



**ERICK AKIO NAGATA**

**DETECÇÃO, SEGMENTAÇÃO E CLASSIFICAÇÃO DE  
AFUNDAMENTOS DE TENSÃO EM SISTEMAS ELÉTRICOS  
DE POTÊNCIA**

**LAVRAS-MG  
2018**

**ERICK AKIO NAGATA**

**DETECÇÃO, SEGMENTAÇÃO E CLASSIFICAÇÃO DE AFUNDAMENTOS DE  
TENSÃO EM SISTEMAS ELÉTRICOS DE POTÊNCIA**

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

Prof. DSc. Danton Diego Ferreira  
Orientador

**LAVRAS-MG  
2018**

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

Nagata, Erick Akio.

Detecção, segmentação e classificação de afundamentos de  
tensão em sistemas elétricos de potência / Erick Akio Nagata. –  
Lavras: UFLA, 2018.

89 p.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2018.

Orientador: Danton Diego Ferreira.

Bibliografia.

1. Qualidade de Energia Elétrica. 2. Detecção e Segmentação de  
Afundamentos de Tensão. 3. Classificação de Afundamentos de  
Tensão. I. Ferreira, Danton Diego. II. Título.

**ERICK AKIO NAGATA**

**DETECÇÃO, SEGMENTAÇÃO E CLASSIFICAÇÃO DE AFUNDAMENTOS DE  
TENSÃO EM SISTEMAS ELÉTRICOS DE POTÊNCIA  
DETECTION, SEGMENTATION AND CLASSIFICATION OF VOLTAGE SAGS IN  
ELECTRIC POWER SYSTEMS**

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

APROVADA em 16 de janeiro de 2018.

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

Prof. DSc. Danton Diego Ferreira  
Orientador

**LAVRAS-MG  
2018**

## **AGRADECIMENTOS**

Agradeço à Deus, à Nossa Senhora Aparecida e à Santa Rita de Cássia por me dar forças e me permitirem chegar até aqui.

Ao meu orientador, Danton Diego Ferreira, pela excelência na orientação, pelos ensinamentos passados desde o início da graduação e pelo apoio fundamental na minha formação profissional. Agradeço também pela amizade, tempo e paciência dedicados a mim em todos os momentos.

À toda minha família, meus pais, minha irmã e meus avós pelo suporte e base fundamental na minha vida.

À Larissa, pelo amor, carinho e por estar sempre presente.

Aos professores Dr. Carlos Augusto Duque e Dr. Bruno Henrique Groenner Barbosa, pelo apoio e conhecimentos passados, assim como por disporem a participar da banca examinadora.

Ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação (UFLA) e professores deste programa, pela oportunidade concedida e ensinamentos compartilhados.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo suporte financeiro.

## RESUMO

Com o avanço da tecnologia e aumento no uso de equipamentos eletrônicos, principalmente os da eletrônica de potência, e com a inserção da geração distribuída no sistema elétrico, a qualidade da energia elétrica tem se tornado um fator preocupante tanto para os consumidores quanto para as concessionárias de energia. Dessa forma, pesquisas nessa área visando desenvolver novos métodos de detecção, classificação e mitigação de distúrbios causadores de má qualidade de energia elétrica têm se tornado cada vez mais frequentes e importantes no meio científico. De acordo com este cenário, esse trabalho propõe uma abordagem inovadora para detecção, segmentação e classificação de afundamentos de tensão de acordo com suas causas. Para detectar e segmentar é utilizado a técnica Análise de Componente Independentes, com a vantagem de ser rápida e de baixa complexidade computacional na fase de operação, necessitando de somente 1/8 de ciclo do sinal de tensão e fornecendo respostas em tempo real. Para a classificação foram utilizadas as Estatísticas de Ordem Superior para extrair características relevantes dos sinais monitorados e Redes Neurais e Máquinas de Vetor de Suporte para projetar os classificadores. Foram testadas janelas de 1, 1/2, 1/4 e 1/8 de ciclo da componente fundamental, sendo que os melhores resultados foram alcançados com 1/2 ciclo e com o classificador baseado em Redes Neurais. Tanto para o projeto da detecção/segmentação, quanto para a seleção das características foi utilizada a metaheurística *Teaching-Learning-Based Optimization*. Foram alcançados bons resultados com dados simulados para as três tarefas, sendo que para detecção e segmentação também foram avaliados dados reais. Com dados reais, o método obteve bons resultados de detecção, com 0,86% de erro para o banco de dados utilizado.

**Palavras-chave:** Qualidade de Energia Elétrica. Classificação de afundamentos de tensão. Segmentação de afundamentos de tensão. Geração Distribuída.

## ABSTRACT

Technology advancement and the increased use of electronic equipment and the decentralized energy generation made the electrical power quality to become a growing concern factor for both the energy consumers and power distribution companies. Thus, researches in this area aiming to develop new methods for disturbance detection, classification and mitigation have become more frequent and important in the scientific environment. According to this scenery, this work proposes an innovative approach to detect, segment and classify voltage sags according to their causes. To detect and segment, it is used the statistical signal processing technique known as Independent Component Analysis, with the advantage of being fast and with low computational cost in the operational stage, once it uses only 1/8 cycle of the fundamental component and works in real time. For classification purposes, Higher-Order Statistics are used to extract features and the classifiers are based on Support Vector Machine and Neural Networks. It was tested signal windows of 1, 1/2, 1/4 and 1/8 cycle, and the best results were achieved for signal windows with 1/2 cycle and using a Neural Network as classifier. For both detection/segmentation project and feature selection, it was used the metaheuristics Teaching-Learning-Based Optimization. Suitable results were achieved for simulated signals. In addition, real signals were used to evaluate the detection and segmentation method and good results were achieved for the detection task, presenting 0.86% of error for the data set analyzed.

**Keywords:** Power Quality. Voltage sag classification. Voltage sag segmentation. Distributed Generation.

## LISTA DE FIGURAS

Figura 2.1 – Limiares para variações nas tensões RMS. . . . .	17
Figura 2.2 – Custos relacionados a eventos de afundamento de tensão em diversas indústrias. . . . .	19
Figura 2.3 – Quatro tipos de AT representados em fasores. . . . .	21
Figura 2.4 – Representação do modelo SCICA. . . . .	29
Figura 3.1 – Resumo do desenvolvimento do trabalho. . . . .	35
Figura 3.2 – Diagrama unifilar da rede radial de 15 barramentos com GD. . . . .	36
Figura 3.3 – Exemplos dos três tipos de afundamentos de tensão. . . . .	37
Figura 3.4 – Fluxograma da avaliação de cada indivíduo no algoritmo TLBO. . . . .	42
Figura 3.5 – Fluxograma da fase de operação da detecção/segmentação. . . . .	43
Figura 3.6 – Fluxograma do processo de seleção de características . . . . .	47
Figura 4.1 – Resultado da otimização da linha de detecção com TLBO. . . . .	49
Figura 4.2 – Resposta em magnitude do filtro FIR projetado pelo ICA na fase de projeto. . . . .	50
Figura 4.3 – Exemplo de detecção de afundamento causado por falta trifásica. (a) cada uma das 3 fases do sinal. (b) sinal de saída do método. . . . .	51
Figura 4.4 – Exemplo de detecção de afundamento causado por partida de motor de indução. (a) cada uma das 3 fases do sinal. (b) sinal de saída do método. . .	51
Figura 4.5 – Exemplo de detecção de afundamento causado por saturação de transformador. (a) cada uma das 3 fases do sinal. (b) sinal de saída do método. . . . .	52
Figura 4.6 – Exemplos de AT detectados para cada um dos casos (b1, b2, b3 e b4) com outros distúrbios. . . . .	59
Figura 4.7 – Erro de classificação de treinamento (seleção dos melhores cumulantes) e de teste para classificador SVM. (a) Janela de 1 ciclo. (b) Janela de 1/2 ciclo. (c) Janela de 1/4 de ciclo. (d) Janela de 1/8 de ciclo. . . . .	60
Figura 4.8 – Erros de classificação de treinamento (seleção dos melhores cumulantes) e de teste para classificador MLP. (a) Janela de 1 ciclo. (b) Janela de 1/2 ciclo. (c) Janela de 1/4 de ciclo. (d) Janela de 1/8 de ciclo. . . . .	62
Figura 4.9 – Sinal real de afundamento bifásico e a resposta do método para cada fase. .	65

Figura 4.10 – Sinal real de afundamento trifásico de dois estágios e a resposta do método para cada fase. . . . .	66
Figura 4.11 – Sinal real de afundamento causado por saturação de transformador e a resposta do método para cada fase. . . . .	66
Figura 4.12 – Comparação entre Wavelet e SCICA para segmentação de AT na presença de ruído. (a) AT de 13% sem <i>phase-jump</i> . (b) AT de 13% com – 10° de <i>phase-jump</i> . . . . .	68
Figura A.1 – Estrutura de uma rede do tipo perceptron de múltiplas camadas (MLP). . .	81
Figura C.1 – Fluxograma de execução do TLBO. . . . .	86

## LISTA DE TABELAS

Tabela 2.1 – Características dos principais distúrbios elétricos segundo IEEE. . . . .	15
Tabela 2.2 – Classificação das Variações de Tensão de Curta Duração segundo ANEEL. . . . .	17
Tabela 2.3 – Tipo de AT resultante de diferentes tipos de falta e tipos de conexão da carga. . . . .	21
Tabela 3.1 – Tipos de faltas utilizadas para gerar ATs e as respectivas porcentagens de eventos para cada tipo de falta. . . . .	35
Tabela 3.2 – Quantidade de neurônios na camada escondida. . . . .	46
Tabela 4.1 – Desempenho de detecção para diferentes níveis de ruído. . . . .	53
Tabela 4.2 – Desempenho de segmentação para diferentes níveis de ruído. . . . .	54
Tabela 4.3 – Desempenho de detecção para sinais sintéticos com somente afundamentos de tensão causados por falta. . . . .	56
Tabela 4.4 – Desempenho de detecção para sinais sintéticos com afundamentos de tensão e outros distúrbios. . . . .	58
Tabela 4.5 – Matriz de confusão da classificação com dados de teste (SVM com 20 cumulantes e janela de 1 ciclo). . . . .	61
Tabela 4.6 – Matriz de confusão da classificação com dados de teste (MLP com 7 cumulantes e janela de 1/2 ciclo e MLP com 4 cumulantes e janela de 1/8 de ciclo). . . . .	63
Tabela 4.7 – Erros de classificação com MLP para sinais simulados com outros distúrbios. . . . .	64
Tabela 4.8 – Desempenho de detecção e segmentação para dados reais. . . . .	66
Tabela 4.9 - Comparação entre um método baseado em transformada Wavelet e o método proposto (SCICA) para segmentação de afundamentos e elevações de tensão. . . . .	68

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>11</b>
1.2	Objetivos e como o problema foi abordado para atingi-los.....	12
1.3	Estrutura do Trabalho .....	12
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>14</b>
2.1	Qualidade de energia elétrica .....	14
2.2	Distúrbios de Qualidade de Energia Elétrica .....	15
2.3	Variações de tensão de curta duração .....	16
2.3.1	Diferença de fase associada a afundamentos e elevações de tensão ( <i>phase-angle-jump</i> ) .....	18
2.3.2	Causas e efeitos dos afundamentos de tensão de curta duração .....	18
2.3.2.1	Afundamentos de tensão causados por falta .....	19
2.3.2.2	Afundamentos de tensão causados por saturação de transformadores .....	22
2.3.2.3	Afundamentos de tensão causados por partida de motores de indução.....	22
2.4	Sistemas com geração distribuída .....	23
2.5	Processamento de Sinais e Inteligência Computacional aplicados na Qualidade de Energia Elétrica .....	25
2.6	Deteção e segmentação de afundamentos de tensão .....	26
2.6.1	Análise de Componentes Independentes (ICA) .....	26
2.6.2	Single Channel Independent Component Analysis (SCICA) .....	28
2.7	Extração e seleção de características .....	30
2.8	Trabalhos já realizados na área .....	31
<b>3</b>	<b>MATERIAL E MÉTODOS .....</b>	<b>34</b>
3.1	Geração de bancos de dados simulados e sintéticos .....	34
3.2	Sistema de deteção de afundamentos de tensão. ....	38
3.2.1	Fase de projeto .....	38
3.2.2	Fase de operação .....	41
3.3	Sistema de classificação de afundamentos de tensão.....	43
3.3.1	Extração de características .....	44
3.3.2	Seleção de características .....	44
<b>4</b>	<b>RESULTADOS .....</b>	<b>49</b>
4.1	Resultados de deteção e segmentação .....	49

4.1.1	Desempenho de detecção e segmentação para sinais simulados via Simulink ....	52
4.1.2	Desempenho de detecção e segmentação para sinais sintéticos de afundamentos causados por falta .....	54
4.2	Resultados de classificação .....	60
4.2.1	Resultados com o classificador SVM .....	60
4.2.2	Resultados com classificador Perceptron de Multicamadas (MLP) .....	62
4.2.3	Resultados de classificação na presença de outros distúrbios .....	63
4.3	Resultados com dados reais .....	64
4.4	Comparação com outros métodos .....	67
4.4.1	Comparação com método de detecção e segmentação baseado em transformada Wavelet .....	67
4.4.2	Comparação com outros métodos de detecção/segmentação e classificação.....	69
4.5	Aplicações dos sistemas de detecção, segmentação e classificação de ATs.....	70
5	CONCLUSÃO E PERSPECTIVAS .....	72
5.1	Perspectivas .....	73
	REFERÊNCIAS .....	74
	APÊNDICE A – REDES NEURAIS ARTIFICIAIS .....	80
	APÊNDICE B – MÁQUINA DE VETOR DE SUPORTE (SVM).....	82
	APÊNDICE C – TEACHING-LEARNING-BASED OPTIMIZATION (TLBO) .....	85
	APÊNDICE D – ESTATÍSTICAS DE ORDEM SUPERIOR (EOS) .....	87
	APÊNDICE E – DISCRIMINANTE LINEAR DE FISHER .....	88
	APÊNDICE F – LISTA DE PUBLICAÇÕES .....	89

## LISTA DE ABREVIATURAS

AT	Afundamento de tensão
Det	Detecção
EOS	Estatísticas de Ordem Superior
ET	Elevação de tensão
FIR	<i>Finite impulse response</i>
GD	Geração distribuída
ICA	<i>Independent Component Analysis</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean square error</i>
PMI	Partida de motor de indução
QEE	Qualidade de energia elétrica
RMS	<i>Root mean square</i>
SCICA	<i>Single Channel Independent Component Analysis</i>
Seg	Segmentação
SEP	Sistema elétrico de potência
SNR	<i>Signal-to-noise ratio</i>
SOBI	<i>Second Order Blind Identification</i>
ST	Saturação de transformador
SVM	<i>Support Vector Machine</i>
THD	<i>Total harmonic distortion</i>
TLBO	<i>Teaching-Learning-Based Optimization</i>

## 1 INTRODUÇÃO

Até algumas décadas atrás, podia-se considerar que as cargas residenciais eram praticamente lineares. Naquela época, qualidade de energia elétrica (QEE) era relacionada basicamente com a continuidade do serviço da entrega da energia elétrica, ou seja, com as interrupções de energia. Com o avanço da tecnologia, cada vez mais equipamentos eletrônicos que exigem energia elétrica de qualidade e que também “injetam” distúrbios elétricos na rede estão sendo utilizados. Tais distúrbios se tornaram muito mais complexos do que as simples interrupções de energia que preocupavam os consumidores antigamente.

Tanto para as concessionárias de energia quanto para os consumidores, esses distúrbios podem gerar sérios danos e grandes prejuízos econômicos. Redução da vida útil de equipamentos, mau funcionamento dos equipamentos de proteção e interrupções na produção são algumas das várias consequências geradas pelos distúrbios elétricos. Consequentemente, os consumidores de energia elétrica estão cada vez mais exigentes com a qualidade da energia disponível na rede. Por outro lado, as concessionárias se veem obrigadas a monitorarem essa qualidade, buscando sempre entregar uma energia dentro dos padrões que estão cada vez mais rigorosos.

O crescimento do uso de redes com Geração Distribuída (GD) e o surgimento das *Smart Grids* também fizeram aumentar muito a preocupação com a QEE. Se por um lado as fontes renováveis de energia e técnicas para gerenciá-la trazem muitos benefícios e vantagens para os consumidores, por outro lado novos padrões de QEE são inseridos no contexto nacional e internacional, o que aumenta a demanda e eficiência exigida no controle da QEE.

Tendo em vista este cenário, pesquisas na área de QEE tiveram um crescimento substancial nos últimos anos. Dentre os temas abordados, a detecção, segmentação e classificação dos distúrbios elétricos são de grande importância. E dentre os distúrbios existentes, os afundamentos de tensão são um dos mais comuns e que causam mais prejuízos aos consumidores e concessionárias. Dessa forma, a detecção e investigação de suas causas se tornam algo de grande necessidade para os sistemas elétricos de potência (SEP).

Muitos trabalhos fazem a classificação de distúrbios de acordo com os tipos de distúrbios (harmônicos, transitórios, afundamentos de tensão etc). No entanto, a classificação do evento de acordo com suas causas pode ser mais útil para o sistema de monitoramento no que diz respeito a identificar as causas do evento e a entender o desempenho do sistema, uma vez que é identificada a origem do distúrbio, permitindo uma melhor análise do problema. Os estudos referentes a esses tipos de classificação ainda estão abertos dentro da área de QEE.

A detecção e classificação automática dos afundamentos de tensão permite criar um banco de dados de eventos que pode ser utilizado para análises estatísticas do SEP. A detecção feita de forma rápida e *online* desse distúrbio é fundamental para os sistemas de proteção. Além disso, o classificador pode ser usado para avaliar e otimizar o sistema de proteção, que muitas vezes entra em operação sem necessidade, como por exemplo em casos de partida de motores de indução e saturação de transformadores, que são confundidos com afundamentos causados por faltas, mas que não necessitam da operação do sistema de proteção.

