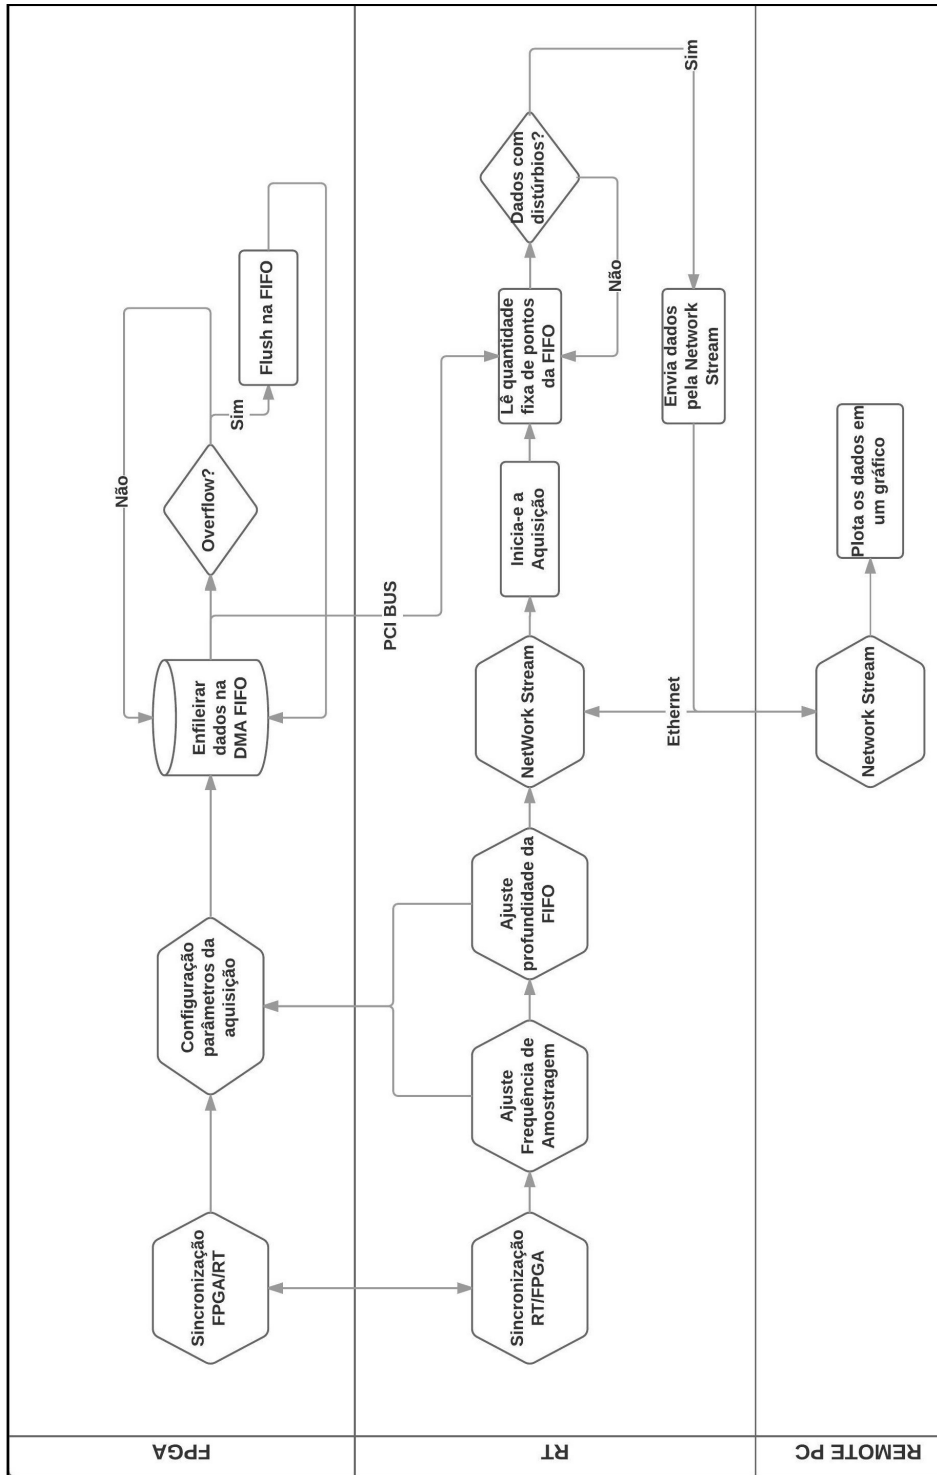


Figura 3.6 – SubVI *Select* que realiza a execução do método proposto.

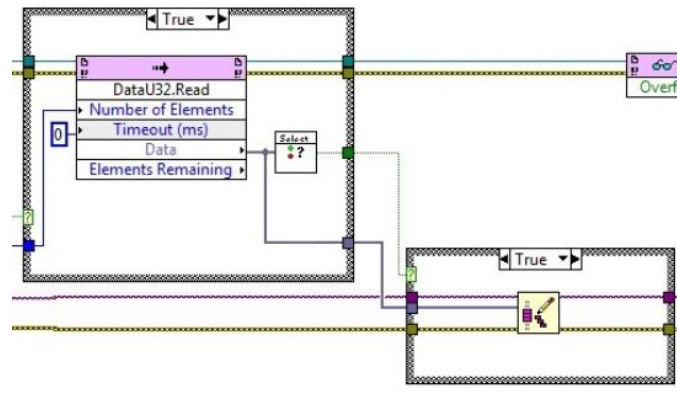
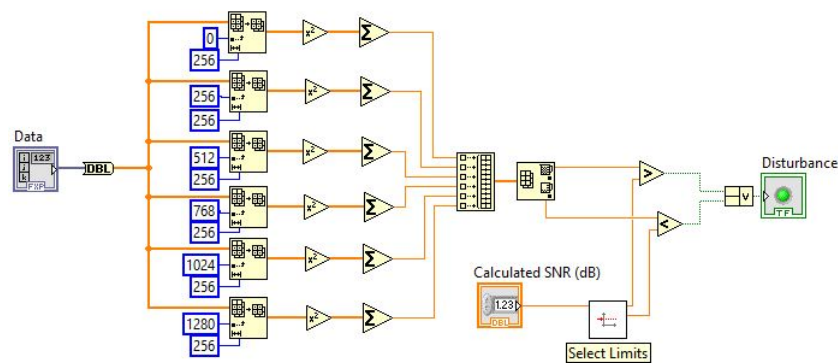


Figura 3.7 – Ilustração da aplicação do método proposto na Abordagem B.

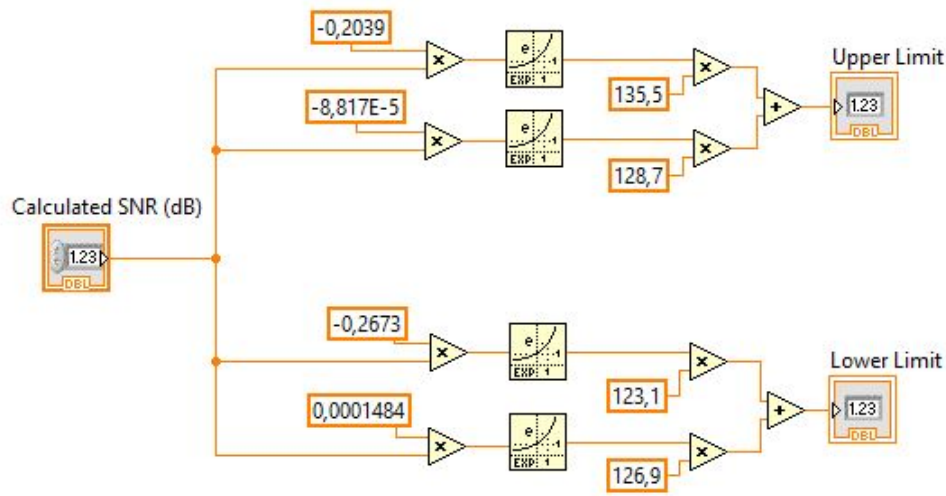


vezes para cada dado de 1536 pontos. Os resultados para essas execuções são salvos em uma matriz e os valores (maior e menor) são selecionados. Estes valores são comparados com os limiares especificados pela função mostrada na Figura 3.8. Esta função é capaz de calcular os limites superior e inferior para o método baseado na SNR do sinal. As equações utilizadas para estimar os limiares em relação ao sinal SNR são descritas em 3.5 e 3.6. Finalmente, dependendo da comparação, o Booleano é alto ou baixo indicando que existe ou não uma perturbação, respectivamente.

$$LimiteSuperior = 135.5exp(-0.2039x) + 128.7exp(-8.817e - 5x) \quad (3.5)$$

$$LimiteInferior = 123.1exp(-0.2673x) + 126.9exp(0.0001484x) \quad (3.6)$$

Figura 3.8 – SubVI de seleção dos limiares.



3.3.3 Resultados e Discussões

3.3.3.1 Resultados para Sinais Simulados

A Tabela 3.1 apresenta o desempenho do método proposto e do método apresentado em Radil et al. (2008), para os sinais simulados do conjunto de dados de validação em função das taxas de probabilidade de detecção (P_d) e probabilidade de falso alarme (P_f). Observa-se que a abordagem A apresentou altas taxas de falso alarme para SNR menor que 60 dB. A abordagem B apresentou melhores resultados com menores taxas de falso alarme. Para SNR de 60 dB, as duas abordagens do método proposto apresentaram resultados similares ao método MMF. Para SNR de 50 dB, apenas a abordagem B do método proposto apresentou resultados similares ao método MMF, com falso alarme nulo. Para maiores níveis de ruído, SNR igual 25 dB, o método proposto na abordagem B apresentou as menores taxas de falso alarme seguido de uma probabilidade de detecção de 90.3%.

O sistema proposto por Radil et al. (2008) aplica os seguintes métodos para monitorar a QEE: filtragem digital e morfologia matemática são utilizadas para detectar e classificar transientes e distorções de forma de onda, enquanto que para os distúrbios de curta e longa duração (*sags*, *swells* e interrupções), realiza-se a análise do valor RMS (*root mean square*) da tensão. O método proposto é adequado para o monitoramento do sistema de energia em tempo real, sendo utilizado como comparador por ser também um método simples que trabalha com limiares.