## **1.2 Objetivos e como o problema foi abordado para atingi-los**

O objetivo deste trabalho é utilizar técnicas de inteligência computacional e processamento de sinais para desenvolver um novo método de detecção, segmentação e classificação de afundamentos de tensão de acordo com suas causas principais: falta, partida de motor de indução e saturação de transformadores.

Para desenvolver o método de detecção, segmentação e classificação foram utilizados sinais simulados via Simulink/MATLAB através de uma rede com geração distribuída. Foi utilizada a Análise de Componentes Independentes para desenvolver os métodos de detecção e segmentação. Objetivou-se desenvolver um método computacionalmente simples e eficiente para permitir a aplicação em tempo real, de tal forma a utilizar a menor janela possível do sinal de tensão e com processamento simples na fase de operação do método. Para a tarefa de classificação também se buscou por uma abordagem de baixa complexidade e de alto desempenho, com rápida resposta e possibilidade de aplicação *online*. Para isso, otimizou-se as etapas de extração e seleção de características do sinal elétrico, de tal forma a projetar classificadores mais simples e eficientes. Os classificadores testados foram baseados em SVM e Redes Neurais. A extração de características foi realizada com as Estatísticas de Ordem Superior e a seleção foi realizada através da metaheurística TLBO, que também foi utilizada para otimizar o projeto do método de detecção e segmentação.

## **1.3 Estrutura do Trabalho**

Este trabalho está organizado da seguinte forma: no Capítulo 2 é feita uma revisão de literatura, mostrando os principais conceitos e trabalhos da área. Em seguida, no Capítulo 3, é descrito como foram gerados os dados e desenvolvidos os métodos de detecção, segmentação

e classificação de afundamentos de tensão. No Capítulo 4 são expostos os resultados referentes a essas três tarefas para dados simulados, resultados de detecção e segmentação para dados reais e comparações entre os métodos propostos e outros métodos encontrados na literatura. Finalmente, no Capítulo 5, são expostas as conclusões e perspectivas de continuidade deste trabalho.

## 2 REFERENCIAL TEÓRICO

### 2.1 Qualidade de energia elétrica

De acordo com a norma IEEE Std 1159 (*INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS – IEEE, 2009*), o termo qualidade de energia se refere a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão e corrente em um dado instante e em uma dada localização no sistema elétrico de potência (SEP). De acordo com a norma IEC Std 61000-4-30 (*INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC, 2015*), qualidade de energia envolve as características da eletricidade em um determinado ponto do sistema elétrico, avaliadas de acordo com um conjunto de parâmetros técnicos de referência. Segundo Bollen e Gu (2006), uma definição mais simples de qualidade de energia elétrica (QEE) se resume em qualidade de tensão e de corrente. Por sua vez, qualidade de tensão e de corrente pode ser simplificada em uma forma de onda de tensão senoidal com constante amplitude e frequência.

A QEE tem se tornado uma crescente área de pesquisa devido a vários fatores, tais como:

- Ao aumento de consumidores residenciais, comerciais e industriais, assim como da necessidade de geração de energia renovável devido a fatores econômicos, como por exemplo a menor susceptibilidade a paradas na produção em uma indústria (MORSI; EL-HAWARY, 2008; SAINI; KAPOOR, 2012).
- O crescimento do uso de equipamentos eletrônicos (principalmente os da eletrônica de potência) que geram distúrbios eletromagnéticos e que também são susceptíveis a esses mesmos distúrbios (GARGOOM; ERTUGRUL; SOONG, 2008).
- O aumento do uso de energia renovável e da inclusão das *Smart Grids*, que fazem uso de muitos equipamentos eletrônicos não lineares e de chaveamento, que injetam distúrbios na rede (MAHELA; SHAIK; GUPTA, 2015).
- A regulamentação ainda em implementação do setor elétrico de acordo com os conceito e novo cenário de QEE (FERREIRA, 2010).

Tendo em vista tal cenário, organizações internacionais e nacionais vêm realizando estudos para definições de normas e padrões de QEE (FERREIRA et al., 2009a). No Brasil, desde 2008 o governo vem trabalhando para regulamentar o setor através do PRODIST: Procedimentos de Distribuição. O módulo 8 do PRODIST trata tanto da caracterização e padronização de indicadores dos fenômenos de QEE quanto das responsabilidades por parte

das concessionárias (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2014). Internacionalmente, tanto o IEC (*International Electrotechnical Commission*) quanto o IEEE (*Institute of Electrical and Electronics Engineers*) possuem padrões definidos de QEE, tais como IEC Std 61000-4-30 (2015) e IEEE Std 1159 (2009).

## 2.2 Distúrbios de Qualidade de Energia Elétrica

Os fenômenos causadores de má QEE são comumente chamados de distúrbios elétricos. Os distúrbios elétricos podem ser definidos como qualquer desvio manifestado na tensão, corrente ou frequência que esteja fora do padrão, resultando em falhas e mal funcionamento de equipamentos elétricos e eletrônicos (MAHELA; SHAIK; GUPTA, 2015).

Os distúrbios de QEE são normalmente divididos de acordo com seu tempo de duração, conteúdo espectral e amplitude típica (ARRUDA, 2003). Segundo a norma IEEE 1159 (2009), os distúrbios de QEE podem ser divididos em sete categorias principais, que são mostradas na Tabela 2.1.

Neste trabalho, os distúrbios abordados serão os afundamentos de tensão (AT) de curta duração (*voltage sag*). Portanto, definições mais detalhadas desse fenômeno serão abordadas nas próximas seções.

Tabela 2.1 – Características dos principais distúrbios elétricos segundo IEEE (continua).

Classificação	Conteúdo Espectral Típico	Duração Típica	Magnitude Típica
<b>1.0 Transientes</b>			
<b>1.1 Impulsivos</b>			
1.1.1 Nanossegundo	5 ns	< 50 ns	
1.1.2 Microssegundo	1 $\mu$	50 ns – 1 ms	
1.1.3 Milissegundo	0,1 ms	> 1 ms	
<b>1.2 Oscilatórios</b>			
1.2.1 Baixa Frequência	< 5 kHz	0,3 – 50 ms	0 – 4 pu <sup>a</sup>
1.2.2 Média Frequência	5-500 kHz	20 $\mu$ s	0 – 8 pu
1.2.3 Alta Frequência	0,5-5 MHz	5 $\mu$ s	0 – 4 pu
<b>2.0 Variação de tensão de curta duração</b>			
<b>2.1 Instantânea</b>			
2.1.1 Afundamento de tensão		0,5 - 30 ciclos	0,1 – 0,9 pu
2.1.2 Elevação de tensão		0,5 - 30 ciclos	1,1 – 1,8 pu
<b>2.2 Momentânea</b>			
2.2.1 Interrupção		0,5 – 30 ciclos	< 0,1 pu
2.2.2 Afundamento de tensão		30 ciclos – 3 s	0,1 – 0,9 pu

Tabela 2.1 – Características dos principais distúrbios elétricos segundo IEEE (conclusão).

Classificação	Conteúdo Espectral Típico	Duração Típica	Magnitude Típica
2.2.3 <i>Elevação de tensão</i>		30 ciclos – 3 s	1,1 – 1,4 pu
<b>2.3 Temporária</b>			
2.3.1 Interrupção		> 3 s – 1 min	< 0,1 pu
2.3.2 <i>Afundamento de tensão</i>		> 3 s – 1 min	0,1 – 0,9 pu
2.3.3 <i>Elevação de tensão</i>		> 3 s – 1 min	1,1 – 1,2 pu
<b>3.0 Variação de tensão de longa duração</b>			
3.1 Interrupção sustentada		> 1 min	0,0 pu
3.2 Subtensão		> 1 min	0,8 – 0,9 pu
3.3 Sobretensão		> 1 min	1,1 – 1,2 pu
3.4 Sobrecarga de corrente		> 1 min	
<b>4.0 Desequilíbrio</b>			
4.1 Tensão		regime permanente	0,5 – 2%
4.2 Corrente		regime permanente	1,0 – 30%
<b>5.0 Distorção da forma de onda</b>			
5.1 Nível CC		regime permanente	0 – 0,1%
5.2 Harmônicos	0 – 9 kHz	regime permanente	0 – 20%
5.3 Interharmônico	0 – 9 kHz	regime permanente	0 – 2%
5.4 <i>Notching</i>		regime permanente	
5.5 Ruído	faixa ampla	regime permanente	0 – 1%
<b>6.0 Flutuações de tensão</b>	< 25 Hz	intermitente	0,1 – 7% 0,2 – 2 P <sub>st</sub>
<b>7.0 Variações de frequência no sistema</b>		< 10 s	± 0,10 Hz

Fonte: Adaptado de IEEE Std 1159 (2009).

### 2.3 Variações de tensão de curta duração

Variações de tensão de curta duração são desvios significativos no valor eficaz da tensão em curtos intervalos de tempo (ANEEL, 2014). Essas variações podem ser classificadas entre afundamentos (AT), elevações (ET) e interrupções de tensão. A classificação desses três eventos é feita no Brasil pela ANEEL (ANEEL, 2014) de acordo com a Tabela 2.2.

Internacionalmente, o IEEE Std 1159 (2009) normatiza esses eventos de acordo com a Tabela 2.1. As diferenças entre essas duas normas podem ser observadas nos valores dos

parâmetros e também na subdivisão “Instantâneo” que o IEEE utiliza a mais em comparação à ANEEL.

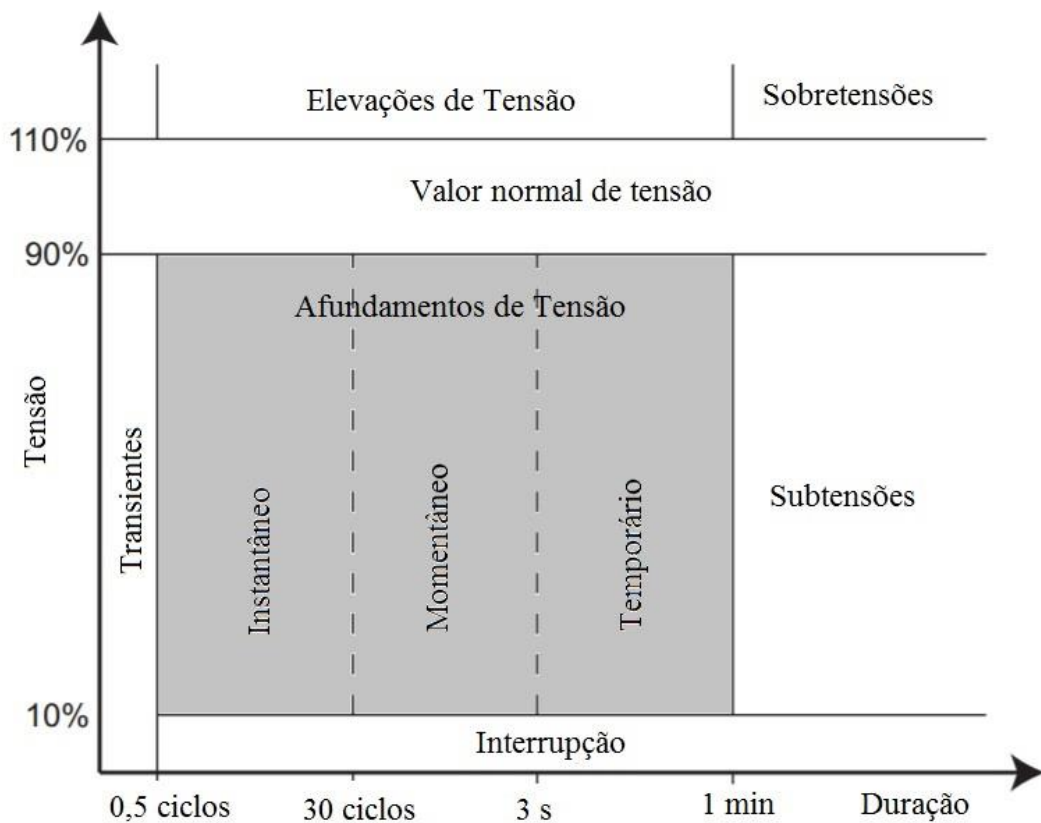
A Figura 2.1 auxilia a diferenciar os eventos de variação de tensão segundo a magnitude da tensão em RMS e a duração do evento, seguindo as normas do IEEE Std 1159 (2009).

Tabela 2.2 – Classificação das Variações de Tensão de Curta Duração segundo ANEEL.

Classificação	Denominação	Duração da variação	Amplitude da tensão (valor eficaz) em relação à tensão de referência
<b>Varição momentânea de tensão</b>	Interrupção	$\leq 3$ s	$< 0,1$ pu
	Afundamento	1 ciclo – 3 s	0,1 – 0,9 pu
	Elevação	1 ciclo – 3 s	$> 1,1$ pu
<b>Varição temporária de tensão</b>	Interrupção	3 s – 3 min	$< 0,1$ pu
	Afundamento	3 s – 3 min	0,1 – 0,9 pu
	Elevação	3 s – 3 min	$> 1,1$ pu

Fonte: Adaptado de ANEEL (2014).

Figura 2.1 – Limiares para variações nas tensões RMS.



Fonte: Adaptado de Bollen e Gu (2006) e IEEE STD 1159 (2009).

### 2.3.1 Diferença de fase associada a afundamentos e elevações de tensão (*phase-angle-jump*)

Até aqui já foram apresentados os dois principais parâmetros que caracterizam afundamentos e elevações de tensão, que são o tempo de duração do evento e a queda ou elevação da magnitude da tensão (tensão residual). No entanto, há uma terceira característica que também está presente nos ATs e ETs, que é a diferença de fase que pode ocorrer no início e final do evento, conhecida na literatura por *phase-angle-jump* ou *phase-jump* (WANG; BOLLEN; XIAO, 2015).

*Phase-jumps* podem ser prejudiciais para alguns equipamentos, como no caso de motores de indução e dos conversores eletrônicos que usam o valor do ângulo de fase como referência (BOLLEN; GU, 2006).

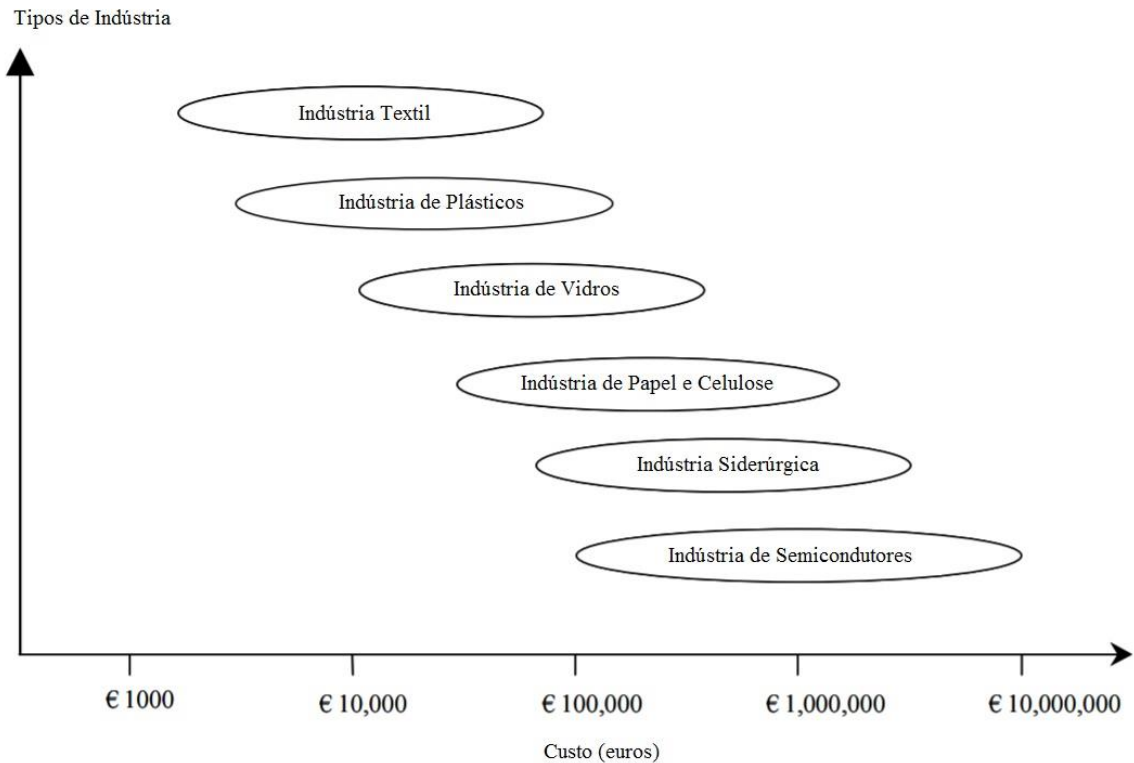
### 2.3.2 Causas e efeitos dos afundamentos de tensão de curta duração

Os afundamentos de tensão de curta duração (*voltage sag*), são causados por aumentos extremos na corrente, sendo três as suas causas principais: AT causado por faltas, AT causado por saturação de transformadores (ST) e AT causado por partida de motores de indução (PMI). Os ATs causados por falta representam a maioria dos casos (SEDIGHNEJAD; JALILIAN, 2010).

As consequências dos AT são, geralmente, mal funcionamento de equipamentos eletrônicos e aparelhos sensíveis, como por exemplo computadores e dispositivos controlados eletronicamente. Algumas vezes, os afundamentos de tensão podem resultar em problemas a longo prazo, tais como deterioração, perda de dados e paradas em processos industriais, sendo que processos industriais interrompidos são fontes de grandes prejuízos (SEDIGHNEJAD; JALILIAN, 2010). Outras consequências são: incorreta operação de dispositivos de controle, a variação de velocidade ou até mesmo a parada de motores e abertura de contadores (ARRILLAGA; BOLLEN; WATSON, 2000). Segundo a norma IEEE Std 1159 (2009), AT e interrupções com menos de um segundo de duração representam 85% das causas de mal funcionamentos devido à má QEE, indicando, portanto, que esses distúrbios são os principais inimigos dos processos industriais.

Para se ter uma ideia do prejuízo gerado por afundamentos de tensão, em um estudo realizado por Andersson e Nilsson (2002) são mostrados os custos médios gerados por AT em vários tipos de indústrias (FIGURA 2.2).

Figura 2.2 – Custos relacionados a eventos de afundamento de tensão em diversas indústrias.



Fonte: adaptado de Andersson e Nilsson (2002).

### 2.3.2.1 Afundamentos de tensão causados por falta

Os AT causados por falta são os mais severos e, portanto, os que provocam maiores problemas no sistema elétrico. Eles se propagam no sistema, causando problemas para um grande número de consumidores. Podem ser categorizados em: auto recuperáveis, temporários e permanentes. Os auto recuperáveis são os em que a tensão volta ao normal sem intervenção externa, os temporários são os que ocorrem até que o componente causador da falta seja desligado e religado e as permanentes só são extinguidas após intervenção humana no reparo do defeito. A maioria dos ATs causados são por faltas auto recuperáveis (BROWN, 2008).

A magnitude do AT causado por falta em determinado ponto do sistema depende principalmente da impedância da falta, do tipo de falta, da distância até o ponto de falta e da configuração do sistema. A sua duração dependerá do tipo de proteção utilizada, podendo durar menos de meio ciclo até alguns segundos (STYVAKTAKIS; BOLLEN, 2003). Esse tipo de evento é conhecido por “AT retangular” devido ao formato da tensão RMS (GU et al, 2004).

As faltas podem ser classificadas entre simétricas (trifásico equilibrado e trifásico equilibrado envolvendo o terra) e não-simétricas (fase-terra, bifásico e bifásico envolvendo o terra). Nas faltas simétricas a magnitude da tensão é igual para as 3 fases, ao contrário do que ocorre nas faltas assimétricas (STYVAKTAKIS; BOLLEN, 2003).

Outra característica das faltas é a variabilidade da amplitude do sinal de tensão durante o AT. Em ATs de apenas um estágio, a amplitude permanece constante até que a tensão volte ao normal. Em ATs de múltiplos estágios, a amplitude do sinal varia durante a ocorrência do evento. Para esse tipo de AT, a mudança em amplitude pode ser causada por mudanças no sistema ou mudanças no tipo da falta. Se durante o evento houver a mudança tanto do tipo de AT quanto na sua magnitude, então a causa é uma mudança no tipo de falta. Se a magnitude da tensão muda, mas o tipo de falta não, então a alteração é causada por mudanças no sistema, que tenta acionar os sistemas de proteção para eliminar a falta (STYVAKTAKIS; BOLLEN; GU, 2002; STYVAKTAKIS; BOLLEN, 2003).

Alguns outros fatores que podem ser analisados em AT causados por faltas são:

- Localização da falta: faltas originadas nos sistemas de distribuição causam AT que podem se propagar na rede. Faltas em sistemas de distribuição radial são mais frequentes mas possuem efeito local.
- Ângulo de incidência da falta: o ângulo de fase em que a falta começa pode afetar a capacidade de alguns equipamentos em tolerar o AT, afetando o comportamento transitório da falta.
- Tempo de recuperação da falta: tempo de atuação do sistema de proteção para conter a corrente de curto-circuito e extinguir a falta.
- Modificações no sistema elétrico: a impedância entre o ponto de observação e o ponto de falta afeta a tensão residual durante a falta. Essa impedância não é fixa devido a mudanças contínuas no sistema (FARIED; ABORESHAID, 2002).

Existem quatro tipos de faltas que podem ocorrer no sistema elétrico. Esses tipos de falta e suas probabilidades de ocorrência são (LIM; DORR, 2000):


- Faltas monofásicas (70%);
- Faltas bifásicas (15%);
- Faltas bifásicas envolvendo o terra (10%);
- Faltas trifásicas (5%).

De acordo com o tipo de falta e com o tipo de conexão da carga (estrela ou triângulo), quatro tipos diferentes de ATs podem ocorrer (BOLLEN, 1997):

- Tipo A: há uma queda de tensão igual nas três fases;
- Tipo B: há queda tensão somente em uma das fases;
- Tipo C: há igual queda de tensão em duas fases;
- Tipo D: há uma maior queda de tensão em uma das fases e uma menor queda de tensão nas outras duas fases.

Esses quatro tipos de afundamentos de tensão são ilustrados com fasores na Figura 2.3. A relação entre o tipo de falta, tipo de AT e o tipo de conexão da carga é apresentada na Tabela 2.3. Quando há a presença de transformadores na rede, no secundário do transformador o tipo de AT pode ser alterado.

Figura 2.3 – Quatro tipos de AT representados em fasores.



Fonte: adaptado de Bollen (1997).

Tabela 2.3 – Tipo de AT resultante de diferentes tipos de falta e tipos de conexão da carga.

Tipo de Falta	Conexão da carga	
	Estrela	Triângulo
Trifásica	A	A
Bifásica	C	D
Monofásica	B	C

Fonte: adaptado de Bollen (1997).

### 2.3.2.2 Afundamentos de tensão causados por saturação de transformadores

A saturação de transformadores pode ocorrer durante a energização ou mudanças na tensão nos terminais do transformador. Essa saturação causa ATs com rápida queda na tensão RMS, seguida por uma recuperação gradual e aumento na distorção harmônica (GU et al, 2004). Outras características desse tipo de AT são: desbalanceamento nas três fases, AT de baixa intensidade e não há mudanças no ângulo de fase (MANJULA; MISHRA; SARMA, 2013).

Uma sucinta explicação da causa desse tipo de AT é a seguinte: durante a energização de um transformador ou mudança de tensão em seus terminais, um transiente ocorre para mudar o fluxo no núcleo para uma nova condição estacionária. Geralmente, isso levará a um fluxo acima do valor de saturação para cada ciclo até que o valor médio do fluxo sobre um ciclo decaia para quase zero. Esse excesso de fluxo no núcleo do transformador causa altos valores de corrente de magnetismo, os quais são altamente assimétricas e decaem exponencialmente. Esse fenômeno é conhecido como corrente de partida de magnetização (corrente de *inrush*) e sua magnitude depende do ponto da onda em que ocorre o chaveamento e a corrente residual no núcleo. Dessa forma, o AT causado por correntes de *inrush* tem duração mais longa e pode levar outros transformadores à saturação (STYVAKTAKIS; BOLLEN, 2003).

### 2.3.2.3 Afundamentos de tensão causados por partida de motores de indução

Durante a partida de motores de indução é solicitada uma alta corrente (de 6 a 10 vezes maior que o valor nominal), a qual causa ATs de menor intensidade. Como a corrente solicitada nas três fases é a mesma, então o AT gerado é simétrico. A magnitude do AT irá depender das características do motor de indução, da impedância de curto circuito no ponto em que o motor é conectado e da maneira como é feita sua partida (STYVAKTAKIS; BOLLEN, 2003; FOROUGH; MOHAMMADI; ESMAEILI, 2014).

As características dos ATs causados por partida de motores de indução são: AT simétrico, baixa intensidade, recuperação da tensão gradual, sem alterações na fase e sem a presença de harmônicos (MANJULA; MISHRA; SARMA, 2013).

## 2.4 Sistemas com geração distribuída

O conceito de geração distribuída é relativamente recente, mas a ideia por trás não é tão nova assim. Antigamente, quando a energia elétrica começou a ser gerada e distribuída, as primeiras usinas elétricas eram pequenas e abasteciam somente consumidores próximos da fonte de geração, o que é a ideia básica de geração distribuída (*Distributed Generation – DG*). Naquela época o sistema elétrico era baseado em corrente contínua (DC), o que limitava a distância de distribuição de energia. Com o advento dos sistemas de corrente alternada (AC), os sistemas elétricos passaram a ter grandes redes de transmissão e distribuição com imensas usinas de geração de energia, concentrando a geração em praticamente uma única fonte para determinada região (PEPERMANS et al, 2005).

O termo geração distribuída (GD), pode ser definido como geração de energia local a partir de diferentes tipos de fontes de energia (ACKERMANN; ANDERSSON; SÖDER, 2001; PEPERMANS et al, 2005). Com a característica de possuir fontes geradoras bem menores, a energia gerada por essas fontes fica em torno de 1 kW a 1 MW (BAYOD-RÚJULA, 2009).

Nas últimas décadas, os problemas ambientais e de mudança climática, o crescimento da demanda de energia elétrica mais confiável, as dificuldades na construção de novas linhas de transmissão e o desenvolvimento de novas tecnologias para geração distribuída contribuíram para o crescente interesse nesse conceito de geração descentralizada (PEPERMANS et al, 2005). Outras razões para a difusão de soluções de geração distribuída são: opção para promover eficiência energética e uso de energias renováveis, construção de usinas de geração de energia elétrica de menor porte e com retorno financeiro mais rápido e inclusão do próprio consumidor no mercado de energia elétrica (ACKERMANN; ANDERSSON; SÖDER, 2001).

Algumas das tecnologias de geração de energia que estão presentes na GD são (BAYOD-RÚJULA, 2009):

- Motores a combustão
- Turbinas a gás
- Microturbinas
- Célula de combustível
- Sistemas fotovoltaicos
- Usinas térmicas
- Usinas de energia eólica

- Termoelétricas a base de biomassa
- Pequenas centrais hidrelétricas (PCH)

Dentre as principais vantagens de se utilizar sistemas com geração distribuída estão: redução do consumo de combustíveis fósseis e emissão de gases poluentes; aumento da eficiência, flexibilidade, confiabilidade e capacidade do sistema elétrico (menor quantidade de interrupções de energia); solução para casos de congestionamento nas linhas de transmissão; redução das perdas na transmissão de energia elétrica e geração de oportunidade de novos mercados de energia elétrica (CHICCO; MANCARELLA, 2009; BAYOD-RÚJULA, 2009).

Apesar dos diversos benefícios que as redes GD podem trazer, alguns problemas técnicos também podem surgir, tais como: inversão no fluxo de potência (afetando a qualidade e estabilidade da rede e requerendo maior controle na operação e proteção do sistema), dificuldades no controle da tensão, gerenciamento da potência reativa e aumento da presença de distúrbios elétricos na rede (BAYOD-RÚJULA, 2009).

O sistema elétrico não foi tradicionalmente projetado para receber fontes de geração interna e nem mais de um caminho de fluxo de potência, principalmente a nível de distribuição. Ao se introduzir novas fontes geradoras de energia no sistema, requer-se uma maior atenção técnica à sua compatibilidade com o sistema, uma vez que este foi projetado e possui métodos de controle de QEE baseados na configuração de apenas uma fonte geradora de energia centralizada (CHICCO; MANCARELLA, 2009; MORENO-MUNOZ, 2010). Tendo em vista a tendência mundial em inserir novas fontes de energia na rede elétrica, é necessário que sejam realizadas novas investigações referentes ao comportamento dos distúrbios elétricos e dos sistemas de monitoramento de QEE nas redes com GD.

Em relação aos ATs, a influência da GD vai depender de diversos fatores, tais como o tipo de conexão da fonte GD na rede (direta ou por conversores), da capacidade de geração e da proximidade do AT à fonte de GD. A nível de distribuição, a GD pode atenuar a queda de tensão, porém, se empregadas muitas fontes GD, o efeito pode ser oposto. Se a fonte GD possuir como interface máquina de indução ou síncrona, pode haver uma contribuição adicional às correntes de falta. A nível de transmissão, como menos estações geradoras de grande capacidade são empregadas em redes com GD, o número de AT pode aumentar (BOLLEN; YANG; HASSAN, 2008; BARKER; DE MELLO, 2000). Para casos em que os ATs são atenuados, o uso de uma rede com GD para gerar os sinais simulados deste trabalho pode ser um fator agravante ou facilitador na detecção, dependendo da resposta do método. No entanto, não é objetivo deste trabalho analisar as consequências da GD no método de

detecção e classificação dos ATs. A opção pelo uso deste tipo de topologia é justificada apenas pela presença cada vez maior da GD no SEP, desenvolvendo, assim, um estudo mais condizente com a realidade.

## **2.5 Processamento de Sinais e Inteligência Computacional aplicados na Qualidade de Energia Elétrica**

Técnicas de processamento de sinais e inteligência computacional têm sido bastante utilizadas nas pesquisas envolvendo a caracterização, análise e avaliação da qualidade da energia no SEP, assim como em relação às cargas presentes no sistema (RIBEIRO; PEREIRA, 2007).

Em relação ao processamento de sinais, merecem destaque as técnicas de decomposição da forma de onda no domínio da frequência, tal como a transformada rápida de Fourier (DFT). Outras técnicas bastante utilizadas são a transformada de Fourier de curto tempo (*Short-time Fourier Transform* – STFT), a transformada Wavelet e Filtros de Kalman (GU; STYVAKTAKIS, 2003). Neste trabalho são utilizadas as técnicas de processamento de sinais denominadas Análise de Componentes Independentes (ICA) (HYVÄRINEN, KARHUNEN, OJA, 2004) e Estatísticas de Ordem Superior (EOS) (MENDEL, 1991), que são descritas na próxima seção e no Apêndice D.

A inteligência computacional pode ser definida como mecanismos capazes de se comportar de forma “*inteligente*” em ambientes complexos, incertos e variáveis. Esses mecanismos são geralmente bioinspirados e capazes de aprender e se adaptar a novas situações, de fazer generalizações, abstrações e associações. As três principais técnicas da inteligência computacional são as Redes Neurais Artificiais, a Computação Evolucionária e os Sistemas Fuzzy. A partir dessas técnicas e de suas combinações, diversas outras técnicas de aprendizado de máquina podem ser implementadas, como por exemplo sistemas Neuro-Fuzzy e Sistemas Neuro-Genéticos (VENAYAGAMOORTHY, 2009).

A aplicação de processamento de sinais e da inteligência computacional na QEE é bastante vasta. Alguns exemplos são: detecção, segmentação, classificação e identificação de distúrbios elétricos; compressão de dados; estimação e análise de harmônicos; identificação de faltas; localização da fonte do distúrbio; estimação de parâmetros; representação ou decomposição do sinal; alocação ótima de bancos de capacitores; alocação ótima de geração distribuída; dentre diversas outras possíveis aplicações (IBRAHIM; MORCOS, 2002; RIBEIRO; PEREIRA, 2007).

Neste trabalho são utilizadas as técnicas Redes Neurais Artificiais, Máquina de Vetor de Suporte (SVM), discriminante linear de Fisher e o algoritmo de otimização *Teaching-Learning-Based-Optimization* (TLBO). As descrições dessas técnicas são feitas nos Apêndices.

## 2.6 Detecção e segmentação de afundamentos de tensão

A detecção e segmentação de um distúrbio elétrico é o primeiro passo para a análise e classificação desse distúrbio. A detecção permite identificar a existência do distúrbio na rede. Já a segmentação permite identificar os instantes em que o distúrbio ocorreu, possibilitando a divisão do sinal elétricos em trechos com e sem a presença do distúrbio.

A detecção e segmentação dos afundamentos de tensão neste trabalho serão realizadas através da técnica de processamento de sinais Análise de Componentes Independentes.

### 2.6.1 Análise de Componentes Independentes (ICA)

O estágio de detecção e segmentação de AT deste trabalho baseia-se na técnica estatística conhecida como Análise de Componentes Independentes (*ICA – Independent Component Analysis*). A ICA é uma técnica para separar fontes ou componentes ocultos em dados de estatística multivariada. A principal diferença da ICA em relação aos outros métodos da estatística multivariada é que ela procura por componentes que são tanto estatisticamente independentes quanto não-gaussianos (HYVÄRINEN, KARHUNEN, OJA, 2004).

A ICA faz parte dos métodos de separação cega de fontes (BSS – *Blind Source Separation*). Este é um método cego porque se sabe muito pouco ou nada sobre a matriz de misturas, e também, porque são feitas poucas considerações sobre as fontes independentes (FERREIRA, 2010).

Para exemplificar a ICA e melhor compreender termos como matriz de misturas e BSS, tem-se o seguinte exemplo. Considere o caso de várias pessoas dentro de uma sala com vários gravadores de áudio. O modelo de mistura consiste dos  $N$  áudios gravados (dados observados),  $x_1, x_2 \dots x_n$ . O áudio de cada pessoa corresponde aos sinais originais  $s_1, s_2 \dots s_n$  (componentes independentes). O modelo de misturas pode então ser denotado como a combinação linear das  $N$  variáveis aleatórias  $s_1, s_2 \dots s_n$  estatisticamente independentes entre si (HYVÄRINEN, KARHUNEN, OJA, 2004; FERREIRA, 2010):

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{iN}s_N, \quad i = 1, 2 \dots N. \quad (2.1)$$

Neste modelo, os pesos  $a_{ij}$  são representados fisicamente como as distâncias dos gravadores até cada pessoa. Neste exemplo verifica-se a característica BSS da ICA, pois se conhecem apenas o modelo de misturas  $x_i$ . Esse modelo também pode ser expresso na forma matricial:

$$\mathbf{x}[n] = \mathbf{A} \cdot \mathbf{s}[n], \quad (2.2)$$

em que  $\mathbf{A}$  é a matriz de misturas composta pelos coeficientes  $a_{ij}$ .