De acordo com Tomic, Kusljevic e Vujicic (2007), a SNR de sinais de tensão em sistemas de potência varia, na prática, de 50 a 70 dB. Os resultados da Tabela 3.1 mostram que nesta faixa de ruídos o método proposto apresenta boas taxas de detecção (P_d e P_f).

Tabela 3.1 – Desempenho de Detecção de Distúrbios em % para Sinais Simulados.

	SNR				
	60	50	40	30	25
Pd	99.4	97.7	97.7	99.9	99.9
Pf	0.0	23.8	73.2	88.8	94.9
Pd	99.4	99.3	99.2	97.4	90.3
Pf	0.0	0.0	6.4	8.0	10.0
Pd	99.5	99.5	99.5	99.5	99.5
Pf	0.0	0.0	0.0	2.5	99.5

3.3.3.2 Resultados para Sinais Reais

O desempenho do método proposto para sinais reais foi de 100%, de forma que todas as 60 formas de onda de distúrbios na tensão foram detectadas. O método apresentado em Radil et al. (2008) não foi aplicado ao banco de sinais reais, visto que o mesmo utiliza um filtro digital como pré-processamento para eliminar a componente fundamental do sinal de tensão e este filtro gera um transitório que influencia na detecção dos distúrbios, levando a resultados errôneos. O transitório não pôde ser eliminado devido ao número de amostras limitado dos sinais do banco IEEE.

Ressalta-se que, em termos de complexidade computacional, o método proposto apresenta reduzida complexidade, visto que não requer pré-processamento, como filtragem. O método requer apenas o cálculo do quadrado da distância euclidiana entre dois pontos, o que favorece sua implementação em tempo real, por exemplo, em plataformas DSP (*Digital Signal Processor*).

3.3.3.3 Resultados do Sistema de Aquisição

A Tabela 3.2 apresenta o desempenho do método proposto, para os sinais simulados do conjunto de dados de validação em função das taxas de probabilidade de detecção (Pd) e probabilidade de falso alarme (Pf). O sistema de aquisição em tempo real baseou-se na abordagem B do método proposto, onde os limites, inferior e superior, são ajustados de acordo com o nível de ruído presente no sinal. Os testes foram realizados para sinais com um ruído branco Gaussiano aditivo e SNRs de 25 dB, 30 dB e 40 dB.

O desempenho da aplicação do método para sinais reais no sistema de aquisição em tempo real foi de 100%, de maneira que todas as 60 formas de onda de distúrbios na tensão

Tabela 3.2 – Desempenho de Detecção de Distúrbios em % para o Sistema de Detecção em Tempo Real proposto usando a abordagem B (dados de validação).

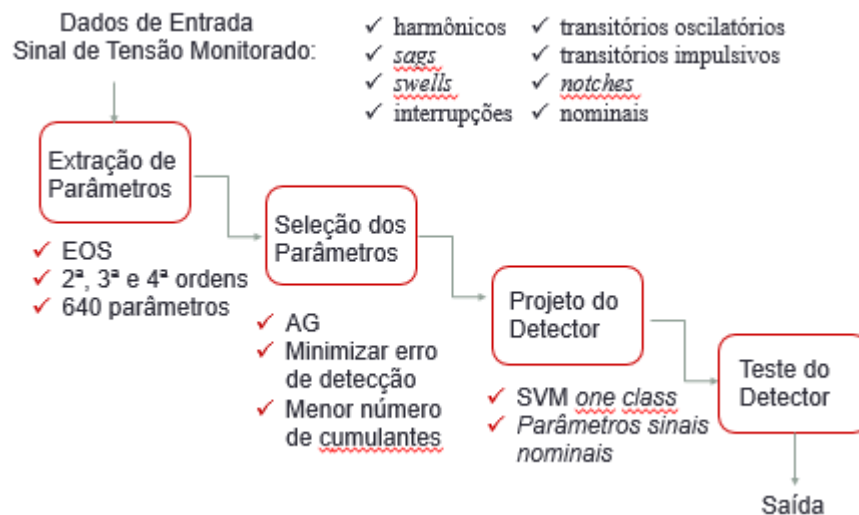
	SNR		
	40	30	25
Pd	100	97.1	97.1
Pf	0.0	0.0	10.0

foram detectadas. Além disso nota-se na Tabela 3.2 que conforme o ruído torna-se mais significativo ocorre uma diminuição da Pd e aumento da Pf.

3.4 Sistema Detecção baseado em Algoritmos Genéticos e Máquina de Vetor de Suporte

Nesta secção é apresentada uma nova proposta para detecção de distúrbios. Para o desenvolvimento deste detector utiliza-se EOS como ferramenta extratora de parâmetros, AG para seleccionar os parâmetros mais significativos e o algoritmo SVM *one class* para detecção dos distúrbios de QEE. O sistema proposto pode ser representado pelo diagrama em blocos da Figura 3.9, em que cada um dos blocos são explicados nos itens listados a seguir.

Figura 3.9 – Esquema geral do método de detecção proposto baseado em AG e SVM.



3.4.1 Dados de Entrada

O sistema proposto foi testado utilizando-se dados simulados, seguindo a metodologia apresentada na Seção 3.3.1, para sinais gerados com ruído branco Gaussiano aditivo a SNR de 60 dB.

3.4.2 Extração de Parâmetros

O bloco Extração de Parâmetros extrai os parâmetros de EOS do sinal pelo cálculo dos cumulantes de segunda, terceira e quarta ordens do sinal de entrada (MENDEL, 1991). Os parâmetros de EOS e o número destes podem ser escolhidos de forma a haver um melhor compromisso entre baixo custo computacional e desempenho. Neste trabalho, devido ao alcance de resultados melhores e satisfatórios, os cumulantes de 2ª, 3ª e 4ª ordens foram utilizados, resultando em uma dimensão total de 640 parâmetros por sinal, sendo equivalente a 128 *lags* do cumulante de segunda ordem, 256 *lags* do de terceira ordem e 256 *lags* do de quarta ordem. As expressões dos cumulantes de 2ª, 3ª e 4ª ordens de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são respectivamente (MENDEL, 1991):

$$C_{2,x}[i] = E\{x[n]x[n+i]\}, \quad (3.7)$$

$$C_{3,x}[i] = E\{x[n]x^2[n+i]\} \quad (3.8)$$

e

$$C_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3C_{2,x}[i]C_{2,x}[0]. \quad (3.9)$$

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões (RIBEIRO et al., 2006):

$$\hat{C}_{2,x}[i] = 2/N \sum_{n=0}^{N/2-1} x[n]x[n+i], \quad (3.10)$$

$$\hat{C}_{3,x}[i] = 2/N \sum_{n=0}^{N/2-1} x[n]x^2[n+i] \quad (3.11)$$

e

$$\begin{aligned} \hat{C}_{4,x}[i] = & 2/N \sum_{n=0}^{N/2-1} x[n]x^3[n+i] \\ & - 2/N^2 \sum_{n=0}^{N/2-1} x[n]x[n+i] \sum_{n=0}^{N/2-1} x^2[n], \end{aligned} \quad (3.12)$$

em que $i = 0, 1, \dots, (N/2) - 1$.

3.4.3 Seleção dos Parâmetros

Para reduzir o número de parâmetros extraídos e, conseqüentemente, a complexidade computacional e o tempo de processamento, Algoritmos Genéticos podem ser utilizados para selecionar um conjunto composto pelos parâmetros mais representativos dentre os obtidos usando EOS. Esta etapa está representada pelo bloco Seleção de Parâmetros. Os Algoritmos Genéticos podem ser definidos como uma técnica de busca baseada numa metáfora do processo biológico de evolução natural, conforme discutido no Apêndice B. Os AGs tendem a ser robustos e eficientes em espaços de busca irregulares, multidimensionais e complexos.

Os AGs simples representam os indivíduos por uma cadeia de bits, aplicam operadores de recombinação e mutação e selecionam os indivíduos proporcionalmente à sua aptidão (BARBOSA, 2009). Usualmente os AGs são implementados conforme (LINDEN, 2006):

1. $t := 0$
2. Inicializa_População $P(0)$
3. Enquanto não terminar faça
4. Avalie_População $P(t)$
5. $P' :=$ Selecione_Pais $P(t)$
6. $P' :=$ Recombinação_e_Mutação P
7. Avalie_População P'
8. $P(t + 1) :=$ Selecione_sobreviventes $P(t), P'$
9. $t := t + 1$
10. Fim Enquanto

A Seleção de Parâmetros do problema proposto, realizada através dos Algoritmos Genéticos, consiste em minimizar o erro de detecção descrito por uma função de aptidão considerando o menor número de cumulantes utilizados. A função de avaliação de cada indivíduo pode ser descrita por:

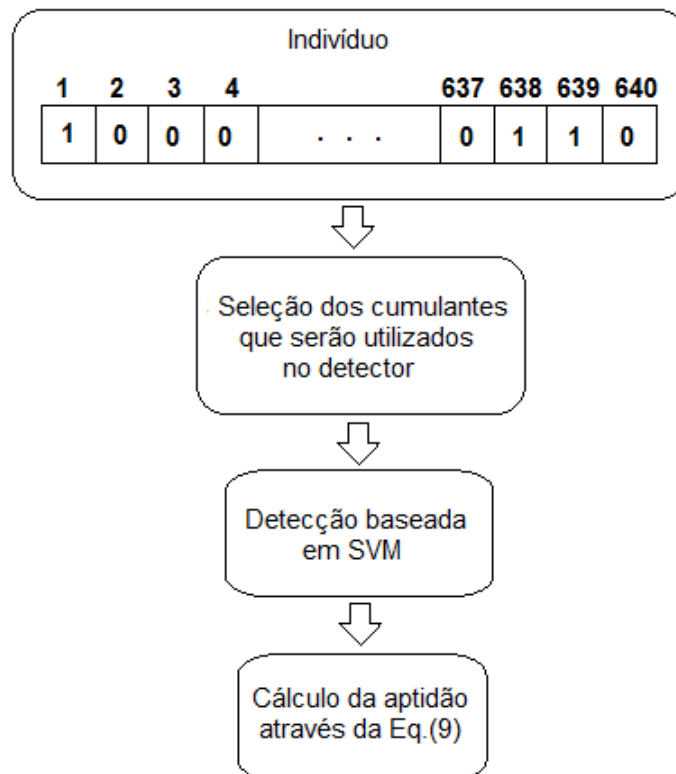
$$\text{Avaliação} = \text{Erro_Detecção} + 0,01 * \text{Número_Cumulantes} \quad (3.13)$$

sendo o termo $0,01 * \text{Número_Cumulantes}$ utilizado para reduzir o número de cumulantes selecionados para o detector, de forma que se o detector obtiver o mesmo erro de detecção, será considerado aquele que possuir menor número de cumulantes.