O objetivo da ICA é, basicamente, encontrar os componentes independentes  $s_i$ . Uma estimativa desses componentes  $\mathbf{y}_i$  pode ser feita encontrando-se uma matriz de separação  $\mathbf{W}$ , que nada mais é do que a inversa da matriz de misturas  $\mathbf{A}$  ( $\mathbf{W} = \mathbf{A}^{-1}$ ), de forma que:

$$\mathbf{y}[n] = \mathbf{W} \cdot \mathbf{x}[n] \quad (2.3)$$

em que  $\mathbf{y} = [y_1(n), y_2(n), \dots, y_N(n)]^T$ . Essas estimativas possuem as ambiguidades de não se poder determinar a ordem, variância e polaridade das fontes originais. No entanto, isso não se torna uma grande desvantagem, pois na maioria das aplicações essas ambiguidades não são um problema (FERREIRA, 2010).

Para que se possa utilizar a ICA, as seguintes condições devem ser supridas (HYVÄRINEN; KARHUNEN; OJA, 2004):

- as componentes independentes devem ser estatisticamente independentes entre si;
- a matriz de misturas deve ser quadrada (o número de misturas observadas deve ser igual ao número de componentes independentes);
- as componentes independentes devem apresentar distribuição não-gaussiana, com a exceção de no máximo uma componente ter distribuição gaussiana.

Existem vários algoritmos na literatura disponíveis para aplicar a técnica ICA. *Fast Independent Component analysis* - FastICA (OJA; YUAN, 2006), *Joint Approximate Diagonalisation of Eigen-matrices* - JADE (CARDOSO; SOULOUMIAC, 1993), *Second Order Blind Identification* - SOBI (BELOUHRANI et al, 1997) e *Algorithm for Multiple Unknown Signals Extraction* - Amuse (TONG et al, 1991) são alguns deles. Neste trabalho,

optou-se pelo uso do SOBI uma vez que ele explora informação temporal do sinal e é robusto a ruídos gaussianos.

A aplicação da técnica ICA abrange as mais diversas áreas, tais como biomedicina, economia e processamento de imagens (HYVÄRINEN, KARHUNEN, OJA, 2004). Nos trabalhos de Ferreira et al (2009b) e Ferreira et al (2014), a ICA foi utilizada para análise de eletroencefalogramas. Em outros trabalhos de Ferreira et al (2015; 2016) e Ferreira, Seixas e Cerqueira (2015; 2009) a ICA foi utilizada como base para a separação de harmônicos e transitórios em um sinal de tensão e também para classificar distúrbios de qualidade de energia elétrica em sistemas elétricos de potência (SEP). No trabalho de Lizieri, Satchell e Zhang, (2007) a ICA foi utilizada para analisar parâmetros de risco em dados de investimentos.

### 2.6.2 Single Channel Independent Component Analysis (SCICA)

Neste trabalho, a técnica ICA foi utilizada para o caso em que o número de misturas é menor do que o número de fontes, pois se tem apenas uma mistura referente a medição feita no SEP. De acordo com HYVÄRINEN e INKI (2002), este caso é conhecido como subdeterminado (*overcomplete ou underdetermined*). A ICA com apenas uma mistura (canal) é conhecida como *single channel ICA* (SCICA) (DAVIES; JAMES, 2007).

Para que o SCICA seja utilizado na forma padrão da ICA, tal como em (2.2) e (2.3), deve-se gerar uma matriz de dados multicanais, que pode ser gerada através de vetores com atrasos temporais a partir de um sinal discreto  $x[n]$  monitorado, que foi obtido do sinal contínuo  $x(t)$  (FERREIRA et al, 2015), tal que:

$$\mathbf{X}[n] = \begin{bmatrix} x[n] \\ x[n-1] \\ \vdots \\ x[n-M+1] \end{bmatrix} \quad (2.4)$$


em que  $M$  representa o número de versões deslocadas do sinal monitorado.

O modelo SCICA pode ser representado pela Figura 2.4. Segundo James e Wang (2006), o modelo SCICA pode ser representado, matematicamente, pela seguinte equação:

$$\mathbf{x}[n] = \sum_{i=1}^M (s_i[n] * a_i[n]) \quad (2.5)$$

onde \* denota convolução.

Figura 2.4 – Representação do modelo SCICA.



De fato, o SCICA pode ser traduzido por uma soma de séries convolutivas, em que os  $M$  vetores  $a_i[n]$  são convoluídos com as respostas ao impulso dos  $M$  filtros ( $s_i[n]$ ). Neste caso, assume-se que as respostas ao impulso são estatisticamente independentes umas das outras.

De acordo com Davies e James (2007), as linhas da matriz de separação  $\mathbf{W}$  gerada utilizando-se algoritmos de ICA na abordagem SCICA, nada mais são do que filtros. Portanto, as estimativas das componentes independentes são versões filtradas da mistura  $\mathbf{x}[n]$  pelas linhas da matriz  $\mathbf{W}$ , cujos valores são coeficientes de um filtro FIR (*Finite-Impulse-Response*). A ordem desse filtro é dada pelo número de versões deslocadas do sinal monitorado menos um ( $M - 1$ ). Esse processo pode ser demonstrado a seguir (FERREIRA et al, 2015). Suponha a matriz de separação quadrada:

$$\mathbf{W} = \begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{pmatrix}, \quad (2.6)$$

então

$$\begin{pmatrix} y_1[n] \\ y_2[n] \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{pmatrix} \begin{pmatrix} x[n] \\ x[n-1] \end{pmatrix}. \quad (2.7)$$

Reescrevendo (2.7) no domínio da transformada Z, tem-se:

$$Y_1[z] = w_{11}X[z] + w_{12}X[z]z^{-1} \quad (2.8)$$

e

$$Y_2[z] = w_{21}X[z] + w_{22}X[z]z^{-1} \quad (2.9)$$

Assim, os componentes estimados,  $\{y_1[n]\}$  e  $\{y_2[n]\}$ , são versões filtradas do sinal  $x[n]$ , pelos filtros FIR

$$H_1[z] = w_{11} + w_{12}z^{-1} \quad (2.10)$$

e

$$H_2[z] = w_{21} + w_{22}z^{-1}. \quad (2.11)$$

## 2.7 Extração e seleção de características

Em trabalhos de reconhecimentos de padrões, uma importante etapa é a extração de características do sinal analisado. Os parâmetros extraídos são muito úteis para a tarefa de classificação, pois eles representam informações importantes e restritas sobre cada classe, aumentando as fronteiras de separação e facilitando a classificação. Além disso, é possível reduzir a complexidade computacional do problema com a redução do número de parâmetros que servirão de entrada para o classificador através da seleção de características (FERREIRA, 2010).

Neste trabalho, as Estatísticas de Ordem Superior (EOS) são utilizadas como extratoras de características dos sinais de tensão analisado. A etapa de seleção das características também é muito importante, pois permite projetar classificadores mais simples e de melhor desempenho, sendo que neste trabalho essa etapa é realizada através do discriminante linear de Fisher e do algoritmo TLBO.

O uso das EOS como extratora de características foi motivado principalmente por suas propriedades como ferramenta de processamento de sinais, tais como: manipulação eficaz de ruído colorido Gaussiano, extração de características devido a desvios em relação à Gaussianidade e detecção e caracterização de propriedades não lineares dos sinais (GUEDES; FERREIRA; BARBOSA, 2016). A principal motivação do uso das EOS é sua robustez ao ruído Gaussiano. Nos trabalhos de Barbosa e Ferreira (2013), Ferreira et al (2009a) e Ferreira,

Seixas e Cerqueira (2015), EOS foi aplicada com sucesso em problemas envolvendo reconhecimento de eventos de qualidade de energia elétrica.

## 2.8 Trabalhos já realizados na área

Vários trabalhos já foram desenvolvidos na área de detecção/segmentação e classificação de afundamentos de tensão segundo suas causas. Alguns deles realizam somente a tarefa de detecção/segmentação de sinais contendo AT, ET e interrupções, já outros executam também a classificação desses distúrbios.

No trabalho de Sadigh e Smedley (2016) os autores propuseram um método de detecção de ATs para aplicações em restauradores dinâmicos de tensão. O método se baseia no cálculo da amplitude da fundamental utilizando os componentes  $d$  e  $q$  de cada fase da tensão em janelas de meio ciclo. O método se mostrou eficiente para diferentes níveis de afundamento, *phase-jump*, harmônicos e variação na frequência fundamental. O menor erro de detecção foi de 1 ms e o maior de 8,8 ms.

No trabalho de Latran e Teke (2015) foi desenvolvido um algoritmo que utiliza a transformada Wavelet para detectar AT na presença de *flicker* e harmônicos. O método mostrou-se mais robusto, mais preciso e mais rápido do que outros três métodos utilizados pelo autor para comparação, baseados em transformada DQ (*direct quadrature*), FFT (*Fast Fourier Transform*) e EPLL (*Enhanced Phase Locked Loop*). No entanto, os autores não testaram o método em dados reais e não mencionaram a presença de ruído nos dados simulados.

A transformada DQ (*direct quadrature*) foi utilizada no trabalho de Teke, Bayindir e Tumay (2010) para detectar AT e ET. Além da detecção, os autores propuseram um restaurador dinâmico de tensão (DVR) baseado em lógica Fuzzy. A vantagem desse método é a rápida e precisa resposta do detector de afundamentos e elevações de tensão, permitindo uma rápida resposta do DVR e uma compensação de tensão adequada. No entanto, o detector de AT e ET não foi testado sob a presença de outros distúrbios, tais como harmônicos e *flicker*.

No trabalho de Moreno et al (2016), os autores utilizaram um método de segmentação causal e anti-causal de afundamentos de tensão. O método é baseado num algoritmo de soma cumulativa, sendo capaz de alcançar resultados de segmentação bastante precisos. No entanto, devido à abordagem anti-causal, essa técnica só é válida em casos de processamento em “batelada”.

No trabalho de Gu et al. (2004) foi apresentado um detector e classificador de ATs causados por faltas em meio a eventos de saturação de transformadores e chaveamento de capacitores. O detector foi baseado no valor RMS de meio ciclo do sinal de tensão, já o classificador utiliza o critério estatístico de Neyman-Pearson, classificando ATs causados por falta, saturação de transformadores e chaveamento de capacitores com a menor janela do sinal de tensão possível. O método foi eficaz utilizando somente meio ciclo da componente fundamental, podendo ser empregado para melhorar os sistemas de proteção, evitando falsos alarmes.

No trabalho de Manjula, Mishra e Sarma (2013), foi desenvolvido um método de detecção e classificação das causas de ATs utilizando a transformada Hilbert e Redes Neurais Probabilísticas. Os autores utilizam primeiro a Decomposição de Modo Empírico (EMD) para decompor o sinal não estacionário em sinais simétricos chamados Funções de Modo Intrínseco (IMFs). Então é aplicada a transformada Hilbert para realizar a extração de características. Por fim, uma rede neural probabilística (PNN) é usada para realizar a classificação de ATs causados por faltas (curtos-circuitos), partida de motores de indução ou energização de transformadores. O método é comparado com um sistema baseado em Transformada Wavelet e Rede Neural Multicamadas (MLNN), sendo o desempenho do método proposto superior.

No trabalho de Styvaktakis, Bollen e Gu (2002), foi desenvolvido um método de classificação de eventos com significantes variações de tensão baseado em um sistema especialista. Os eventos classificados foram: energização, interrupções causadas ou não por faltas, saturação de transformadores seguidas ou não por proteção, partida de motor de indução, degraus na tensão e ATs causados por faltas. Foram analisados sinais reais, sendo o método dividido nos seguintes passos: detecção e segmentação dos eventos utilizando filtros de Kalman, classificação dos eventos com o sistema especialista e um módulo de análises adicionais para extrair informações tais como o tipo e duração do AT e as causas de sobretensões que podem estar presentes. O método conseguiu classificar a maior parte dos eventos, sendo seus únicos problemas relacionados a falhas na detecção de pequenas variações de tensão e na resolução temporal para estimação da amplitude e detecção.

Outra técnica também utilizada para classificar ATs é os sistemas Fuzzy. No trabalho de Kezunovic e Liao (2001), a lógica Fuzzy foi utilizada como classificador de ATs causados por faltas, partida de motores de indução e re-aceleração de motores. O método não realiza a detecção dos eventos, o que deve ser feito por outra técnica. Após a classificação, o método

realiza a caracterização dos eventos segundo vários parâmetros para posterior análise de sensibilidade de equipamentos ao distúrbio AT.

No trabalho de Foroughi, Mohammadi e Esmaili (2014), foi utilizado a decomposição de modo empírico (EMD) para decompor o sinal de tensão e extrair as três primeiras funções de modo intrínseco (IMFs). A transformada Hilbert foi então utilizada para extrair as características do sinal. Para classificar o AT entre suas causas: faltas, partida de motores de indução, energização de transformadores e re-aceleração de motores após eliminação da falta, foi utilizada a técnica SVM (*Support Vector Machine*). O método foi comparado com transformada Wavelet combinada com uma rede neural probabilística (PNN) e também com EMD combinada com PNN, mostrando-se superior a estes outros métodos.

Após realizada uma pesquisa detalhada sobre os trabalhos desenvolvidos na área de detecção e classificação de ATs de acordo com suas causas, nenhum trabalho envolvendo redes com geração distribuída (GD) foi encontrado. No entanto, é importante ressaltar que a maioria dos trabalhos envolvendo GD são sobre ilhamento e, conforme já discutido na seção 2.4, não é objetivo deste trabalho analisar a influência da GD no método proposto, mas apenas utilizá-la por ser um tipo de rede que vem ganhando maior presença e importância no setor elétrico. Além disso, melhorias no desempenho e redução na complexidade de detecção e classificação de ATs podem ser alcançadas com a abordagem de técnicas ainda não utilizadas, tais como as que são propostas neste trabalho. Tais melhorias podem, inclusive, viabilizar a detecção e classificação online e em tempo real, o que é de extrema importância para sistemas de proteção e ainda necessita de novos estudos. É importante ressaltar que o termo “tempo real” é utilizado neste trabalho quando o método é capaz de responder para cada nova amostra adquirida, ou seja, sem atraso em relação à amostra mais recente adquirida pelo sistema de aquisição. Já o termo “*online*” é utilizado quando o método oferece uma resposta com determinado tempo de atraso em relação à amostra atual adquirida, pois nesse caso é necessário realizar o acúmulo de uma quantidade de amostras para executar o algoritmo. No entanto, o método ainda é executado enquanto a aquisição está sendo realizada e não é necessário reprojeter o método durante sua execução.

### 3 MATERIAL E MÉTODOS

Neste trabalho, é desenvolvido um novo método de detecção, segmentação e classificação de afundamentos de tensão de acordo com suas causas. Para isso, foram utilizadas as seguintes técnicas de inteligência computacional e processamento de sinais: Análise de Componentes Independentes (ICA), Estatísticas de Ordem Superior (EOS), Discriminante Linear de Fisher, *Teaching-Learning Based Optimization* (TLBO), Máquina de Vetor de Suporte (SVM) e Redes Neurais Artificiais (RNA).

O trabalho foi desenvolvido de acordo com as seguintes etapas:

1. Geração de sinais simulados: os distúrbios analisados foram gerados no *software* MATLAB e também através da ferramenta *Simulink* para montar um banco de dados a ser utilizado no treinamento e teste do método. Foi utilizado uma rede de distribuição radial de 15 barramentos com geração distribuída proposta pelo IEEE para gerar os eventos. Os eventos também foram gerados sinteticamente no MATLAB.
2. Desenvolvimento do método de detecção e segmentação de afundamentos de tensão através da técnica ICA.
3. Extração das características dos sinais de tensão através das EOS.
4. Seleção das características através do discriminante linear de Fisher e do algoritmo de otimização TLBO.
5. Classificação dos eventos utilizando Redes Neurais Artificiais (*Multilayer Perceptron* – MLP) e SVM.
6. Teste de desempenho do método para dados simulados e reais, assim como a comparação do método proposto com outros encontrados na literatura.

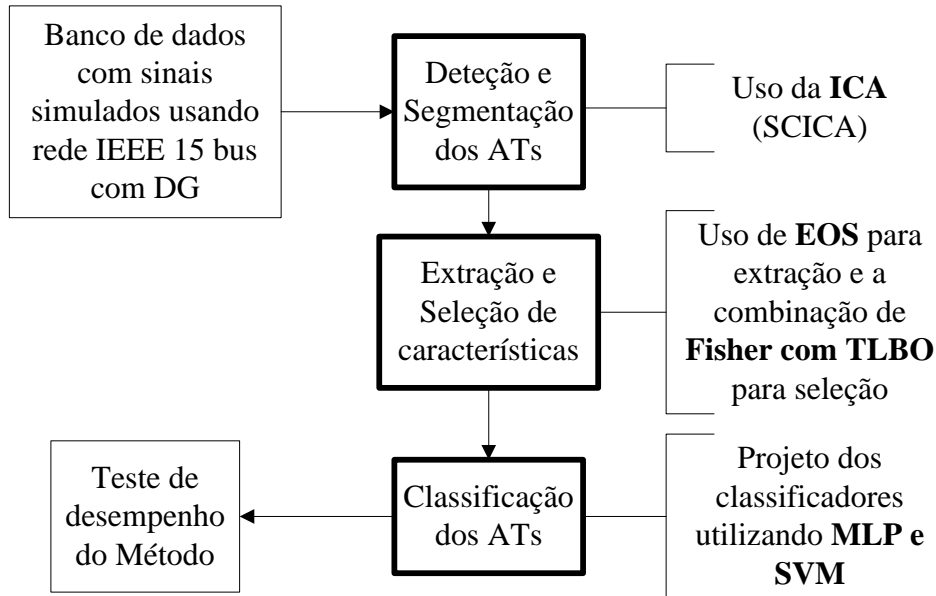
A Figura 3.1 ilustra o resumo de todo o processo do desenvolvimento deste trabalho.