A população foi constituída por 500 indivíduos(cromossomos), cada um destes representados por sequências binárias com 640 posições, resultantes dos cumulantes extraídos de segunda, terceira e quarta ordem. Cada posição indica o uso ou não do cumulante, representados pelo valor 1 ou 0, respectivamente. Posteriormente, os cumulantes selecionados são apresentados ao detector baseado em SVM, e por último, é feito o cálculo da aptidão (3.13). A Figura 3.10 ilustra a abordagem para avaliação de soluções.

Referindo-se aos parâmetros utilizados pelo AG, optou-se por utilizar a função de mutação uniforme e o operador de cruzamento utilizou multi-pontos. Devido ao fato de serem extremamente dependentes de fatores estocásticos (probabilísticos) e heurísticas de aprendizado, tanto na fase de inicialização da população e escolha de operadores e limiares, quanto na fase de evolução, para seleção dos melhores parâmetros que representam a classe dos sinais nominais em relação a classe dos sinais que contém distúrbios, neste trabalho foram realizadas 10 simulações do AG, cada uma contendo 100 gerações.

Figura 3.10 – Abordagem proposta para seleção genética de parâmetros.




3.4.4 Algoritmo de Detecção via SVM

Neste bloco, é utilizada uma técnica para detectar de forma eficiente a ocorrência de distúrbio através do processamento dos parâmetros extraídos do sinal. Para isso foi empregado o detector baseado em Máquina de Vetor de Suporte, cuja metodologia é detalhada no Apêndice A. O método SVM apresenta uma elevada eficiência na classificação com um esforço computacional relativamente alto comparado a outros métodos (FERREIRA et al., 2009a). Nas pesquisas desenvolvidas recentemente na área de QEE nota-se uma preocupação muito grande com dois aspectos: eficiência elevada aliada a um baixo esforço computacional (FERREIRA et al., 2009a).

Considerando um conjunto de pontos que possuam duas classes como mostrado na Figura 3.11, a estratégia geral do SVM trata-se de estabelecer um hiperplano que coloca a maioria dos pontos da mesma classe no mesmo lado, enquanto maximiza a distância (m) entre duas classes do presente hiperplano. A distância entre uma classe e um hiperplano é a menor distância entre o hiperplano e os outros pontos da mesma classe, e é chamado de hiperplano de separação ótima. O hiperplano de separação criado pelo SVM é traçado ao meio da margem de separação (m). Os subconjuntos de pontos que determinam os planos de separação que originam a margem (m), denominam-se vetores de suporte (BACCARANI et al., 2011). É importante destacar que no presente trabalho foi utilizado o *kernel* RBF (*Radial Basis Function*) para classificação.


Figura 3.11 – Hiperplano SVM ótimo de separação de duas classes.



Para o sistema de detecção proposto neste trabalho foi utilizada uma abordagem conhecida como SVM *one class*. A Figura 3.12 ilustra o funcionamento deste algoritmo, onde o círculo sólido representa o cluster resultante para a classe conhecida no espaço de características, valores de saída positivos são os padrões da classe representada pelos sinais nominais

enquanto os valores alvo negativos são obtidos mediante o agrupamento de todos os padrões de outras classes não conhecidas durante o treinamento, representadas pelos respectivos distúrbios elétricos: harmônicos, afundamentos de tensão, elevação de tensão, interrupções, transitórios oscilatórios, transitórios impulsivos e *notches*.

Figura 3.12 – Modelo do detector proposto baseado em SVM *one class*.



Para treinamento da Máquina de Vetores de Suporte é suficiente apenas o conhecimento dos parâmetros selecionados dos sinais nominais, isto mostra a boa capacidade de generalização das SVMs assim como a não necessidade do conhecimento de todas as classes do problema. Ademais, espera-se detectar distúrbios não abordados neste trabalho sem que haja a necessidade de reprojeter modelos.

3.4.5 Resultados e Discussões

O desempenho do método proposto para os sinais simulados foi analisado em função das taxas de probabilidade de detecção (P_d) e probabilidade de falso alarme (P_f). Vale ressaltar que P_f está relacionado à probabilidade de detecção de distúrbio em um sinal de tensão nominal, isto é, desprovido de qualquer perturbação relacionada a algum distúrbio.

A Tabela 3.3 apresenta o número de parâmetros selecionados pelo AG e o desempenho do detector baseado em SVM em função de P_d e P_f . Utilizando os parâmetros selecionados pelo AG em cada uma das dez simulações e apresentando estes parâmetros ao detector baseado em SVM, o P_d global do método proposto foi de 100%, de forma que todas as formas de onda de distúrbios na tensão foram detectadas. Além disso, obteve-se uma média de 0.04% de P_f .

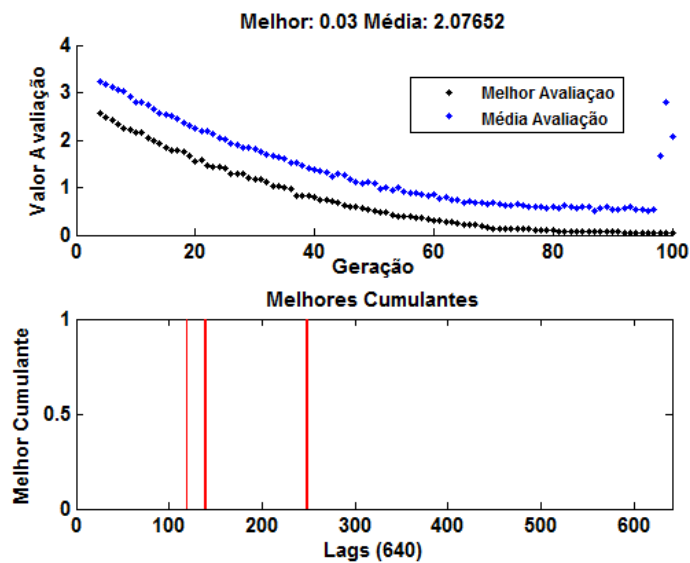
No melhor caso de seleção de parâmetros, onde utiliza-se um menor número de parâmetros e alcança-se um resultado ótimo de detecção, foi necessário o uso de apenas três parâmetros, um de segunda ordem (*lag* 119) e dois de terceira ordem (*lag* 139 e *lag* 248). Os resultados de

Tabela 3.3 – Desempenho do detector para dados de validação em função dos parâmetros selecionados

Testes	Número de Parâmetros Selecionados	Pd(%)	Pf(%)
1	9	100	0.0
2	5	100	0.0
3	8	100	0.2
4	5	100	0.0
5	3	100	0.0
6	8	100	0.2
7	6	100	0.0
8	4	100	0.0
9	7	100	0.0
10	9	100	0.0

valor médio de aptidão e melhor indivíduo da população (cumulantes que atingem o melhor resultado) podem ser observados na Figura 3.13.

Figura 3.13 – Resultado da melhor combinação de parâmetros obtida pelo AG.



4 CLASSIFICAÇÃO DE DISTÚRBIOS DE QEE

Neste capítulo, um sistema de classificação de distúrbios é proposto, em que o classificador especialista baseado em Máquina de Vetor de Suporte é aplicado.

4.1 Classificação de Distúrbios

A etapa de classificação de distúrbios é de grande relevância em um processo de monitoramento da QEE, uma vez que contribui diretamente para identificar e localizar a fonte causadora dos distúrbios. Sabe-se que o problema de classificação de distúrbios é bastante complexo, principalmente quando classes de múltiplos distúrbios são consideradas.

A classificação de distúrbios pode ser realizada sob dados armazenados, de forma *off-line*, ou fazendo a monitoração em tempo real do sistema elétrico. Geralmente, aliar uma técnica com reduzido custo computacional a uma alta eficiência não é uma tarefa fácil. As análises em tempo real requerem técnicas com rápido processamento dos dados e, conseqüentemente, que apresentem reduzida complexidade computacional. As análises *off-line* não requerem rápido processamento e, portanto, técnicas com maior complexidade computacional podem ser empregadas.

Em geral, a classificação é precedida pela etapa de extração de parâmetros e aplicação de técnicas de seleção de parâmetros. Os principais objetivos da extração de parâmetros para fins de classificação são maximizar as fronteiras de separação entre as classes extraindo parâmetros com informações importantes e restritas acerca de cada classe. A seleção de parâmetros realiza a redução da complexidade computacional diminuindo o número de parâmetros, sendo que a utilização de técnicas de seleção de parâmetros torna a escolha dos melhores parâmetros automática e menos dependente do conhecimento do problema por parte do projetista.

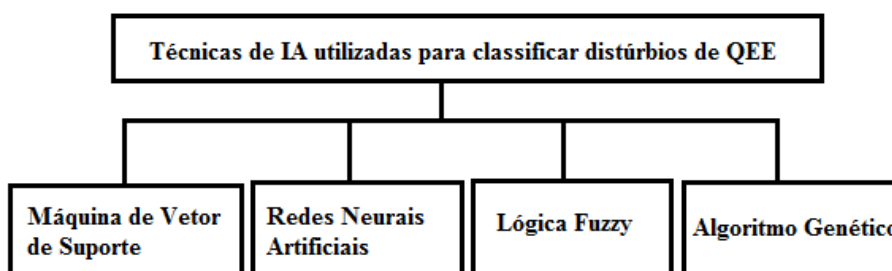
Neste capítulo, será apresentado o desenvolvimento de classificadores especialistas, baseados em Máquina de Vetor de Suporte *one class*. Conforme discutido no Capítulo 3, para uso desta abordagem (SVM *one class*) é suficiente apenas o conhecimento dos parâmetros da classe que se deseja classificar. Baseado nesta característica, foi desenvolvido um classificador especialista para cada uma das classes de distúrbios aqui abordadas. Neste sistema de classificação de distúrbios utiliza-se EOS como ferramenta extratora de parâmetros e FDR (THEODORIDIS et al., 2010) para selecionar os parâmetros mais representativos dos sinais analisados e, conseqüentemente, facilitar o processo de classificação. É importante destacar que o FDR seleciona os parâmetros que apresentam uma melhor separabilidade entre classes distintas, verificando

a distância entre as médias das classes, ponderada pelas suas variâncias, conforme mostrado no Apêndice C. A escolha do uso desta ferramenta de seleção de parâmetros deve-se à sua simplicidade e por já ter sido provado sua efetividade em vários trabalhos de classificação de distúrbios.