#### 3.1 Geração de bancos de dados simulados e sintéticos

Para gerar os sinais simulados com afundamentos de tensão, foi utilizada uma rede de distribuição radial de 15 barramentos do IEEE simulada no *software* Matlab/Simulink. O diagrama unifilar da rede é mostrado na Figura 3.2. Essa rede possui um alimentador principal (subestação) com tensão de 11 kV e uma fonte GD (fonte de tensão comum) com capacidade de 300 kW. Para gerar os sinais com ATs causados por faltas, foram consideradas faltas

monofásicas, bifásicas (incluindo ou não o terra), trifásicas e faltas direto no alimentador principal, tal como descreve a Tabela 3.1.

Figura 3.1 – Resumo do desenvolvimento do trabalho.




Para cada tipo de falta foi variada a localização da falta em dez diferentes pontos da rede (próximos a diferentes cargas), sendo que o medidor de tensão foi colocado na barra 3. Dos 500 sinais gerados com afundamentos de tensão causados por faltas, 20% são de faltas com múltiplos estágios. A resistência de curto-circuito das faltas foi variada entre 5, 10, 50 e 100 ohms para que se varie a amplitude da queda de tensão. O tempo de início das faltas foi variado aleatoriamente entre 0,1s e 0,3s, sendo que a duração do evento foi limitada entre  $\frac{1}{2}$  ciclo e 0,2s por questões de simplificação da simulação. O nível de carga da rede também foi variado entre 50% 70% e 100% das cargas nominais.

Tabela 3.1 – Tipos de faltas utilizadas para gerar ATs e as respectivas porcentagens de eventos para cada tipo de falta.

Tipo de falta	Porcentagem de eventos gerados
Monofásicas	74%
Bifásicas não incluindo o terra	4%
Bifásicas incluindo o terra	4%
Trifásicas	8%
Direto no alimentador	10%


Para gerar os ATs causados por partida de motores de indução (PMI) e saturação de transformadores (ST), foram considerados cinco localizações diferentes dentro da rede para incluir os motores e transformadores. Tais localizações são representadas pelas chaves abertas na Figura 3.2, de tal forma que para cada sinal simulado, uma chave é fechada aleatoriamente, conectando o respectivo motor ou transformador (representado como uma carga no diagrama) na rede. O tempo de início do AT foi variado entre 0,05s e 0,15s. O nível de carga da rede também foi variado entre 50%, 70% e 100% da carga nominal. A potência dos motores foi variada entre 30 HP e 150 HP, e a potência dos transformadores foram variadas entre 1 MW e 10 MW. Para os casos de falta e PMI o afundamento ocorreu após o sistema atingir regime permanente, enquanto que para ST o transformador parte do repouso, ou seja, foram considerados casos de energização do transformador.

Figura 3.2 – Diagrama unifilar da rede radial de 15 barramentos com GD.



Dessa forma, tem-se 1500 sinais, 500 para cada tipo de afundamento (falta, partida de motor e saturação de transformador) para serem usados tanto no treinamento (1050 sinais, que correspondem a 70% dos sinais gerados) quanto no teste (450 sinais, que correspondem a 30% dos sinais gerados) do método. É importante ressaltar que foi utilizada uma frequência de amostragem de 15,36 kHz para gerar os sinais. A relação sinal-ruído (SNR) foi variada em 40, 50 e 60 dB. A Figura 3.3 ilustra um exemplo dos três tipos de afundamentos de tensão através do valor RMS de cada fase do sinal. Cada cor representa uma fase do sinal.

Figura 3.3 – Exemplos dos três tipos de afundamentos de tensão.



Afundamentos de tensão também foram gerados sinteticamente utilizando o MATLAB para auxiliar nos testes de desempenho do método, uma vez que é possível controlar mais precisamente a profundidade do afundamento, o ponto de onda em que ocorre e a presença de *phase jump* e outros distúrbios (harmônicos, flutuações de tensão e variações da frequência fundamental) que também foram gerados juntos com afundamentos para avaliar o desempenho do método.

Para gerar os sinais sintéticos, considerou-se a versão discreta do sinal de tensão, que pode ser matematicamente representada pela combinação linear da componente fundamental com distúrbios e ruído (RIBEIRO; PEREIRA, 2007):

$$v[n] = v(t)_{t=\frac{n}{F_s}} := A[n]\cos\left[2\pi\frac{f[n]}{F_s}n + \phi[n]\right] + d[n] + r[n], \quad (3.1)$$

em que  $n = 0, \dots, N - 1$  é o índice da amostra,  $F_s$  é a frequência de amostragem,  $A[n]$ ,  $f[n]$  e  $\phi[n]$  são referentes à magnitude, frequência fundamental e fase da componente fundamental, respectivamente.  $d[n]$  representa a componente do distúrbio, que pode ser harmônicos, flutuação de tensão, entre outros;  $r[n]$  representa o ruído com distribuição normal  $\mathcal{N}(0, \sigma_n^2)$  e independente dos outros componentes.

Assim como para os sinais simulados via *Simulink*, foi utilizada uma frequência de amostragem de 256 pontos por ciclo da componente fundamental (15,36 kHz). A relação sinal-ruído (SNR) foi variada entre 40, 50 e 60 dB.

Portanto, no total foram gerados 1500 sinais simulados através do *Simulink* e mais 4500 sinais sintéticos com AT causados por falta para avaliar o desempenho do método. O banco de dados simulados (1500 sinais) é utilizado no projeto e teste de desempenho tanto do detector quanto do classificador de AT. Já o banco de dados sintético é utilizado apenas para

avaliar o desempenho do detector. A quantidade de sinais utilizados para projeto e teste, assim como a quantidade de ciclos, são especificadas com mais detalhes nas próximas seções e na seção de Resultados.

### 3.2 Sistema de detecção de afundamentos de tensão.

Para projetar o detector de afundamentos de tensão, foi utilizado o banco de dados simulados de treinamento com 1050 sinais (70% dos dados simulados no Simulink) com afundamentos de tensão gerados a partir da rede com 15 barras e GD. Foi considerada a presença de ruído com relação sinal-ruído (SNR) de 40, 50 e 60 dB. O detector é baseado na abordagem *Single Channel ICA*, em que a saída do ICA representa o sinal elétrico monitorado filtrado por um filtro FIR. Através da filtragem do sinal de tensão, é possível atenuar a componente fundamental junto com algumas componentes harmônicas e amplificar altas frequências, onde se encontra a parte transitória do AT. O detector é monofásico, mas pode ser aplicado a sinais trifásicos aplicando o algoritmo para cada uma das fases, o que acaba se tornando uma vantagem do método, que pode ser aplicado tanto para sinais monofásicos quanto trifásicos e permite a detecção individual (por fase) para sinais trifásicos.

Para gerar um detector de baixa complexidade computacional, optou-se por projetar uma matriz de separação  $\mathbf{W}$  fixa, conforme modelo ICA visto em (2.3), de tal forma que na fase de operação do método não seja preciso aplicar o algoritmo SOBI para toda iteração. Ao invés disso, o sinal de saída do método é obtido apenas pela multiplicação de uma das linhas de  $\mathbf{W}$  pelo vetor de entrada do método, o que é detalhado na próxima seção.

#### 3.2.1 Fase de projeto

A fase de projeto da detecção e segmentação compreende na escolha da quantidade de deslocamentos  $M$  para construir a matriz de dados multicanais conforme em (2.4) e na seleção da melhor matriz de separação  $\mathbf{W}$  projetada pela ICA, da qual é utilizada uma de suas linhas para executar a detecção em fase de operação. Tais tarefas foram executadas com o algoritmo TLBO, de tal forma a obter uma quantidade ótima de deslocamentos  $M$  assim como uma linha de detecção ótima.

O algoritmo TLBO é baseado em população. Assim, o problema de otimização desenvolvido por ele se resume em buscar pelo melhor indivíduo da população a cada geração de tal forma que a evolução da população durante as gerações faça com que no final da

execução do algoritmo tenha-se o melhor indivíduo alcançado, permitindo otimizar os parâmetros de interesse, uma vez que o indivíduo representa esses parâmetros. No método de detecção e segmentação o indivíduo é representado por quatro variáveis: número  $M$  de deslocamentos (entre 2 e 15), qual sinal de tensão trifásico escolhido dentro do banco de dados simulados, qual fase desse sinal de tensão é utilizada e qual nível de ruído incluído no sinal. Cada variável possui valores entre 1 e 500, de tal forma que seja dividida em partes iguais que representem o parâmetro analisado. Por exemplo, para o número de deslocamentos, se a respectiva variável assumir valores entre 0 e 35 então tem-se  $M = 2$ . No final da execução do TLBO tem-se os parâmetros ótimos alcançados assim como a linha de detecção ótima obtida com a ICA.

O parâmetro utilizado para medir o desempenho de cada indivíduo (função custo) é a taxa de segmentação alcançada com aquele indivíduo na avaliação do banco de dados de teste com a inclusão de ruído com SNR de 40 dB (pior caso para o método de detecção/segmentação) e harmônicos. Dessa forma, durante a execução do TLBO é necessário executar o algoritmo de segmentação em sua fase de operação para obter o valor da função custo.

Portanto, a fase de projeto do método é executada através do TLBO utilizando-se uma população de 15 indivíduos e com 50 gerações. A ICA é utilizada dentro da função custo, uma vez que é nela que se projeta a linha de separação e avalia-se o banco de dados de teste. O fluxograma mostrado na Figura 3.4 resume como cada indivíduo é avaliado, sendo que a fase de projeto pode ser dividida em 6 passos, considerando-se uma fase do sinal de tensão:

**Passo 1:** Inicialização da população e das variáveis do TLBO. As variáveis consideradas foram: número  $M$  de atrasos temporais (entre 2 e 15, definido a partir de testes empíricos), sinal trifásico escolhido dentro do banco de dados de treinamento, qual fase do sinal escolhido será utilizada e intensidade de ruído (SNR = 40, 50 ou 60 dB). Dentre as  $M+1$  linhas da matriz de separação, restringiu-se somente às linhas 3 e 7 (testadas em execuções separadas do algoritmo), pois teste empíricos mostraram que as outras linhas não levam a bons resultados de detecção. É importante lembrar que as linhas de  $\mathbf{W}$  são versões deslocadas de filtros FIR e, portanto, podem levar a resultados parecidos, necessitando da escolha da melhor (ou das melhores) linha que leva a melhores resultados. Os Passos 2 ao 5 são referentes à função de avaliação, em que o algoritmo ICA é executado e a linha de detecção é utilizada para avaliar os dados de teste.

**Passo 2:** Construção da matriz de representação de dados multicanais  $\mathbf{X}[n]$ , tal como em (2.4), com  $M$  deslocamentos do sinal original, que contem 1 ciclo (256 amostras). Foram utilizadas janelas de 1 ciclo somente para a fase de projeto. Na fase de operação utiliza-se janelas de apenas 1/8 de ciclo, uma vez que  $\mathbf{W}$  projetado contém a informação necessária para detectar os eventos.

**Passo 3:** Aplicação do algoritmo de ICA na matriz  $\mathbf{X}[n]$ . Neste trabalho optou-se pelo uso do algoritmo SOBI uma vez que ele explora informação temporal do sinal e é robusto a ruídos gaussianos.

**Passo 4:** O algoritmo SOBI retorna a matriz de separação  $\mathbf{W}$ , da qual é selecionada somente uma de suas  $M+1$  linhas, definida na execução do TLBO. A linha selecionada ( $\mathbf{W}_{(l,:)}$ ) é então utilizada para processar os dados de teste (450 sinais, 30% dos dados gerados via *Simulink*).

**Passo 5:** A detecção dos afundamentos é feita nos dados de teste utilizando a linha  $\mathbf{W}_{(l,:)}$  obtida da matriz  $\mathbf{W}$  no passo anterior. A detecção é feita através da multiplicação da linha  $\mathbf{W}_{(l,:)}$  pela matriz de dados multicanais  $\mathbf{X}[n]$  e, então comparado com um limiar que, se for menor do que a amostra analisada, leva a detecção de um evento. Trata-se da fase de operação do método, detalhada na próxima subseção. O limiar é determinado com base nos dois primeiros ciclos do sinal. Ele deve assumir um valor de tal forma que seja pequeno o suficiente para garantir o máximo de detecções (mais sensível a afundamentos) e ao mesmo tempo que gere um mínimo de falsos alarmes devidos a ruídos no sinal. A partir de testes empíricos determinou-se que, multiplicando 1,8 pelo maior valor da saída do processamento dos dois primeiros ciclos do sinal leva a limiares que atendem esses dois critérios de maneira satisfatória.

**Passo 6:** Obtém-se o erro de detecção, o qual é a função custo do algoritmo TLBO. Caso o erro seja menor do que no passo anterior, então é armazenada a matriz de separação  $\mathbf{W}$ . Se o número de iterações não foi atingido, então o TLBO atualiza os indivíduos da população e volta-se ao passo 2.

### 3.2.2 Fase de operação

Uma vez projetada a linha da matriz de separação que leva a bons resultados de detecção, então o estágio de operação do método se resume nos seguintes passos (veja diagrama em blocos da Figura 3.5):

**Passo 0:** Determinação do limiar de detecção utilizando os dois primeiros ciclos do sinal. Os dois primeiros ciclos são processados de acordo com os Passos 1 e 2 descritos a seguir (construção da matriz de dados multicanais  $\mathbf{X}[n]$  e multiplicação pela linha  $\mathbf{W}_{(l,:)}$ ) e, então o valor máximo do sinal de saída é multiplicado por 1,8 para determinar o limiar:

$$\text{limiar} = 1,8 \cdot \max(\text{saída}) \quad (3.2)$$

**Passo 1:** Construção da matriz de dados multicanais  $\mathbf{X}[n]$ , tal como em (2.4), utilizando um número fixo  $M$  de deslocamentos encontrado na fase de projeto e uma janela com 1/8 de ciclo da componente fundamental. Essa janela é do tipo deslizante, deslocando  $k$  amostras ( $k = 1/16$  ciclos,  $1/32$  ciclos ou  $k = 1$  amostra) para a próxima iteração.

**Passo 2:** Multiplicação da linha  $\mathbf{W}_{(l,:)}$  pela matriz  $\mathbf{X}[n]$ :

$$\text{saída} = \mathbf{W}(l, :) \cdot \mathbf{X}[n] \quad (3.3)$$

**Passo 3:** Comparação do valor máximo do sinal *saída* com o limiar. Caso seja maior que o limiar, então um evento foi detectado e seu respectivo tempo de ocorrência é armazenado. Devido à janela deslizante, uma mesma amostra é analisada mais de uma vez. Para evitar múltiplas detecções para o mesmo evento, há um intervalo mínimo de  $1/2$  ciclo entre as detecções. Esse intervalo também leva em consideração que os AT têm duração mínima de  $1/2$  ciclo.

É importante deixar claro que a determinação do limiar (Passo 0) é realizada somente no momento de inicialização do algoritmo, ficando então o limiar com um valor fixo enquanto o algoritmo estiver em funcionamento, que corresponde à repetição dos Passos 1, 2 e 3 para cada janela do sinal de tensão analisada. O limiar é adaptativo, ou seja, se ajusta conforme as características do sinal elétrico, sendo determinado na fase de operação de acordo com

somente os 2 primeiros ciclos do sinal analisado, não necessitando de treinamento prévio para ser determinado.

Figura 3.4 – Fluxograma da avaliação de cada indivíduo no algoritmo TLBO.