4.2 Estado da Arte de Técnicas de Classificação

Uma definição ampla de inteligência artificial (IA) compreende a teoria e a aplicação de técnicas computacionais inspiradas no comportamento humano, tais como, tomada de decisão, resolução de problemas, aprendizagem, percepção e raciocínio (EREMIA; LIU; EDRIS, 2016). Recentemente, o uso de técnicas de IA contribuiu bastante para o desenvolvimento e aperfeiçoamento de técnicas de reconhecimento de padrões. Neste contexto, as principais ferramentas de IA usadas como classificadores de eventos de QEE são mostradas na Figura 4.1 e a seguir algumas recentes contribuições que envolvem a classificação destes eventos são referenciadas.

Figura 4.1 – Principais Técnicas de Classificação de distúrbios de QEE.



O desempenho das técnicas de reconhecimento de padrões está diretamente relacionado com os parâmetros extraídos dos padrões. Em geral, os métodos de classificação de distúrbios de QEE utilizam técnicas de extração de parâmetros seguidas de técnicas tradicionais de reconhecimentos de padrões. No campo de extração de parâmetros com a finalidade de classificação, as Transformadas Wavelets (TW) são as mais empregadas e no campo da classificação, as Redes Neurais Artificiais (RNA), SVMs, Lógica Fuzzy e Algoritmos Genéticos (AG) têm sido as técnicas mais utilizadas.

Com relação ao uso de RNAs na classificação de distúrbios de QEE pode-se destacar os trabalhos de Liu et al. (2014), Valtierra-Rodriguez et al. (2014) e Khokhar et al. (2017). Baseado na excelente capacidade de classificação das RNAs, uma combinação da Kurtosis Espectral (SK) e Rede Neural RBF (*Radial Basis Function*) foram propostas em Liu et al. (2014) para classificar distúrbios transitórios de QEE. Em Valtierra-Rodriguez et al. (2014) uma nova me-

todologia para detectar e classificar os distúrbios QEE isolados e combinados é proposta, constituída, por um lado, por uma Rede Neural Adaline para estimativa harmônica e interharmônica que permite calcular o nível de distorção harmônica total e o valor RMS do sinal de tensão. Por outro lado, uma RNA *feedforward* também é utilizada para classificação de distúrbios. A combinação das RNAs acima mencionadas permite a detecção e classificação de várias classes de distúrbios mesmo quando elas aparecem simultaneamente. Uma nova técnica de classificação automática de distúrbios simples e combinados de QEE é proposta em Khokhar et al. (2017). O algoritmo proposto consiste na utilização da Transformada Wavelet Discreta (DWT) e de um algoritmo inspirado em Colônia de Abelhas Artificiais baseadas em RNA (PNN-ABC).

Máquina de Vetor de Suporte é uma ferramenta de aprendizagem supervisionada aplicada para reconhecimento de padrões (VAPNIK, 2013), utilizada eficientemente em problemas de classificação de eventos de QEE. No trabalho desenvolvido por Cerqueira et al. (2008) é introduzida uma abordagem simples para a extração de características, baseada na subtração do componente fundamental do sinal de tensão monitorado. O sinal resultante é apresentado a SVM para classificação dos eventos. Em Yong, Bhowmik e Magnago (2015) foi proposto um método baseado em TW e SVM para classificar eventos complexos de QEE. O método usa um SVM *multiclass* um contra um (OVO). Os testes e treinamentos foram realizados utilizando-se sinais reais complexos e os resultados mostram que a metodologia proposta é eficiente. Em Erişti, Uçar e Demir (2010) e Eristi e Demir (2012), um eficaz algoritmo de classificação baseado em TW e SVM foi proposto para classificar distúrbios de QEE. Já em Mohanty et al. (2013) os distúrbios de QEE são automaticamente classificados com base na extração de características usando Transformada-S, seguida do treinamento de dois classificadores, Rede Neural Probabilística Modular (*Modular Probabilistic Neural Network* - MPNN) e SVM.

A Lógica Fuzzy tem como desígnio assemelhar-se ao modo aproximado de raciocínio, tentando imitar a habilidade humana de tomar decisões racionais em um ambiente de incerteza. Meher e Pradhan (2010) propuseram a concepção de uma ferramenta para quantificar parâmetros de QEE, usando teoria de TW e Lógica Fuzzy. O método aborda duas questões, tais como a seleção de características discriminatórias e classificação dos distúrbios de QEE com o mínimo de erro. Em Hooshmand e Enshae (2010) foi proposta uma nova abordagem para a detecção e classificação de distúrbios de QEE simples e combinados, utilizando a Lógica Fuzzy e um algoritmo de Otimização de Enxames de Partículas (*Particle Swarm Optimization* - PSO).

Os Algoritmos Genéticos são uma família de modelos computacionais inspirados no processo de evolução natural (EREMIA; LIU; EDRIS, 2016). Normalmente os AG's são vistos como otimizadores de funções, embora a quantidade de problemas para o qual se aplicam seja bastante abrangente. Os AGs são introduzidos como uma poderosa ferramenta para monitorar e supervisionar as perturbações geradas pelo comportamento dinâmico dos sistemas de QEE (EL-NAGGAR; AL-HASAWI, 2006). Um método de análise da QEE através de GA e TW foi apresentado em Wang e Tseng (2011). Em Sánchez et al. (2013), os autores descreveram o desempenho do AG como otimizador da Transformada-S para análise e classificação dos distúrbios em sinais elétricos. Recentemente, os AGs têm sido explorados por vários autores como ferramenta de monitoramento da QEE (SURESH; KANNANAND; MANIKANDAN, 2016; VATANKULU et al., 2016).

É importante evidenciar o uso de outras ferramentas para classificação de distúrbios simples e combinados de QEE (FERREIRA; SEIXAS; CERQUEIRA, 2015; BARBOSA; FERREIRA, 2013). O método proposto por Ferreira, Seixas e Cerqueira (2015) utiliza Análise de Componentes Independentes para classificar distúrbios simples e combinados, alcançando resultados interessantes a partir de sinais simulados e experimentais. Em Barbosa e Ferreira (2013) foi proposto um método para classificar distúrbios simples e combinados baseado no princípio de Dividir e Conquistar. A proposta insere o uso dos classificadores Perceptron e Bayesiano. Com o objetivo de reduzir seu custo computacional, parâmetros foram extraídos através do cálculo dos cumulantes de segunda ordem e do valor RMS dos sinais monitorados. Os resultados mostram que a abordagem pode classificar muitos tipos de perturbações de QEE com boa precisão, mesmo para diferentes valores de SNR e para dados reais.

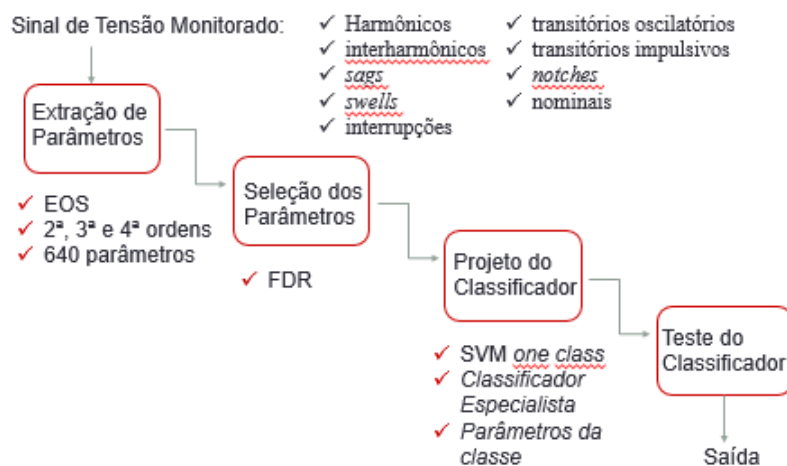
A presente dissertação de mestrado contribui com uma abordagem inovadora no que se refere ao uso do classificador não supervisionado SVM *one class*, para estabelecer um envelope multidimensional que circunda as amostras de cada classe de distúrbios, fazendo a classificação das mesmas através do conceito de detecção de novidade.

4.3 Sistema de Classificação Especialista baseado em Máquina de Vetor de Suporte

Para o projeto e teste do sistema de classificação proposto, seguiu-se uma metodologia semelhante a utilizada no detector descrita no Capítulo 3, Seção 3.4, porém a ferramenta de seleção de parâmetros escolhida foi o Discriminante Linear de Fisher. O diagrama da Figura

4.2 representa a forma geral adotada para o sistema de classificação especialista proposto para cada uma das classes de distúrbios abordadas.

Figura 4.2 – Método de Classificação Proposto.



Na fase de projeto do sistema de classificação, considera-se um ciclo do componente fundamental do sinal, o que é equivalente a 256 amostras. Os dados gerados foram simulados conforme a metodologia apresentada na Seção 3.3.1. Os distúrbios abordados foram: afundamentos de tensão, elevações de tensão, interrupções de tensão, transitórios oscilatórios, harmônicos, interharmônicos, transitórios impulsivos e *notches*.

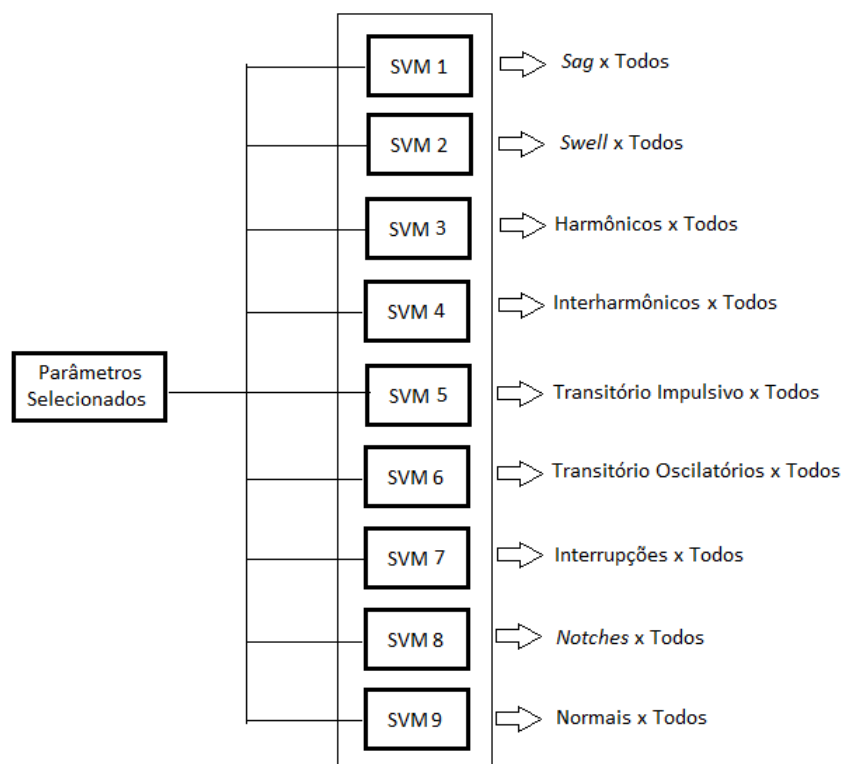
A extração de parâmetros é realizada por meio do cálculo dos cumulantes de segunda, terceira e quarta ordens dos sinais, conforme descrito no Capítulo 3, Seção 3.4.2. Uma vez calculados os 640 *lags* resultantes dos cumulantes de ordens dois, três e quatro, o discriminante de Fisher (FDR) (DUDA; HART; STORK, 2000) é usado para selecionar um conjunto reduzido de dados composto pelos parâmetros mais representativos (do ponto de vista de separação de classes) dentre os obtidos usando EOS. É importante destacar que o FDR seleciona os parâmetros que apresentam uma melhor separabilidade entre classes distintas, verificando a distância entre as médias das classes, ponderada pelas suas variâncias, conforme mostrado no Apêndice C.

O sistema de classificação proposto é representado pela Figura 4.3, onde projeta-se um sistema de classificação especialista (SCE) para cada distúrbio. Dessa forma, o número de SCE é determinado pela quantidade de distúrbios possíveis de estarem presentes do sinal monitorado. A vantagem deste método é a facilidade de incluir novas classes no sistema.

Os parâmetros extraídos através de EOS e selecionados pelo discriminante de Fisher são apresentados a Máquina de Vetor de Suporte *one class*, conforme abordagem descrita no

Capítulo 3, Seção 3.4.4, com o propósito de classificação. Este classificador é responsável pela identificação das seguintes classes: afundamentos/ elevações de tensão, *notches*, transitórios impulsivos, interrupções, harmônicos, interharmônicos, e transitórios oscilatórios.

Figura 4.3 – Sistema de Classificação Especialista baseado em SVM.



4.3.1 Resultados e Discussões

Cada uma das classes de distúrbios é representada por 640 parâmetros, resultantes dos cálculos dos cumulantes de segunda (128 *lags*), terceira (256 *lags*) e quarta (256 *lags*) ordens. Conforme discutido anteriormente, o cálculo dos cumulantes pode envolver um número expressivo de parâmetros, devido aos *lags*. A fim de reduzir a quantidade de parâmetros foi utilizado o FDR para selecionar os *lags* mais significativos para o problema de classificação. As análises realizadas pelo FDR são mostradas nas Figuras 4.4 , 4.5, 4.6, 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12. Nestas figuras são apresentados os cumulantes que apresentam melhor separabilidade entre as classes, para cada uma das classes contempladas no presente trabalho, onde os primeiros 128 parâmetros são referentes aos cumulantes de segunda ordem (*lags* 0-127); os próximos 256 parâmetros correspondem aos cumulantes de terceira ordem (*lags* 0-255); e os últimos 256 são

equivalentes aos cumulantes de quarta ordem (lags 0-255). Como é possível notar, os cumulantes de ordens dois e quatro são os que melhor representam as classes.

Figura 4.4 – FDR para *sags*





Figura 4.5 – FDR para *swells*.



Foram apresentados quinze *lags* dentre os mais representativos da classe ao seu respectivo classificador especialista baseado em SVM *one class*, apenas para o treinamento do classificador especialista em interharmônicos foram necessários cinquenta *lags* para alcançar melhores resultados de classificação. Os resultados finais do classificador, para os eventos de

Figura 4.6 – FDR para harmônicos.





Figura 4.7 – FDR para interharmônicos.



teste, são mostrados na Tabela 4.1 em relação ao percentual de detecção (Pd) e percentual de falso alarme (Pf), onde pode-se observar que o desempenho na classificação é satisfatório, com a eficiência se situando acima de 99,0% considerando-se a média aritmética dos desempenhos obtidos para cada classe de distúrbio.

Figura 4.8 – FDR para transitórios impulsivos.




Figura 4.9 – FDR para transitórios oscilatórios.




Figura 4.10 – FDR para interrupção.


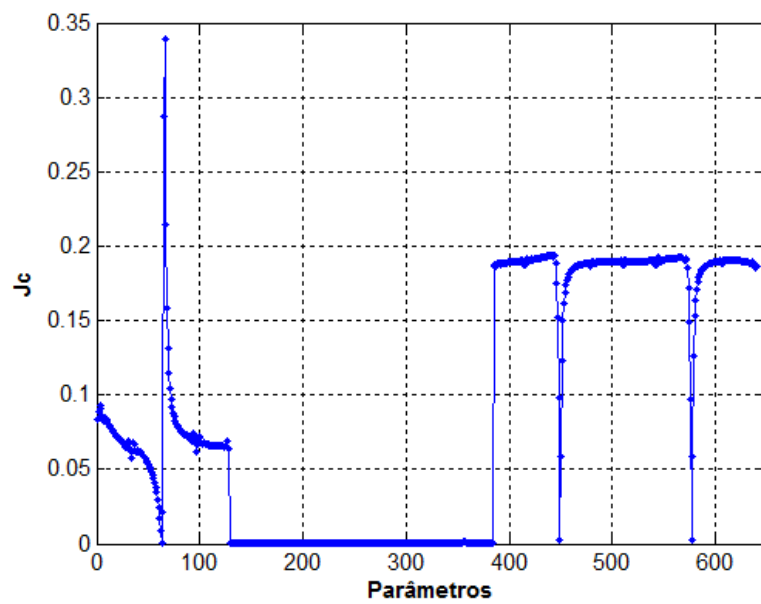
Figura 4.11 – FDR para *notches*.

Figura 4.12 – FDR para sinais normais.




Tabela 4.1 – Desempenho dos Sistemas de Classificação Especialista em %.

Sistema de Classificação Especialista	Pd (%)	Pf (%)
Afundamento de Tensão x Todos	98.66	3.0
Elevação de Tensão x Todos	100.00	4.2
Harmônicos x Todos	99.74	2.4
Interharmônicos x Todos	93.63	28.8
<i>Notches</i> x Todos	100	0.2
Interrupções x Todos	99.69	0.2
Transitório Impulsivo x Todos	100.00	4.6
Transitório Oscilatório x Todos	100.00	10.8
Normais x Todos	100.00	4.2

5 CONCLUSÕES E PERSPECTIVAS

Este trabalho teve por finalidade o desenvolvimento e aperfeiçoamento de técnicas de processamento de sinais e inteligência computacional aplicadas à detecção e classificação de distúrbios elétricos. O trabalho apresentou uma possível topologia para DN em aplicações de QEE dentro do novo cenário das *Smart Grids*. Neste capítulo as peculiaridades dos métodos implementados são discutidas. Sua organização segue aquela adotada na descrição dos métodos e apresentação dos resultados.

5.1 Sistemas de Detecção de Distúrbios

5.1.1 Sistema de Detecção baseado na Distância Euclidiana

Este sistema teve como principal objetivo o desenvolvimento de um método de detecção de distúrbios elétricos em sistemas de potência. A inovação do método está no fato de se trabalhar no espaço d -dimensional dos dados, já que foi mostrado que a classe de sinais nominais forma uma circunferência em d -dimensões. Ademais, apenas um parâmetro foi usado para a detecção, o quadrado da distância Euclidiana dos sinais monitorados ao centro da classe de sinais nominais. Além de poder ser utilizado na detecção de distúrbios, este parâmetro de distância pode ser bastante útil para quantificar a severidade do distúrbio ocorrido em função do seu desvio em relação ao sinal de tensão ideal (nominal), fornecendo um índice geral de QEE. Este índice de QEE pode ser aplicado no contexto de DN medindo-se a distância do ponto no espaço d -dimensional do sinal monitorado até a origem deste mesmo espaço. Caso o valor obtido não esteja dentro dos limites definido pelo sinal nominal, será detectada a presença de novidade. Considerando a nova configuração de geração de energia descentralizada, um novo índice de QEE para verificar a energia gerada e injetada no sistema elétrico é muito importante. O método apresentou bons resultados na detecção de distúrbios em geral, porém, mostrou ser afetado pelo nível de ruído presente no sinal processado. Uma alternativa para melhorar o desempenho do método proposto a variações de SNR no sinal monitorado seria usar um estimador de SNR em pré-processamento e atualizar o limiar do detector de acordo com as estimativas de SNR, conforme mostrado pela abordagem B do método. As principais vantagens do método proposto consistem em sua reduzida complexidade computacional na fase operacional, agregada ao fato de não requerer conhecimento das demais classes para seu projeto e não necessitar ser reprojeto caso uma nova classe emergja a partir de novos dados. O método requer apenas

o quadrado da distância euclidiana do sinal monitorado a um ponto d -dimensional e a comparação do mesmo com um limiar previamente definido. Com isso foi possível implementar este método em um sistema real baseado em FPGA de forma satisfatória.