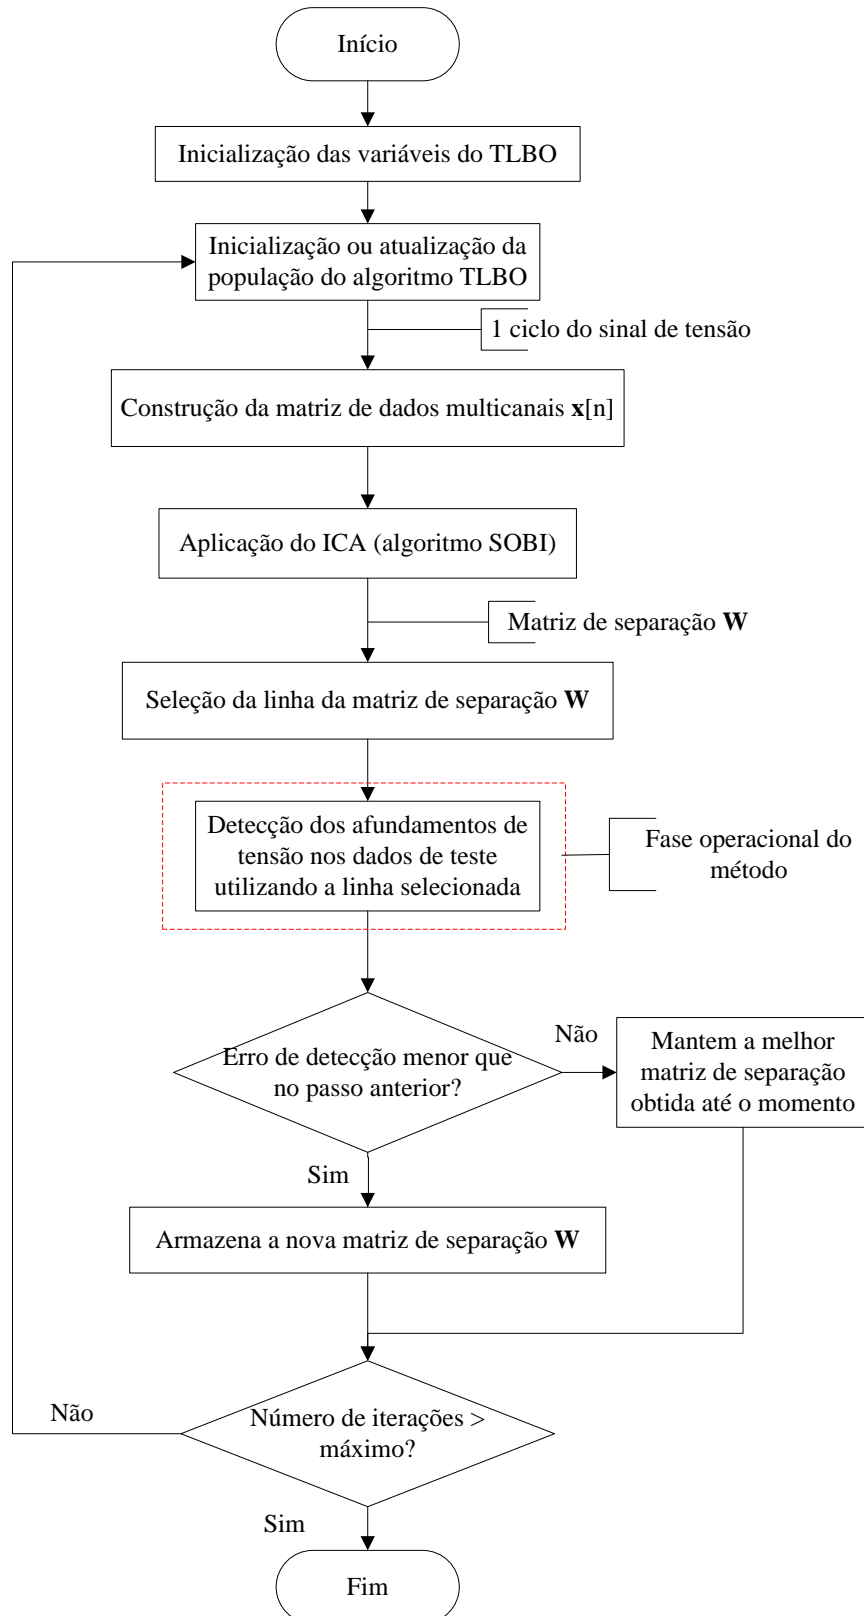
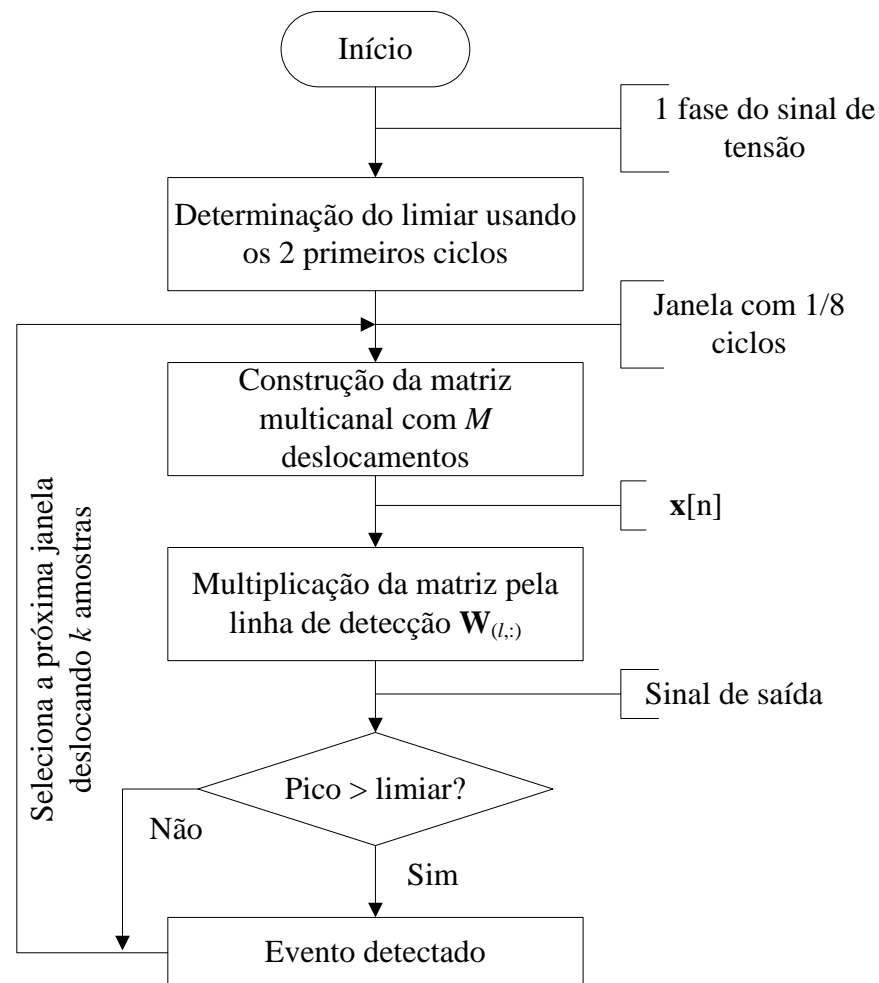


Figura 3.5 – Fluxograma da fase de operação da detecção/segmentação.



### 3.3 Sistema de classificação de afundamentos de tensão

Após realizada a detecção do afundamento de tensão, é muito útil para o monitoramento de qualidade de energia a identificação da causa do evento, principalmente para sistemas de proteção. Essa identificação é abordada neste trabalho como a classificação dos afundamentos de tensão de acordo com suas três causas principais: faltas, partida de motores de indução e saturação de transformadores.

Assim como na detecção, também foi utilizado o banco de dados simulados de treinamento (1050 sinais de tensão trifásico, 350 de cada tipo, gerados via *Simulink*) para projetar os classificadores.

Para realizar a tarefa de classificação, primeiramente é necessário realizar a extração de características do sinal de tensão e selecionar aquelas mais convenientes para o classificador, ou seja, aquelas que melhor discriminam as classes abordadas. Essas duas

etapas foram feitas utilizando EOS para extrair as características e o discriminante linear de Fisher com TLBO para selecioná-las.

### 3.3.1 Extração de características

Os cumulantes de 2<sup>a</sup>, 3<sup>a</sup> e 4<sup>a</sup> ordens foram utilizados como características do sinal de tensão, calculados de acordo com (D4), (D5) e (D6) no Apêndice D. Foram variadas as quantidades de ciclos do sinal utilizadas para cálculo dos cumulantes e classificação dos eventos, variando entre 1, 1/2, 1/4 e 1/8 de ciclo. Como os cumulantes de 2<sup>a</sup> ordem são simétricos, então calcula-se apenas a primeira metade deles. Por exemplo: para 1 ciclo (256 amostras) são calculados 128 cumulantes de 2<sup>a</sup> ordem, 256 de 3<sup>a</sup> e 256 de 4<sup>a</sup>, totalizando 640 características.

Como os sinais de tensão são trifásicos, então calculou-se a média dos cumulantes entre as três fases. Embora haja outras possibilidades de se manipular os cumulantes das três fases, como é o caso de usar todos eles como um único vetor, a abordagem da média se mostrou satisfatória para o problema. Utilizando-os como um vetor único, por exemplo, poderia levar a erros quando a falta atinge somente uma ou duas das fases. Ademais, o método de detecção já indica quais fases sofreram a falta e os cumulantes são necessários apenas para classificar os ATs entre suas três causas principais.

### 3.3.2 Seleção de características

Como a quantidade de características (cumulantes) é elevada para ser usada de entrada para um classificador, é necessário realizar a seleção das melhores características, ou seja, aquelas que levam a melhores resultados de classificação e assim reduzir a dimensão. A partir dessa tarefa é possível projetar classificadores mais eficientes e de menor custo computacional.

Análogo à etapa de detecção, também foi utilizado o algoritmo de otimização TLBO para selecionar as características. Para parametrizar o TLBO, utilizou-se uma população de 40 indivíduos e 50 gerações.

A busca pelos melhores cumulantes foi feita utilizando dois critérios:

- 1) Considerou-se 1 ciclo, 1/2, 1/4 e 1/8 de ciclos do componente fundamental.
- 2) Para cada quantidade de ciclos, variou-se a quantidade de cumulantes entre 2 e 15, de tal forma que se encontre os 2 melhores cumulantes, 3 melhores, ... 15 melhores. Tal

abordagem permite modelar o problema de otimização como sendo multiobjetivo, pois a partir dos resultados é possível escolher o mínimo desempenho necessário para a menor quantidade de entradas (menor complexidade) e menor quantidade de ciclos (resposta mais rápida).

Como a função custo do TLBO é o erro de classificação, então dentro da execução do algoritmo na fase de projeto é necessário projetar o classificador para toda iteração. Foram testados dois classificadores diferentes: Perceptron de Multicamadas (MLP) e Máquina de Vetor de Suporte (SVM).

As MLPs projetadas possuem 1 camada escondida. Para determinar o número de neurônios na camada escondida, utilizou-se a variação mostrada na Tabela 3.2 na fase de projeto. A limitação da quantidade de neurônios testada na fase de projeto foi determinada a fim de não causar *overfitting*, em que os pesos dos neurônios acabam “memorizando” os dados de treinamento e, conseqüentemente, levando a um classificador de pouca capacidade de generalização. Assim, de acordo com Duda, Hart e Stork (2012), uma boa aproximação para o número máximo de pesos da rede é de pelo menos 10 vezes menor que o número de dados de treinamento. Considerando essa regra e que a camada de saída possui três neurônios, foi determinado o número máximo de neurônios na camada escondida conforme a Tabela 3.2.

O algoritmo de treinamento utilizado para a rede foi o *Scaled Conjugate Gradient*, escolhido empiricamente.

Para o projeto dos classificadores SVM foi utilizado o *kernel* polinomial de quarta ordem (escolhido a partir de testes empíricos). Como há mais de duas classes, então foi utilizada a abordagem um-contra-um (SVM *multiclass*).

O processo de seleção de características foi executado através do algoritmo TLBO. Para construção do indivíduo, o número de variáveis representa a quantidade de cumulantes, que foi variado entre 2 e 20 para o SVM e entre 2 e 15 para a MLP. Cada indivíduo é composto pela quantidade de cumulantes calculados para a respectiva janela (1 ciclo: 640 cumulantes, 1/2 ciclo: 320 cumulantes, 1/4 de ciclo: 160, 1/8 de ciclo: 80), de tal forma que no final da execução do algoritmo tenha-se os melhores 2 cumulantes, 3 cumulantes, 4 ...  $n$  cumulantes para cada tamanho de janela. A função custo para o problema de classificação é o erro de classificação obtido com os cumulantes selecionados para cada indivíduo e com o classificador projetado.

O processo de seleção de características pode ser dividido nos 4 passos mostrados a seguir, que são executados para cada tamanho de janela.

Tabela 3.2 – Quantidade de neurônios na camada escondida.

Número de entradas	Número de neurônios na camada escondida
2	Entre 2 e 19
3	Entre 2 e 15
4	Entre 2 e 13
5	Entre 2 e 11
6	Entre 2 e 10
7	Entre 2 e 9
8	Entre 2 e 8
9	Entre 2 e 7
10	Entre 2 e 7
11	Entre 2 e 6
12	Entre 2 e 6
13	Entre 2 e 5
14	Entre 2 e 5
15	Entre 2 e 5

**Passo 1:** Inicialização das variáveis e da população do algoritmo TLBO. A escolha inicial dos  $N$  cumulantes não foi feita de modo aleatório. Os cumulantes iniciais foram escolhidos utilizando o discriminante linear de Fisher, que seleciona as melhores características para o classificador de acordo com a média e variância dos dados. Portanto, foi utilizada uma semente no passo inicial do algoritmo TLBO.

**Passo 2:** Projeto do classificador utilizando os  $N$  cumulantes selecionados de cada indivíduo da população no TLBO e utilizando os dados de treino (70%, 1050 sinais trifásicos). Cada classificador (SVM e MLP) são projetados e testados de forma independente.

**Passo 3:** Classificação dos dados utilizando o classificador projetado e cálculo do erro de classificação.

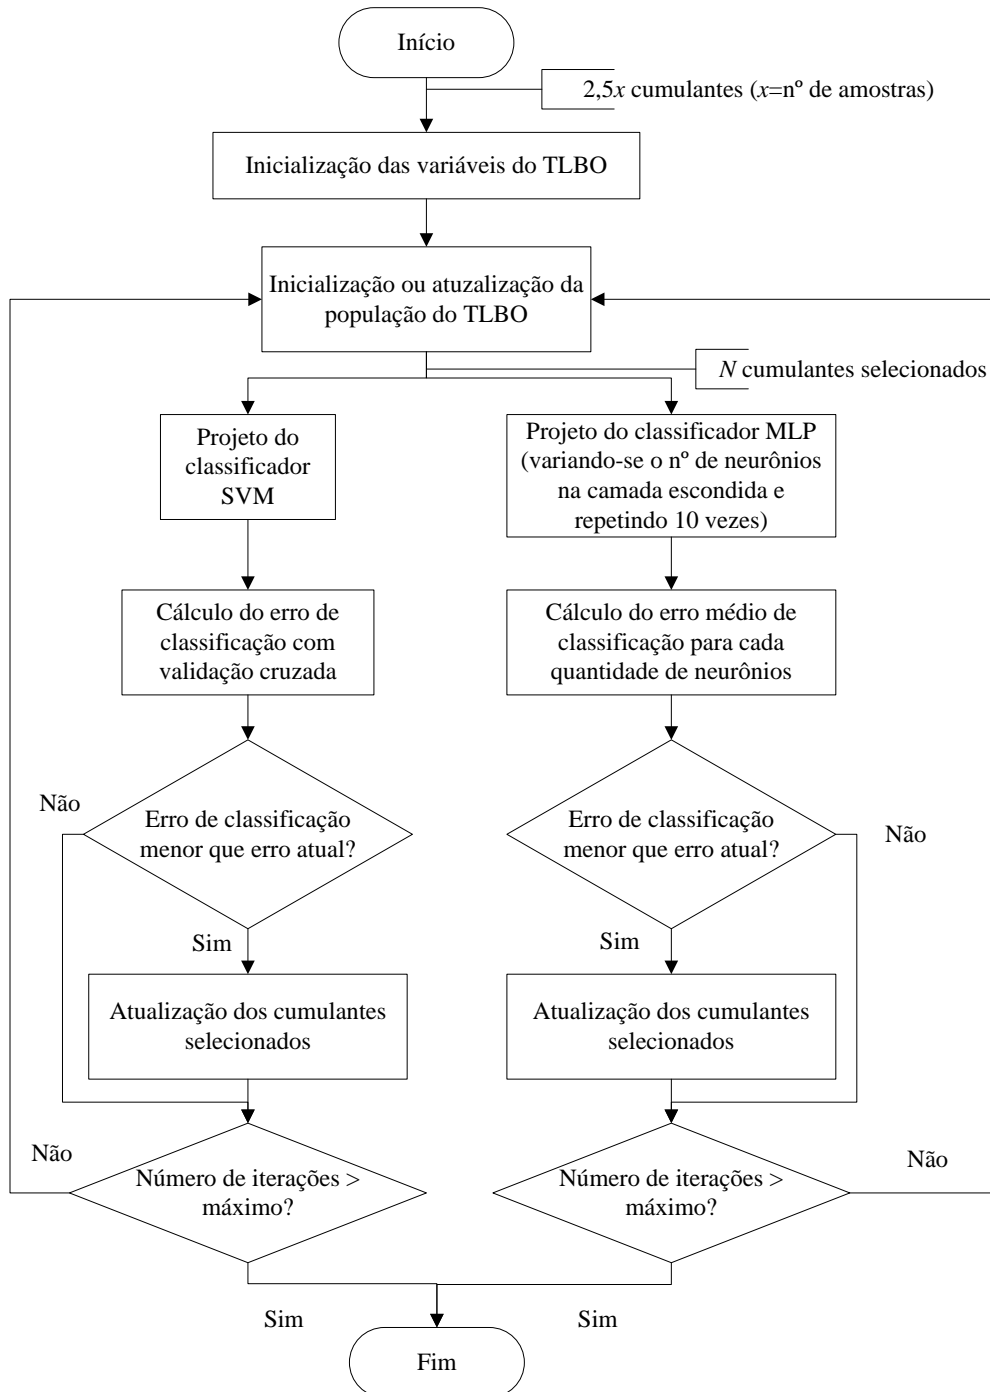
**Passo 4:** Caso o erro de classificação seja menor do que o erro atual, então são armazenados os cumulantes escolhidos. Repete-se todo o processo para as 50 gerações.

Os passos 2 e 3 são executados dentro da função de avaliação, que é executada para cada indivíduo da população durante a execução do TLBO. Para o classificador MLP, para

cada quantidade de neurônios na camada escondida, o processo de treinamento da MLP e classificação dos dados é repetido 10 vezes e então computado o erro médio de classificação. Já para o classificador SVM, a função custo é o erro médio quadrático da validação cruzada dos dados de treinamento utilizando 5 *folds*. Esses erros são os resultados das funções custo para cada classificador, respectivamente.

O processo de seleção de características pode então ser resumido na Figura 3.6.

Figura 3.6 – Fluxograma do processo de seleção de características.



Esse processo é realizado para cada um dos quatro comprimentos de sinal: 1 ciclo (256 amostras), 1/2 (128 amostras), 1/4 (64 amostras) e 1/8 de ciclo (32 amostras).

A fase de operação da classificação se resume em calcular os cumulantes selecionados na fase de projeto e fornece-los como entrada para o classificador já projetado.


## 4 RESULTADOS

Os resultados estão divididos em resultados de detecção/segmentação e resultados de classificação.

### 4.1 Resultados de detecção e segmentação

A evolução da otimização com TLBO para obtenção da melhor linha de detecção do ICA durante a fase de projeto é mostrada na Figura 4.1.

Figura 4.1 – Resultado da otimização da linha de detecção com TLBO.



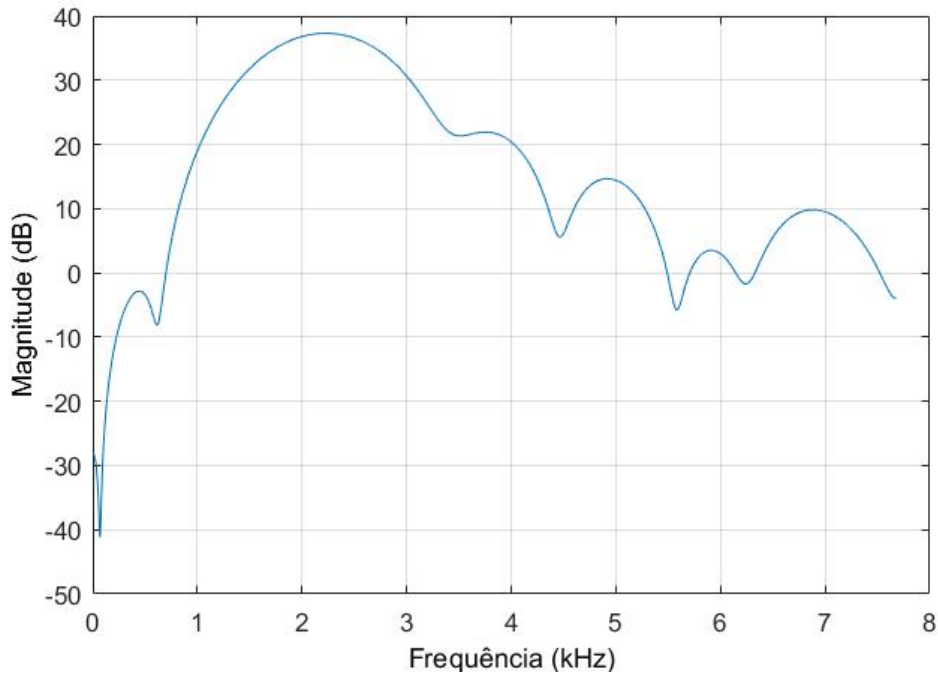
A melhor linha de detecção/segmentação encontrada pelo TLBO gera um erro de segmentação de 43,40%, que é um valor alto, mas em relação à detecção esse erro cai para 7,1%. No entanto, vale lembrar que os sinais avaliados na fase de operação executada durante o projeto possuem relação sinal-ruído (SNR) de 40 dB e harmônicos, sendo o pior caso para o método proposto. A escolha do pior caso para os dados de teste durante a fase de projeto é motivada para se obter melhor desempenho na fase de operação, pois se fossem escolhidos sinais com menos ruído e sem harmônicos, o método teria bons resultados durante o projeto, mas na fase de operação o desempenho seria prejudicado. Nas próximas seções serão feitas diversas análises que discutirão a eficiência do método de detecção/segmentação.

A linha de detecção ótima possui 15 coeficientes. Dessa forma, o valor  $M$  de deslocamentos necessários no Passo 1 da fase de operação é 14 (14 versões deslocadas do sinal original e o sinal original). Como a janela analisada a cada iteração possui 1/8 de ciclo

(apenas 32 amostras), então as variáveis na multiplicação realizada pela Equação (3.2) têm as seguintes dimensões:  $l(1 \times 15)$ ;  $x(15 \times 18)$ ;  $saída(1 \times 18)$ . As 18 colunas são resultantes dos 14 atrasos temporais feitos para construir a matriz de dados multicanais a partir da janela com dimensão  $1 \times 32$ , ou seja, em cada linha de  $x$  apenas 18 amostras das 32 são usadas, visto que é necessário descontar as 14 amostras referentes aos deslocamentos.

Como já mencionado, a ICA funciona como um filtro FIR na detecção dos AT, atenuando baixas frequências e amplificando frequências mais altas, onde se encontra a parte transiente dos AT. A resposta em magnitude do filtro FIR projetado é mostrada na Figura 4.2. Como na construção da matriz multicanal há 15 sinais, então o filtro possui 15 coeficientes. Observa-se na Figura 4.2 que o filtro obtido se aproxima de um passa-alta, atenuando frequências abaixo de aproximadamente 750 Hz, e amplificando frequências acima de 800 Hz, aproximadamente. A faixa de maior ganho, entre 800 Hz e 5,4 kHz, engloba as frequências da parte transiente do AT, assim como de parte do ruído presente. Portanto, a saída do método é constituída principalmente da parte transiente do AT e de ruído, filtrando a componente fundamental (60 Hz) e possíveis componentes harmônicas (aproximadamente abaixo de 800 Hz) que possam estar presentes.

Figura 4.2 – Resposta em magnitude do filtro FIR projetado pelo ICA na fase de projeto.



A título de ilustração, a Figura 4.3 mostra um exemplo de sinal trifásico com afundamento de tensão causado por falta trifásica e as respectivas respostas do método. As

Figuras 4.4 e 4.5 mostram exemplos de detecção de afundamentos causados por partida de motor de indução e saturação de transformador, respectivamente. A linha em vermelho em (b) representa o limiar de detecção para o respectivo sinal.

Figura 4.3 – Exemplo de detecção de afundamento causado por falta trifásica. (a) as 3 fases do sinal. (b) sinal de saída do método. A linha vermelha representa o limiar de detecção.

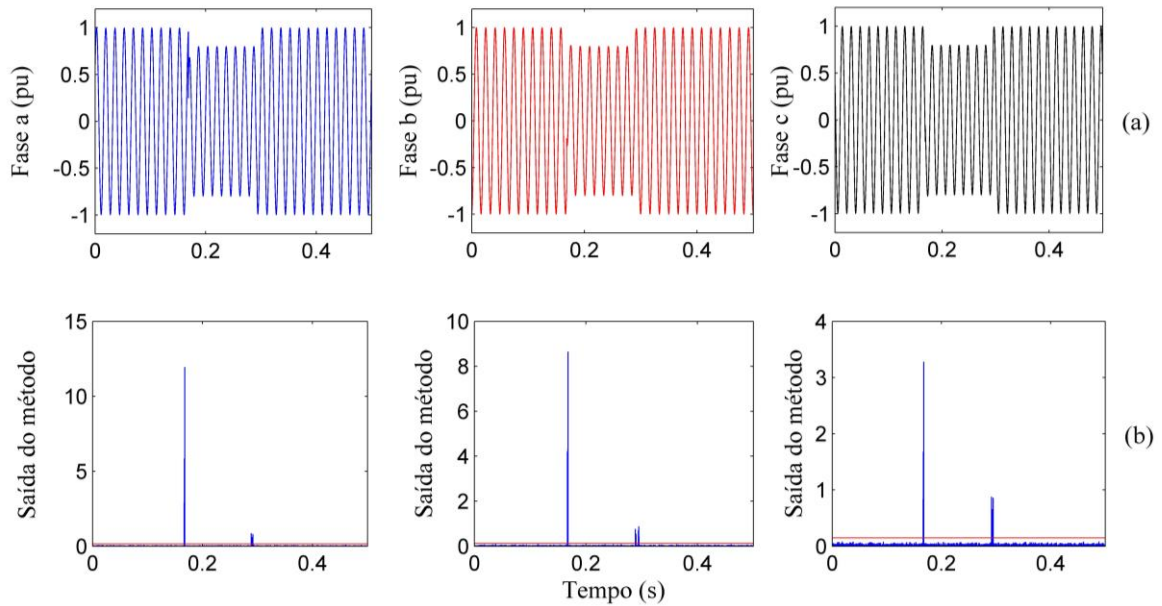
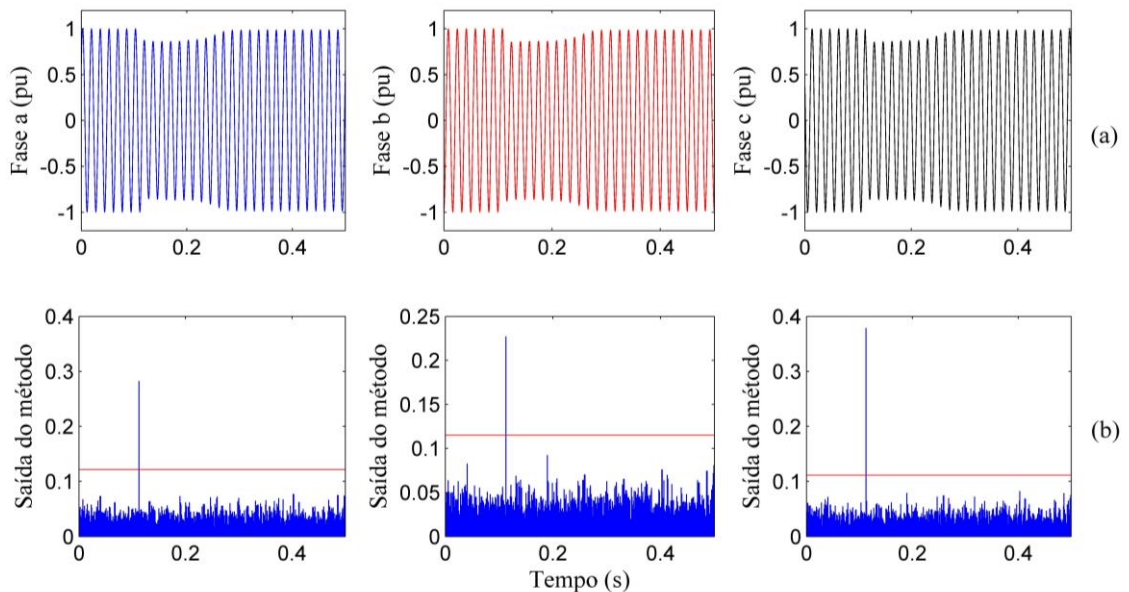



Figura 4.4 – Exemplo de detecção de afundamento causado por partida de motor de indução. (a) as 3 fases do sinal. (b) sinal de saída do método correspondente. A linha vermelha representa o limiar de detecção.



A partir dessas figuras, pode-se observar algumas características do método. Na Figura 4.3, na resposta do método para a fase b (vermelho), tem-se dois picos muito próximos referentes ao final do afundamento. Para não gerar falso alarme, é considerada a detecção do evento somente para picos distantes mais do que  $1/2$  ciclo um do outro, pois pela norma IEEE 1159 (2009) os afundamentos de tensão mais curtos são de  $1/2$  ciclo. Na Figura 4.4, observa-se menor pico de detecção na saída do método. Já na Figura 4.5, é possível notar que a partir do momento que o transformador entra em saturação, a resposta do método permanece acima do limiar, o que geraria vários falsos alarmes. Dessa forma, vê-se a necessidade de um sistema de classificação para identificar que o evento é uma saturação de transformador e, então, não levar em consideração os falsos alarmes.

Figura 4.5 – Exemplo de detecção de afundamento causado por saturação de transformador. (a) as 3 fases do sinal. (b) sinal de saída do método correspondente. A linha vermelha representa o limiar de detecção.



#### 4.1.1 Desempenho de detecção e segmentação para sinais simulados via Simulink

Aplicando o método de detecção nos dados de teste (450 sinais trifásicos, 30% dos dados gerados via *Simulink*) e variando-se o nível de ruído, obtém-se o resultado apresentado na Tabela 4.1. Foram testadas janelas deslizantes de comprimento  $1/8$  de ciclo, mas “deslizando”  $1/16$  ciclos,  $1/32$  ciclos e também amostra a amostra. Quanto menos amostras forem necessárias para serem deslocadas para formar a janela, mais rápida é a resposta. Para o

caso amostra a amostra, o método funciona em tempo real, pois a cada amostra é gerada uma nova resposta. Na Tabela 4.1 “Falta (1/16)” corresponde ao deslocamento de 1/16 ciclos, “Falta (1/32)” a 1/32 ciclos e “Falta (1 amostra)” a amostra a amostra.

No caso de falta, Det. na Tabela 4.1 significa detectar o início do evento corretamente, enquanto que Seg. significa detectar tanto o início quanto o fim do evento, ou seja, realizar a segmentação de forma correta. Assim, a porcentagem de segmentação errada corresponde a casos em que só o início ou só o final do evento foi detectado, ou ainda quando não há nenhuma detecção. Já para os casos de partida de motor e saturação de transformador, ambas as tarefas tem o mesmo significado: detectar o início do evento corretamente. “Falso Al.” é a abreviatura para taxa de falso alarme.

Tabela 4.1 – Desempenho de detecção para diferentes níveis de ruído

Tipo de afundamento	SNR = 60 dB			SNR = 50 dB			SNR = 40 dB		
	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)
Falta (1/16)	100	99,6	0,4	97,4	92,8	0,2	91,4	50,8	0,2
Falta (1/32)	100	98,2	1,8	98,2	92,6	0,2	92,4	51,6	0
Falta (1 amostra)	100	97,8	2,2	98,0	93,6	0,2	92,4	53,4	0
Partida de motor (1/16)	-	99,6	0,8	-	78,0	0,8	-	6,8	0,4
Partida de motor (1/32)	-	99,4	0,4	-	78,0	1	-	7,2	0,2
Partida de motor (1 amostra)	-	99,2	0,8	-	77,4	0,8	-	8,8	0
Saturação de transformador (1/16)	-	100	0	-	100	0	-	98	0
Saturação de transformador (1/32)	-	100	0	-	100	0	-	97,8	0
Saturação de transformador (1 amostra)	-	100	0	-	100	0	-	97,8	0

Analisando a Tabela 4.1, o método possui ótimo desempenho de detecção para afundamentos causados por falta. Para sinais com SNR igual ou maior que 50 dB, a tarefa de segmentação também é realizada com boas porcentagens de acerto. Apesar de ter uma taxa de

segmentação de apenas 50,8% para SNR de 40 dB no pior caso de falta, segundo Tomic, Kusljevic e Vujicic (2007), na prática, o SNR do sinal de tensão obtido no SEP varia entre 50 e 70 dB. Assim, casos de 40 dB seriam mais raros.

Para os casos de PMI e ST, se a aplicação do método for para sistemas de proteção, então não é importante realizar a detecção desses eventos, pois o sistema de proteção não deve atuar para esses casos. Além disso, grande parte dos afundamentos são causados por condições de falta. Para o caso de PMI, o método apresentou bom desempenho somente para SNR de 60 dB. Para o caso de ST, como já mencionado anteriormente, é importante que o sistema de classificação seja capaz de indicar essa causa.

A Tabela 4.2 mostra a média do erro médio quadrático (MSE) em  $s^2$  entre o tempo estimado de segmentação e o tempo real do banco de dados de teste, juntamente com o desvio padrão. Vale ressaltar que os três casos de deslocamento (1/16, 1/32 e 1 amostra) possuem MSE da ordem de  $10^{-7} s^2$ . A partir do MSE, é possível determinar a precisão na segmentação dos eventos, pois a tarefa de segmentação é justamente identificar o momento correto da ocorrência do evento e dividir o sinal em trechos com e sem afundamentos.

Tabela 4.2 – Desempenho de segmentação para diferentes níveis de ruído

Tipo de afundamento	SNR = 60 dB	SNR = 50 dB	SNR = 40 dB
	MSE $\pm$ desvio ( $\times 10^{-7}$ )	MSE $\pm$ desvio ( $\times 10^{-7}$ )	MSE $\pm$ desvio ( $\times 10^{-7}$ )
Falta	1,297 $\pm$ 0,6514	1,283 $\pm$ 0,6556	1,225 $\pm$ 0,5725
Partida de motor	0,9239 $\pm$ 0,5362	0,7787 $\pm$ 0,4037	0,6370 $\pm$ 0,8316
Saturação de transformador	1,407 $\pm$ 0,5592	1,307 $\pm$ 0,4470	9,083 $\pm$ 19,07

#### 4.1.2 Desempenho de detecção e segmentação para sinais sintéticos de afundamentos causados por falta

Além dos sinais simulados via Simulink, também foram gerados, sinteticamente, sinais no Matlab para ATs causados somente por falta (sua principal causa) para analisar melhor a influência de certas características do evento no desempenho do método. Analisando o desempenho do método para detecção e segmentação de sinais com somente AT causados por falta, variaram-se os seguintes parâmetros:

**Caso a1** - Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com e 50 % sem *phase-jump*; início do evento em diferentes pontos da onda (0 – 180°).

**Caso a2** - Afundamentos com tensão residual de 0,9 pu (0,1 pu de afundamento); **sem** *phase-jump*; início do evento em diferentes pontos da onda (0 – 180°).

**Caso a3** - Afundamentos com tensão residual de 0,9 pu (0,1 pu de afundamento); **com** *phase-jump*; início do evento em diferentes pontos da onda (0 – 180°).

**Caso a4** - Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com e 50 % sem *phase-jump*; início do evento em diferentes pontos da onda (0 – 180°). Frequência de amostragem variando entre 1200 Hz e 15360 Hz.

**Caso a5** - Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com e 50 % sem *phase-jump*; início do evento em diferentes pontos da onda (0 – 180°). Duração do AT de 1/2 ciclo.

Para todos os casos (com exceção do Caso a5), a duração do evento foi variada aleatoriamente entre 1/2 ciclo e 10 ciclos. Foi considerado ruído com SNR de 40, 50 e 60 dB. Foram gerados 500 sinais para cada um dos casos simulados. Os resultados dessa análise são mostrados na Tabela 4.3.

De modo geral, analisando o Caso a1 da Tabela 4.3, observa-se que o método possui alta porcentagem de detecção e segmentação, principalmente para situações com SNR igual ou maior que 50 dB.