5.1.2 Sistema de Detecção baseado em Algoritmos Genéticos e Máquina de Vetor de Suporte

O sistema proposto objetivou o desenvolver um método não supervisionado de detecção de distúrbios elétricos em sistemas de potência. Para a extração de parâmetros o uso de EOS foi proposto, através do cálculo dos cumulantes de segunda, terceira e quarta ordens, seguidos da utilização de AG para seleção de parâmetros. Como resultado, um pequeno número de parâmetros a serem usados pelo algoritmo de detecção foi selecionado, o que reduz a complexidade do método proposto. O uso de SVM *one class* forneceu ao método a vantagem de não requerer o conhecimento dos tipos de distúrbios que ocorrem no sistema elétrico, visto que só é necessário o conhecimento da classe de sinal sem distúrbios durante o treinamento, o que torna o método simples. Ademais, o método está apto a detectar novas classes de distúrbios e, naturalmente, pode ser utilizado como detector de novidade. Visto que o aparecimento de novidades (distorções no sinal elétrico) são esperadas com o progresso e implantações de *Smart Grids*. Os resultados, em geral, mostram que o sistema proposto é apropriado para aplicações de QEE, apresentando elevado índice de detecções corretas.

5.1.3 Sistema de Classificação Especialista baseado em Máquina de Vetor de Suporte

Baseado no sistema de detecção proposto no Capítulo 3, Seção 3.4, foi proposto um sistema de classificação especialista. O sistema utilizou um método não supervisionado, SVM *one class*, para classificar distúrbios. EOS foi utilizada como ferramenta extratora de parâmetros, através do cálculo dos cumulantes de segunda, terceira e quarta ordens. Os parâmetros extraídos foram selecionados a partir do método FDR. Como pôde ser observado, a principal diferença do sistema de detecção para o sistema de classificação, consistiu na escolha do algoritmo de seleção de parâmetros. No detector proposto, utilizou-se AG para selecionar os parâmetros mais representativos dentre os extraídos através de EOS. Todavia, no classificador optou-se por utilizar o FDR como ferramenta de seleção. A escolha foi motivada pelo fato de o método FDR possuir menor tempo de processamento e complexidade computacional reduzida quando comparado ao AG. Conforme discutido, para o uso do classificador (SVM *one class*) é suficiente

apenas o conhecimento dos parâmetros de uma das classes em um problema de classificação de duas classes. Baseado nesta característica foi desenvolvido um classificador especialista para cada uma das classes de distúrbios aqui abordadas. Este sistema de classificação apresenta a vantagem de ser possível inserir facilmente uma nova classe de distúrbio a ser classificada, não precisando reformular o classificador. Portanto, este tipo de sistema torna-se útil visando as constantes mudanças observadas no cenário dos sistemas de energia elétrica.

5.2 Perspectivas

A análise de desempenho do método baseado no quadrado da distância Euclidiana para a classificação de distúrbios trata-se de uma interessante proposta de continuidade. Para o projeto do classificador pretende-se obter o cálculo do quadrado da distância Euclidiana dos sinais de cada classe de distúrbio até a origem, e observar as peculiaridades de tal medida individualmente para cada uma das classes abordadas. A distância será utilizada para indicar à qual classe o distúrbio pertence.

A detecção de distúrbios através do uso do classificador não supervisionado SVM *one class*, utilizando EOS para extração de parâmetros e AG para seleção dos parâmetros mais representativos mostrou-se eficiente, apresentando percentual global de detecção de 100%. Em projetos futuros almeja-se explorar esta configuração de projeto para fins de classificação de distúrbios.

Atualmente, a análise de harmônicos, subharmônicos, interharmônicos e supraharmônicos é de grande importância para o controle e proteção de sistemas de potência. Quando trata-se de componentes subharmônicos, interharmônicos e supraharmônicos, os métodos de monitoramento e análise são, em geral, ainda pouco eficientes. Neste contexto, pretende-se empregar as técnicas desenvolvidas neste trabalho para o monitoramento de tais distúrbios.

REFERÊNCIAS

- ARRILLAGA, J.; BOLLEN, M. H.; WATSON, N. R. Power quality following deregulation. **Proceedings of the IEEE**, IEEE, v. 88, n. 2, p. 246–61, 2000.
- BACCARANI, L. M. R. et al. SVM practical industrial application for mechanical faults diagnostic. **Expert Systems with Applications**, v. 38, p. 6980–6984, 2011.
- BARBOSA, B. H. G. **Computação Evolucionária e Máquinas de Comitê na Identificação de Sistemas Não-Lineares**. Tese (Doutorado) — Universidade Federal de Minas Gerais, Mestrado em Engenharia Elétrica, 2009.
- BARBOSA, B. H. G.; FERREIRA, D. D. Classification of multiple and single power quality disturbances using a decision tree-based approach. **Journal of Control, Automation and Electrical Systems**, Springer, v. 24, n. 5, p. 638–648, 2013.
- BOLLEN, M. H. Bridging the gap between signal and power. **IEEE Signal Processing Magazine**, IEEE, v. 23, n. 4, p. 12–31, 2009.
- BOLLEN, M. H.; GU, I. **Signal processing of power quality disturbances**. [S.l.]: John Wiley & Sons, 2006. v. 30.
- BOLLEN, M. H. et al. Power quality aspects of smart grids. In: **International Conference on Renewable Energies and Power Quality**. [S.l.: s.n.], 2010.
- CERQUEIRA, A. et al. Sistema digital de detecção e classificação de eventos de qualidade de energia. **IEEE Latin America Transactions**, v. 4, n. 5, p. 342–349, 2006.
- CERQUEIRA, A. S. et al. Power quality events recognition using a svm-based method. **Electric Power Systems Research**, Elsevier, v. 78, n. 9, p. 1546–1552, 2008.
- CLIFTON, L. et al. Identification of patient deterioration in vital-sign data using one-class support vector machines. In: IEEE. **Computer Science and Information Systems (FedCSIS), 2011 Federated Conference on**. [S.l.], 2011. p. 125–131.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification (pt. 1)**. Wiley-Interscience, 2000.
- DUQUE, C. A. et al. Power quality event detection based on the divide and conquer principle and innovation concept. **IEEE Transactions on Power Delivery**, IEEE, v. 20, n. 4, p. 2361–2369, 2005.
- EL-HAWARY, M. E. The smart grid—state-of-the-art and future trends. **Electric Power Components and Systems**, Taylor & Francis, v. 42, n. 3-4, p. 239–250, 2014.
- EL-NAGGAR, K. M.; AL-HASAWI, W. M. A genetic based algorithm for measurement of power system disturbances. **Electric power systems research**, Elsevier, v. 76, n. 9, p. 808–814, 2006.
- ELÉTRICA, A. . A. N. de E. **PRODIST: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional**. [S.l.]: Relatório técnico, 2012. [Http://www.aneel.gov.br](http://www.aneel.gov.br).
- EREMIA, M.; LIU, C.-C.; EDRIS, A.-A. **Advanced Solutions in Power Systems: HVDC, FACTS, and Artificial Intelligence**. [S.l.]: John Wiley & Sons, 2016.

- ERISTI, H.; DEMIR, Y. Automatic classification of power quality events and disturbances using wavelet transform and support vector machines. **IET generation, transmission & distribution**, IET, v. 6, n. 10, p. 968–976, 2012.
- ERİŞTI, H.; UÇAR, A.; DEMIR, Y. Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. **Electric power systems research**, Elsevier, v. 80, n. 7, p. 743–752, 2010.
- FERREIRA, D. D. et al. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade de energia elétrica. **Sociedade Brasileira de Automática**, v. 20, p. 53–62, 2009.
- FERREIRA, D. D. et al. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, SciELO Brasil, v. 20, n. 1, p. 53–62, 2009.
- FERREIRA, D. D.; SEIXAS, J. M. de; CERQUEIRA, A. S. A method based on independent component analysis for single and multiple power quality disturbance classification. **Electric Power Systems Research**, Elsevier, v. 119, p. 425–431, 2015.
- FERREIRA, D. D. et al. A direct approach for disturbance detection based on principal curves. In: IEEE. **2014 16th International Conference on Harmonics and Quality of Power (ICHQP)**. [S.l.], 2014. p. 747–751.
- GOLDBERG, D. E.; HOLLAND, J. H. Genetic algorithms and machine learning. **Machine learning**, Springer, v. 3, n. 2, p. 95–99, 1988.
- HOOSHMAND, R.; ENSHAEE, A. Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm. **Electric Power Systems Research**, Elsevier, v. 80, n. 12, p. 1552–1561, 2010.
- HUANG, Y.-h. et al. Effective voltage flicker detection approach based on a new modified s-transform algorithm. In: IEEE. **The 26th Chinese Control and Decision Conference (2014 CCDC)**. [S.l.], 2014. p. 4747–4752.
- INSTRUMENTS, N. **NI LabVIEW for CompactRIO Developer's Guide**. J12. [S.l.], 2012. Recommended LabVIEW Architectures and Development Practices for Control and Monitoring Applications.
- JYOTHSNA, V.; PRASAD, V. R.; PRASAD, K. M. A review of anomaly based intrusion detection systems. **International Journal of Computer Applications**, Citeseer, v. 28, n. 7, p. 26–35, 2011.
- KANIRAJAN, P.; KUMAR, V. S. Power quality disturbance detection and classification using wavelet and rbfnn. **Applied Soft Computing**, Elsevier, v. 35, p. 470–481, 2015.
- KHOKHAR, S. et al. A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 51, p. 1650–1663, 2015.
- KHOKHAR, S. et al. A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. **Measurement**, Elsevier, v. 95, p. 246–259, 2017.

- KHOKHAR, S. et al. Matlab/simulink based modeling and simulation of power quality disturbances. In: IEEE. **Energy Conversion (CENCON), 2014 IEEE Conference on**. [S.l.], 2014. p. 445–450.
- LATRAN, M. B.; TEKE, A. A novel wavelet transform based voltage sag/swell detection algorithm. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 71, p. 131–139, 2015.
- LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da inteligência computacional**. [S.l.]: Brasport, 2006.
- LIU, Z. et al. A new classification method for transient power quality combining spectral kurtosis with neural network. **Neurocomputing**, Elsevier, v. 125, p. 95–101, 2014.
- MEHER, S. K.; PRADHAN, A. K. Fuzzy classifiers for power quality events analysis. **Electric power systems Research**, Elsevier, v. 80, n. 1, p. 71–76, 2010.
- MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. **Proceedings of the IEEE.**, v. 79, n. 3, p. 278 – 305, Mar 1991.
- MITCHELL, M.; HOLLAND, J. H.; FORREST, S. When will a genetic algorithm outperform hill climbing? **Ann Arbor**, v. 1001, p. 48109, 1993.
- MOHANTY, S. R. et al. Classification of disturbances in hybrid dg system using modular pnn and svm. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 44, n. 1, p. 764–777, 2013.
- MOREIRA, M. G.; FERREIRA, D. D.; DUQUE, C. A. Interharmonic detection and identification based on higher-order statistics. In: **2016 17th International Conference on Harmonics and Quality of Power (ICHQP)**. [S.l.: s.n.], 2016.
- NANDI, A. K. Higher-order statistics in signal processing. In: **Signal analysis and prediction**. [S.l.]: Springer, 1998. p. 57–77.
- NETO, H. V.; NEHMZOW, U. Real-time automated visual inspection using mobile robots. **Journal of Intelligent and Robotic Systems**, Springer, v. 49, n. 3, p. 293–307, 2007.
- PATCHA, A.; PARK, J.-M. An overview of anomaly detection techniques: Existing solutions and latest technological trends. **Computer networks**, Elsevier, v. 51, n. 12, p. 3448–3470, 2007.
- PIMENTEL, M. A. et al. A review of novelty detection. **Signal Processing**, Elsevier, v. 99, p. 215–249, 2014.
- QUALITY, I. S. C. C. O. P. **IEEE recommended practice for monitoring electric power quality**. [S.l.]: Relatório técnico, IEEE, 1995.
- RADIL, T. et al. Pq monitoring system for real-time detection and classification of disturbances in a single-phase power system. **Instrumentation and Measurement, IEEE Transactions on**, IEEE, v. 57, n. 8, p. 1725–1733, 2008.

- RAMOS, F. et al. On signal processing approach for event detection and compression applied to power quality evaluation. In: IEEE. **Harmonics and Quality of Power, 2002. 10th International Conference on.** [S.l.], 2002. v. 1, p. 133–138.
- RAMOS, P. M. et al. Pq monitoring system for real-time detection and classification of disturbances in a single-phase power system. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 57, n. 8, p. 1725–1733, 2008.
- RAY, P. K. et al. Optimal feature and decision tree-based classification of power quality disturbances in distributed generation systems. **IEEE Transactions on Sustainable Energy**, IEEE, v. 5, n. 1, p. 200–208, 2014.
- RIBEIRO, M. et al. Power quality disturbances detection using hos. In: IEEE. **2006 IEEE Power Engineering Society General Meeting.** [S.l.], 2006. p. 6–pp.
- RIBEIRO, M. V.; ROMANO, J. M.; DUQUE, C. A. An improved method for signal processing and compression in power quality evaluation. **IEEE Transactions on Power Delivery**, IEEE, v. 19, n. 2, p. 464–471, 2004.
- RIBEIRO, P. F. et al. **Power systems signal processing for smart grids.** [S.l.]: John Wiley & Sons, 2013.
- RÖNNBERG, S.; BOLLEN, M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. **The Electricity Journal**, v. 29, p. 49 – 61, 2016.
- SÁNCHEZ, P. et al. Genetic algorithm for s-transform optimisation in the analysis and classification of electrical signal perturbations. **Expert Systems with Applications**, Elsevier, v. 40, n. 17, p. 6766–6777, 2013.
- SANTO, K. G. D. et al. A review on smart grids and experiences in brazil. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 52, p. 1072–1082, 2015.
- SHUKLA, S.; MISHRA, S.; SINGH, B. Empirical-mode decomposition with hilbert transform for power-quality assessment. **IEEE transactions on power delivery**, IEEE, v. 24, n. 4, p. 2159–2165, 2009.
- SILVA, L. R. M. et al. The concept of novelty detection applied to power quality. In: IEEE. **Power and Energy Society General Meeting (PESGM), 2016.** [S.l.], 2016. p. 1–5.
- SINGH, S.; JAIN, B.; JAIN, S. Wavelet based real-time power quality monitoring. In: IEEE. **Electrical and Computer Engineering (CCECE), 2016 IEEE Canadian Conference on.** [S.l.], 2016. p. 1–6.
- SOFMAN, B. et al. Anytime online novelty and change detection for mobile robots. **Journal of Field Robotics**, Wiley Online Library, v. 28, n. 4, p. 589–618, 2011.
- SURESH, S.; KANNANAND, S.; MANIKANDAN, B. Power quality enhancement employing genetic algorithm based asymmetrical multilevel inverter. In: IEEE. **Circuit, Power and Computing Technologies (ICCPCT), 2016 International Conference on.** [S.l.], 2016. p. 1–8.

TAKAHASHI, R. H. Otimização escalar e vetorial. **de Matemática. Universidade Federal de Minas Gerais, D., editor, Notas de aula**, v. 3, 2007.

TARASSENKO, L. et al. Novelty detection. **Encyclopedia of Structural Health Monitoring**, Wiley Online Library, 2009.

TAX, D. M.; DUIN, R. P. Support vector data description. **Machine learning**, Springer, v. 54, n. 1, p. 45–66, 2004.

THEODORIDIS, S. et al. **Introduction to pattern recognition: a matlab approach**. [S.l.]: Academic Press, 2010.

TOMIC, J. J.; KUSLJEVIC, M. D.; VUJICIC, V. V. A new power system digital harmonic analyzer. **IEEE transactions on power delivery**, IEEE, v. 22, n. 2, p. 772–780, 2007.

VALTIERRA-RODRIGUEZ, M. et al. Detection and classification of single and combined power quality disturbances using neural networks. **IEEE Transactions on Industrial Electronics**, IEEE, v. 61, n. 5, p. 2473–2482, 2014.

VAPNIK, V. **The nature of statistical learning theory**. [S.l.]: Springer Science & Business Media, 2013.

VAPNIK, V. N.; VAPNIK, V. **Statistical learning theory**. [S.l.]: Wiley New York, 1998. v. 1.

VATANKULU, Y. E. et al. Estimation of power system harmonics based on spectral model optimisation. In: IEEE. **Signal Processing and Communication Application Conference (SIU), 2016 24th**. [S.l.], 2016. p. 1769–1772.

VLASVELD, R. Introduction to one-class support vector machines. **City**, 2013.

WANG, M.-H.; TSENG, Y.-F. A novel analytic method of power quality using extension genetic algorithm and wavelet transform. **Expert Systems with Applications**, Elsevier, v. 38, n. 10, p. 12491–12496, 2011.

YONG, D. D.; BHOWMIK, S.; MAGNAGO, F. An effective power quality classifier using wavelet transform and support vector machines. **Expert Systems with Applications**, Elsevier, v. 42, n. 15, p. 6075–6081, 2015.

ZHANG, Y.; MERATNIA, N.; HAVINGA, P. Outlier detection techniques for wireless sensor networks: A survey. **IEEE Communications Surveys & Tutorials**, IEEE, v. 12, n. 2, p. 159–170, 2010.

APÊNDICE A – SVM ONE CLASS

O método SVM *one class* é um algoritmo não supervisionado que aprende uma função objetivo para detecção de novidade: classificar novos dados como semelhantes ou diferentes ao conjunto de treinamento (VLASVELD, 2013). Portanto, no SVM *one class*, o modelo de vetor de suporte é treinado com dados de apenas uma classe, que é a classe "normal". Infere as propriedades dos dados normais e através destas pode prever quais exemplos são diferentes dos normais. Visto que a escassez de exemplos de treinamento é o que define anomalias, esta forma de aprendizado torna-se muito útil para a DN, pois usualmente existem poucos exemplos de intrusão de rede, fraude ou outro comportamento anômalo.

A.1 Conceitos Básicos do SVM

SVM é uma técnica de aprendizagem supervisionada utilizada como ferramenta de reconhecimento de padrões e análise de regressão (VAPNIK; VAPNIK, 1998). Tradicionalmente, o SVM é aplicado onde os padrões são representados por duas classes diferentes, cujo objetivo é encontrar o melhor hiperplano que divide os padrões nessas duas classes. A fim de entender os conceitos a respeito do SVM *one class* é importante conceituar o método SVM de duas classes. Considere um conjunto de dados $\Omega = (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, onde os pontos $x_i \in \mathfrak{R}^d$ (dado um exemplo bidimensional), sendo x_i o i -ésimo padrão de entrada de dados e $y_i \in \{-1, 1\}$ o i -ésimo padrão de saída, indicando a associação das classes.

O hiperplano é representado pela equação $w_x^T + b = 0$, com $w \in F$ e $b \in \mathfrak{R}$. O hiperplano construído determina a margem de separação entre as classes, de forma que todos os pontos de dados para a classe -1 estão de um lado e todos os pontos de dados para a classe +1 encontram-se no outro lado. A distância do ponto mais próximo de cada classe até o hiperplano é igual. Assim o hiperplano construído procura maximizar a distância entre as classes. Para evitar que o hiperplano de classificação sofra grandes desvios com dados ruidosos (ou seja, para criar uma margem suave), variáveis de folga ξ_i são introduzidas a fim de permitir que alguns dados fiquem dentro da margem, e a constante $C > 0$ é utilizada para ajustar os erros de treinamento. A função objetivo do classificador SVM é de minimização e apresenta a seguinte formulação:

$$\min_{w,b,\xi_i} \frac{\|w\|^2}{2} + C \sum_{i=1}^n \xi_i \quad (1)$$

sujeito a:

$$y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i, \text{ para todo } i = 1, \dots, n.$$

$$\xi_i \geq 0, \text{ para todo } i = 1, \dots, n.$$

Este problema de otimização restrito é chamado de problema primordial e pode ser solucionado usando o método dos multiplicadores de Lagrange. A função objetivo para uma amostra de dado x torna-se então:

$$f(x) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i K(x, x_i) + b\right) \quad (2)$$

onde α_i são os multiplicadores de Lagrange. Cada $\alpha_i > 0$ é ponderado na função objetivo. Uma vez que as SVMs são consideradas escassas, haverá relativamente poucos multiplicadores de Lagrange com um valor diferente de zero. A função $K(x, x_i) = \phi(x)\phi^T(x_i)$ é conhecida como função kernel. Esta função promove uma transformação do espaço de entradas para um espaço de dimensão mais alta denominado espaço de parâmetros.

A.2 Formulação Matemática do SVM *one class*

Uma possível abordagem do método SVM *one class* é criar uma hipersfera circunscrita em torno dos dados no espaço de característica F (TAX; DUIN, 2004). Este tipo de implementação tem uma abordagem esférica, ao invés de planar. O algoritmo obtém um limite esférico, no espaço de característica F , ao redor dos dados. O volume desta hipersfera é minimizado, para minimizar o efeito da incorporação de *outliers* na solução.

A hipersfera resultante é caracterizada por um centro c e um raio $R > 0$ que representa a distância do centro para qualquer vetor de suporte dentro dos limites. A função objetivo se resume em minimizar o volume (R^2). O centro c é uma combinação linear dos vetores de suporte (que são os pontos de dados de treinamento para os quais os multiplicadores de Lagrange são diferentes de zero). Da mesma forma que a formulação tradicional, pode ser necessário que todas as distâncias dos dados x_i para o centro sejam menores que R , ou seja, que a hipersfera contorne todos os dados, mas, considerando a presença de *outliers* utiliza-se as variáveis de folga ξ a fim de criar uma margem suave com o parâmetro de penalidade C . O problema de minimização torna-se então:

$$\min_{R, c} R^2 + C \sum_{i=1}^n \xi_i \quad (3)$$

sujeito a:

$$\|x_i - \mathbf{c}\|^2 \leq R^2 + \xi_i, \text{ para todo } i = 1, \dots, n.$$

$$\xi_i \geq 0, \text{ para todo } i = 1, \dots, n.$$

Esta função de otimização é resolvida através do uso dos multiplicadores de Lagrange α_i . Após a resolução pode-se testar se um novo dado x_i encontra-se dentro ou fora do *cluster* que define a classe. O dado será considerado como pertencente a classe quando a distância deste ao centro for menor que o valor do raio R , usando o kernel gaussiano como uma função de distância sobre dois pontos de dados calcula-se:

$$\|x_i - c\|^2 = \sum_{i=1}^n \alpha_i \exp\left(\frac{-\|x_i - c\|^2}{\sigma^1}\right) \geq -R^2/2 + C_R. \quad (4)$$

APÊNDICE B – ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos (AG's) baseiam-se no processo de evolução natural dos seres vivos. Os AG's são caracterizados pela "evolução" de um conjunto de soluções (indivíduos da população), regidos por regras estocásticas de busca e combinação que transcorrem ao longo das gerações (TAKAHASHI, 2007). Em um algoritmo genético, basicamente, existem três operadores genéticos: cruzamento, mutação e seleção. Pode-se, portanto, construir um AG a partir dessas três regras, ou pode-se incluir outros tipos de regras, tais como: busca local, nicho, etc.

Em um AG cada indivíduo da população é composto por cromossomos, portanto os AG's processam populações de cromossomos. Um cromossomo trata-se de uma estrutura de dados, que representa uma possível solução do problema a ser otimizado. Como a representação binária é dominante em vários dos textos básicos da área, muitas vezes pode-se escrever *string* (de bits) significando o mesmo que cromossomo. Essa representação foi a adotada inicialmente por Goldberg e Holland (1988), em seu livro seminal .

Um AG inicia-se com uma população inicial de N cromossomos que pode ser gerada de forma aleatória ou a partir de conhecimentos prévios do problema, sendo que o tamanho da população inicial deve ser determinado de acordo com cada problema. Cada um dos indivíduos da população são caracterizados através de uma função de avaliação. Tal medida indica quão bem adaptado o indivíduo está ao ambiente, ou seja, avalia as chances do indivíduo sobreviver e reproduzir-se repassando seu material genética.

Na etapa de seleção, analisa-se a função de avaliação de cada um indivíduos da população, e a partir dessa análise alguns indivíduos são replicados e alguns eliminados, gerando a próxima população. Deve-se destacar que indivíduos menos aptos nunca devem ser totalmente descartados da população reprodutora, pois isto causaria uma rápida convergência genética de todas as soluções para um mesmo conjunto de características e evitaria uma busca mais ampla pelo espaço de soluções O operador de cruzamento combina a informação contida em dois ou mais indivíduos (possíveis soluções), gerando outros indivíduos; e operador de mutação, utiliza a informação contida em um indivíduo, gerando outro indivíduo estocasticamente. O fluxo básico de um AG pode ser representado por:

1. $t := 0$
2. Inicializa_População $P(0)$

3. Enquanto não terminar faça
4. Avalie_População $P(t)$
5. $P' :=$ Selecione_Pais $P(t)$
6. $P' :=$ Recombinação_e_Mutação P
7. Avalie_População P'
8. $P(t+1) :=$ Selecione_sobreviventes $P(t), P'$
9. $t := t + 1$
10. Fim Enquanto

Os AGs não são métodos de *hill climbing* (MITCHELL; HOLLAND; FORREST, 1993), isto é, eles não ficarão estagnados simplesmente pelo fato de terem encontrado um máximo local. A evolução natural não é um processo dirigido à obtenção da solução ótima. Um AG tem o mesmo comportamento que a evolução natural, onde a competição entre os indivíduos é que determina as soluções obtidas. AG trata-se de uma técnica de busca com inúmeras características positivas, tais como: paralela, global, não totalmente aleatórios, não afetada por descontinuidades na função ou em suas derivadas, capaz de lidar com funções discretas e contínuas, boas técnicas para atacar problemas de busca com espaços de busca intratavelmente grandes, que não podem ser resolvidos por técnicas tradicionais.

APÊNDICE C – DISCRIMINANTE LINEAR DE FISHER

Discriminação consiste em se procurar características capazes de serem utilizadas para alocar objetos em diferentes grupos previamente definidos. O discriminante linear de Fisher (FDR - *Fisher Discriminat Ratio*) consiste em uma técnica utilizada para discriminação de dados multi-dimensionais. O FDR tornou-se muito utilizado devido sua simplicidade, podendo ser usado como separador de classes e como ferramenta de seleção de parâmetros (DUDA; HART; STORK, 2000).

C.1 FDR como Separador de Classes

A função discriminante linear de Fisher refere-se a uma combinação linear de características originais que se caracteriza por produzir separação máxima entre duas populações. Para entender ambas aplicações do FDR suponha um espaço de n eventos d -dimensionais, x_1, \dots, x_n , em que n_1 pertence à classe 1 (C_1) e n_2 à classe 2 (C_2). A média das amostras d -dimensionais da classe i é:

$$m_i = \frac{1}{n_i} \sum_{x \in C_i} x. \quad (5)$$

pode-se definir matrizes *scatters* S_i , S_W e S_B por:

$$S_i = \sum_{x \in C_i} (x - m_i)(x - m_i)^T, \quad (6)$$

$$S_W = S_1 + S_2, \quad (7)$$

e

$$S_B = (x - m_i)(x - m_i)^T, \quad (8)$$

onde T significa transposto.

A matriz S_W é conhecida por matriz *scatter* intra-classe e é proporcional à matriz de covariância dos dados. É também simétrica, semi-definida positiva e, usualmente, não-singular se $n > d$. A matriz S_B é também simétrica e semi-definida positiva. Ela chamada de matriz *scatter* inter-classes. Em termos de S_W e S_B , a função custo para o critério FDR como discriminante é escrita como:

$$J(w) = \frac{w^T S_B w}{w^T S_w w}. \quad (9)$$

O vetor w que maximiza $J(\cdot)$ será:

$$w = S_w^{-1} (m_1 - m_2). \quad (10)$$

assim, o vetor w obtido representa a máxima razão entre a matriz *scatter* inter-classes e a intra-classes. Dessa forma, o processo de classificação é convertido de um espaço d -dimensional para um espaço *uni*-dimensional. Neste novo espaço, pode-se obter um limiar que fará a separação entre os dados projetados em w das classes 1 e 2.

C.2 FDR para Seleção de Parâmetros

A função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$J_c = (m_1 - m_2)^T \odot \frac{1}{(D_1)^2 + (D_2)^2} \quad (11)$$

onde $J_c = [J_1 \dots J_{L_l}]^T$; L_l é o número total de parâmetros; m_1 e m_2 , e $(D_1)^2$ e $(D_2)^2$ são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo \odot refere-se ao produto de Hadamard $r \odot s = ([r_0 s_0 \dots r_{L_r-1} s_{L_r-1}])^T$, i.e., produto direto, elemento por elemento, de duas matrizes ou vetores.

Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de J_c , representam os parâmetros que apresentam melhor separabilidade entre classes. Esta técnica é bastante útil em processos de classificação mais complexos, uma vez que torna possível selecionar os melhores parâmetros (que mais discriminam as classes envolvidas) e, conseqüentemente, reduzir o número de parâmetros utilizado na classificação. Esta redução de parâmetros é atraente em sistemas que necessitam de menor complexidade computacional, tais como sistemas que operam em tempo real. Ademais, o uso de um número reduzido de parâmetros pode levar ao projeto de classificadores mais simples e com melhor desempenho, já que os parâmetros responsáveis pela interseção entre classes são, teoricamente, descartados.

APÊNDICE D – LISTA DE PUBLICAÇÕES

Nesta seção, os artigos e resumos relacionados ao desenvolvimento desta, publicados em congressos e periódicos nacionais e internacionais, são apresentados. Os referidos seguem listados.

- "Monitoramento Multidimensional de Qualidade de Energia Elétrica para *Smart Grids*: Implementação em FPGA e Labview." Autores: Thais Martins Mendes, Danton Diego Ferreira, Bruno Henrique Bruno Henrique Groenner Barbosa, Euler Rodrigues Sousa Faria e Lucas Aparecido Vizioli Perle. Publicado no XXI Congresso Brasileiro de Automática - CBA 2016, realizado no período de 3 a 7 de outubro de 2016 em Vitória, ES.
- "Monitoramento da Qualidade de Energia Elétrica Baseado em Algoritmos Genéticos e Máquina de Vetor de Suporte." Autores: Thais Martins Mendes, Danton Diego Ferreira e Bruno Henrique Groenner Barbosa. Publicado no XXI Congresso Brasileiro de Automática, CBA 2016, realizado entre os dias 3 e 7 de outubro de 2016 em Vitória, ES.
- "Multidimensional Monitoring for Power Quality Disturbance Detection." Autores: Thais Martins Mendes, Danton Diego Ferreira e Carlos Augusto Duque. Publicado no 17th International Conference on Harmonics and Quality of Power, realizado entre os dias 16 e 19 de outubro de 2016 em Belo Horizonte, MG.