É possível notar que, para sinais sem *phase-jump* (Caso a2), o desempenho do método é mais afetado pelo ruído. Para esse caso, relação sinal-ruído abaixo de 60 dB já faz com que a porcentagem de eventos com início e fim corretamente detectados fique relativamente baixa. Se o ruído possuir SNR de 70 dB o desempenho de segmentação aumenta para 98,8% e de detecção para 100%.

Com base na Tabela 4.3 (Caso a3), é possível aferir que faltas de alta impedância, em que a magnitude do afundamento é baixa, não afetam significativamente o desempenho, pois no Caso a3 os afundamentos foram todos de 0,1 pu e as taxas de detecção e segmentação se mantiveram em alto nível para as situações com SNR = 60 dB e 50 dB.

Analisando o Caso a4, observa-se que a frequência de amostragem também não afeta o desempenho do método. No entanto, para que seja possível o uso de diferentes frequências de amostragem, é necessário que se varie o tamanho da janela analisada para que seja possível a construção da matriz de dados multicanais. Para a variação entre 1200 e 15360 Hz, o tamanho da janela varia entre 1,6 ciclos e 1/8 ciclos respectivamente.

Embora AT de curta duração sejam difíceis de serem detectados para outros métodos de detecção, o Caso a5 mostrou que o método proposto não encontra dificuldades para eventos de 1/2 ciclo de duração. Pelo contrário, este foi o caso com melhor desempenho na Tabela 4.3.

Tabela 4.3 – Desempenho de detecção para sinais sintéticos com somente afundamentos de tensão causados por falta.

Tipo de afundamento	SNR = 60 dB			SNR = 50 dB			SNR = 40 dB		
	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)
Caso a1 (1/16)	100	99,40	0	97,8	95,80	0,6	89,6	80,60	0,6
Caso a1 (1/32)	99,8	99,6	0	97,8	95,6	0,6	89,6	81,8	0,2
Caso a1 (1 amostra)	100	99,6	0	97,4	95,2	0,6	90,2	82,2	0,2
Caso a2 (1/16)	95,6	92,6	0,4	88,6	75,8	0,2	54,6	24,8	0,6
Caso a2 (1/32)	95,6	92,6	0,2	86,8	74,2	0,2	57,0	26,6	0
Caso a2 (1 amostra)	95,6	92,6	0	87,2	75,8	0,2	52,8	25,4	0,6
Caso a3 (1/16)	99,6	99,0	0,2	95,6	91,8	0,4	86,2	71,4	0,6
Caso a3 (1/32)	99,2	99,2	0,6	95,4	91,0	0,6	87,0	71,6	0,2
Caso a3 (1 amostra)	99,6	99,6	0,2	95,6	91,2	0,2	86,4	70,8	0,4
Caso a4 (1/16)	99,8	99,4	0,2	98,2	97,2	0,2	87,2	79,0	0,4
Caso a4 (1/32)	99,8	99,6	0	97,6	95,8	0,6	86,6	78,0	1,0
Caso a4 (1 amostra)	99,8	99,2	0,6	98,2	95,8	0,4	87,0	78,2	0,4
Caso a5 (1/16)	100	99,4	0,6	98,6	97,2	0,2	92,6	90,2	0,4
Caso a5 (1/32)	100	99,8	0,2	98,2	97,2	0,6	91,2	90,4	0,2
Caso a5 (1 amostra)	100	99,6	0,2	98,2	97,2	0,2	92,0	90,2	0

Verifica-se que as três diferentes quantidades de deslocamentos das janelas não geraram diferença significativa no desempenho, permitindo a escolha da melhor da opção de acordo com a aplicação.

Em relação à segmentação, o MSE entre os tempos originais e estimados se manteve na ordem de  $10^{-7}$  para todos os casos, tal como na Tabela 4.2, evidenciando a alta precisão para segmentação dos sinais com AT simulados para esses casos.

#### 4.1.3 Desempenho de detecção e segmentação para sinais sintéticos de afundamentos causados por falta na presença de outros distúrbios

A fim de verificar a robustez do método na presença de outros distúrbios, foram gerados, sinteticamente, AT na presença de harmônicos, flutuações de tensão (*flicker*) e variações na frequência fundamental do sinal elétrico. Essas análises também foram feitas para diferentes níveis de ruído.

Os distúrbios foram gerados de acordo com os seguintes casos:

##### **Caso b1:** AT + harmônicos (até o limite da norma)

- Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com *phase-jump* e 50% sem; início do evento em diferentes pontos da onda (0 – 180°).
- 3° componente harmônico com amplitude de 0.03 pu + 5° componente harmônico com amplitude de 0.02 pu.

##### **Caso b2:** AT + harmônicos (acima do limite da norma)

- Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com *phase-jump* e 50% sem; início do evento em diferentes pontos da onda (0 – 180°).
- 3° componente harmônico variando entre 0.05 e 0.07 pu + 5° componente variando entre 0.04 e 0.06 pu + 7° componente variando entre 0.03 e 0.05 pu + 11° componente variando entre 0.02 e 0.04 pu + 13° componente variando entre 0.01 e 0.03 pu.

##### **Caso b3:** AT + *flicker*

- Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com *phase-jump* e 50% sem; início do evento em diferentes pontos da onda (0 – 180°).
- Flicker com amplitude de modulação variando entre 0.01 e 0.1 pu, e frequência da envoltória variando entre 5 e 25 Hz.

**Caso b4:** AT + variação da frequência fundamental

- Afundamentos com amplitude entre 0,1 e 0,9 pu; 50% com *phase-jump* e 50% sem; início do evento em diferentes pontos da onda (0 – 180°).
- Frequência da componente fundamental variado  $\pm 5\%$ , ou seja, entre 57 e 60 Hz. A variação da frequência foi gerada através de um degrau na frequência fundamental.

Foram gerados 500 sinais para cada um dos quatro casos simulados e considerado ruído com SNR de 40, 50 e 60 dB. A duração dos AT também variou entre 1/2 ciclo e 10 ciclos. Foram considerados dois casos diferentes para harmônicos: Caso b1 é para THD (*Total Harmonic Distortion*) de até 5%, o que obedece à norma IEC TR 61000-3-6 (2008); Caso b2, com THD acima de 5%. Os resultados dessa análise são mostrados na Tabela 4.4.

Tabela 4.4 – Desempenho de detecção para sinais sintéticos com afundamentos de tensão e outros distúrbios.

Tipo de afundamento	SNR = 60 dB			SNR = 50 dB			SNR = 40 dB		
	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)	Det. (%)	Seg. (%)	Falso Al. (%)
Caso b1 (1/16)	99,8	99,2	0,4	98,6	94,4	0,6	89,2	81,6	0,4
Caso b1 (1/32)	99,8	99,4	0	98,2	94,0	0,6	90,0	81,4	0,6
Caso b1 (1 amostra)	99,6	99,4	0	98,4	94,4	0,4	89,6	80,8	0,6
Caso b2 (1/16)	99,4	99,2	0,8	98,0	95,0	0,2	91,8	85,2	0
Caso b2 (1/32)	99,4	99,2	0	98,2	96,4	0	92,8	84,4	0
Caso b2 (1 amostra)	99,4	99,0	0	98,0	95,6	0	92,0	84,0	0,4
Caso b3 (1/16)	100	99,8	0	97,2	95,2	0,4	90,4	83,2	0,6
Caso b3 (1/32)	99,8	99,8	0	96,6	94,6	0,6	90,0	83,2	0,6
Caso b3 (1 amostra)	100	99,8	0	97,4	94,6	0,6	90,0	83,2	0,4
Caso b4 (1/16)	100	99,2	0,2	96,6	93,4	0,6	89,2	80,4	0,6
Caso b4 (1/32)	100	98,2	0,4	97,2	94,0	0,2	90,0	81,0	0,8
Caso b4 (1 amostra)	99,8	98,6	0	97,0	94,4	0,4	90,0	81,4	0,4

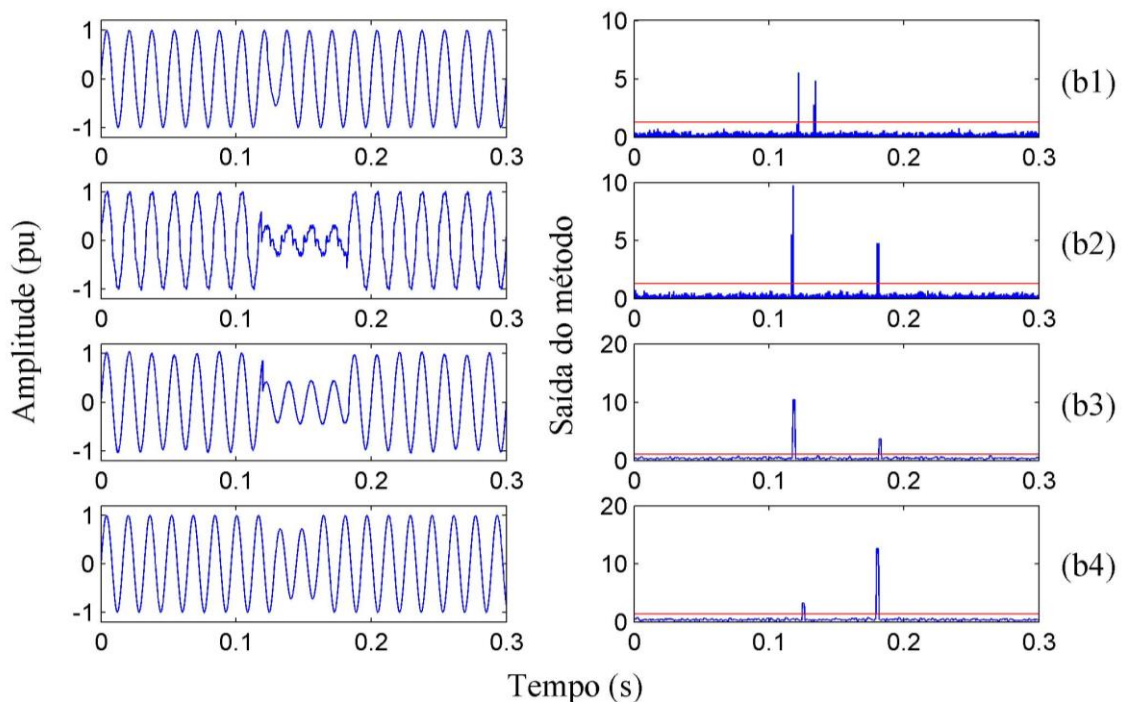
De acordo com a Tabela 4.4, pode-se afirmar que o desempenho do método não foi afetado pela presença de harmônicos, *flicker* ou variação da frequência fundamental do sistema, pois as porcentagens de segmentação se mantiveram acima de 93% e detecção acima de 96% para SNR de 50 e 60 dB. O desempenho só foi afetado pela presença de ruído com SNR de 40 dB, mas ainda mantendo acima de 80% de segmentação correta. Verifica-se também um desempenho muito parecido para diferentes quantidades de deslocamentos das janelas (1/16, 1/32 e 1 amostra), permitindo a escolha do deslocamento mais apropriado para a aplicação.

Em relação à segmentação, o MSE se manteve na ordem de  $10^{-7}$  para todos os casos, indicando precisão na segmentação ainda que na presença dos distúrbios analisados.

A Figura 4.6 mostra um exemplo de sinal para cada caso e a detecção/segmentação realizada pelo método. São sinais do caso de SNR = 40 dB. A linha em vermelho representa o limiar de detecção. Nessa figura fica evidente a adaptabilidade do limiar, que se modifica dependendo das características do sinal, tais como ruído e harmônicos.

É importante ressaltar que o método também é aplicável para elevações de tensão, uma vez que as características da parte transitória desse distúrbio são semelhantes às dos ATs.

Figura 4.6 – Exemplos de AT detectados para cada um dos casos (b1, b2, b3 e b4) com outros distúrbios.



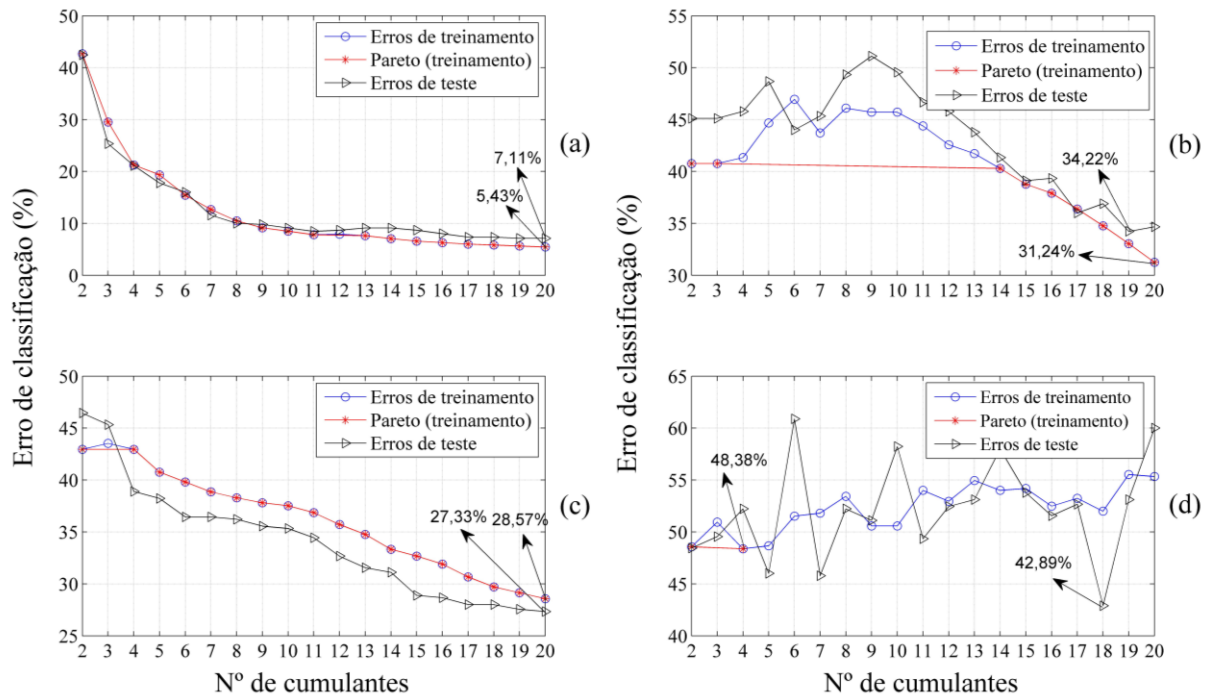
## 4.2 Resultados de classificação

Após realizada a tarefa de detecção e segmentação dos afundamentos de tensão, é importante classificar os eventos para identificar sua causa. Foram projetados dois classificadores diferentes: um baseado em SVM e outro baseado em MLP. Nessa seção foi utilizado o banco de dados gerado via *Simulink*, ou seja, 1500 sinais de tensão trifásico, dos quais 1050 são para treinamento e 450 são para teste.

### 4.2.1 Resultados com o classificador SVM

Durante a fase de projeto foram selecionados os melhores cumulantes para cada quantidade  $N$  de cumulantes, com  $N$  variando entre 2 e 20, para janelas de 1, 1/2, 1/4 e 1/8 de ciclos. Os erros médios quadráticos mínimos encontrados na validação cruzada com os dados de treinamento para cada um desses quatro comprimentos de janela são mostrados na Figura 4.7.

Figura 4.7 – Erro de classificação de treinamento (seleção dos melhores cumulantes) e de teste para o classificador SVM. (a) Janela de 1 ciclo. (b) Janela de 1/2 ciclo. (c) Janela de 1/4 de ciclo. (d) Janela de 1/8 de ciclo.



O menor erro de treinamento (5,43% com validação cruzada de 5 *folds*) foi encontrado com 20 cumulantes e com janelas de 1 ciclo do sinal de tensão. Os demais tamanhos de janelas tiveram um desempenho pior e, provavelmente insuficiente para determinadas aplicações. Portanto, para o classificador SVM é mais aconselhável utilizar janelas de 1 ciclo para realizar a classificação de AT na abordagem desse trabalho. O conjunto de Pareto (em vermelho) representa o menor erro para a menor quantidade de cumulantes possível, uma vez que é mais interessante utilizar classificadores com menos entradas, que são mais simples.

Aplicando os classificadores projetados na fase de treinamento nos dados de teste, verifica-se que, assim como na fase de treinamento, o menor erro (7,11%) ocorreu com janelas de 1 ciclo e com 20 cumulantes. Para os dados de teste o erro obtido com 20 cumulantes foi igual ao obtido com 19 cumulantes. Para esse caso, houve 15 cumulantes de 2ª ordem e 5 de 4ª ordem selecionados pelo TLBO. Os demais comprimentos de janelas tiveram erro relativamente alto. Esse desempenho reduzido pode ser justificado pela pouca informação presente em tais tamanhos de janela e/ou pela escolha do *kernel* polinomial de quarta ordem. A escolha do *kernel* foi feita de maneira empírica e, para os dados analisados apresentou menor erro. No entanto, uma escolha mais detalhada e feita de forma automática poderia levar a resultados melhores, o que será investigado em trabalhos futuros.

Para analisar melhor o desempenho de classificação para cada classe individualmente, é utilizada a matriz de confusão para a classificação de dados de teste do melhor caso (1 ciclo e 20 cumulantes). A Tabela 4.5 mostra essa análise. A classe C1 é referente a AT causados por falta, C2 é para PMI e C3 para ST. Nota-se que não houve grandes discrepâncias nas médias de acertos entre as três classes, sendo que para casos de falta tem-se a menor taxa de acerto (90%).

Tabela 4.5 - Matriz de confusão da classificação com dados de teste (SVM com 20 cumulantes e janela de 1 ciclo).

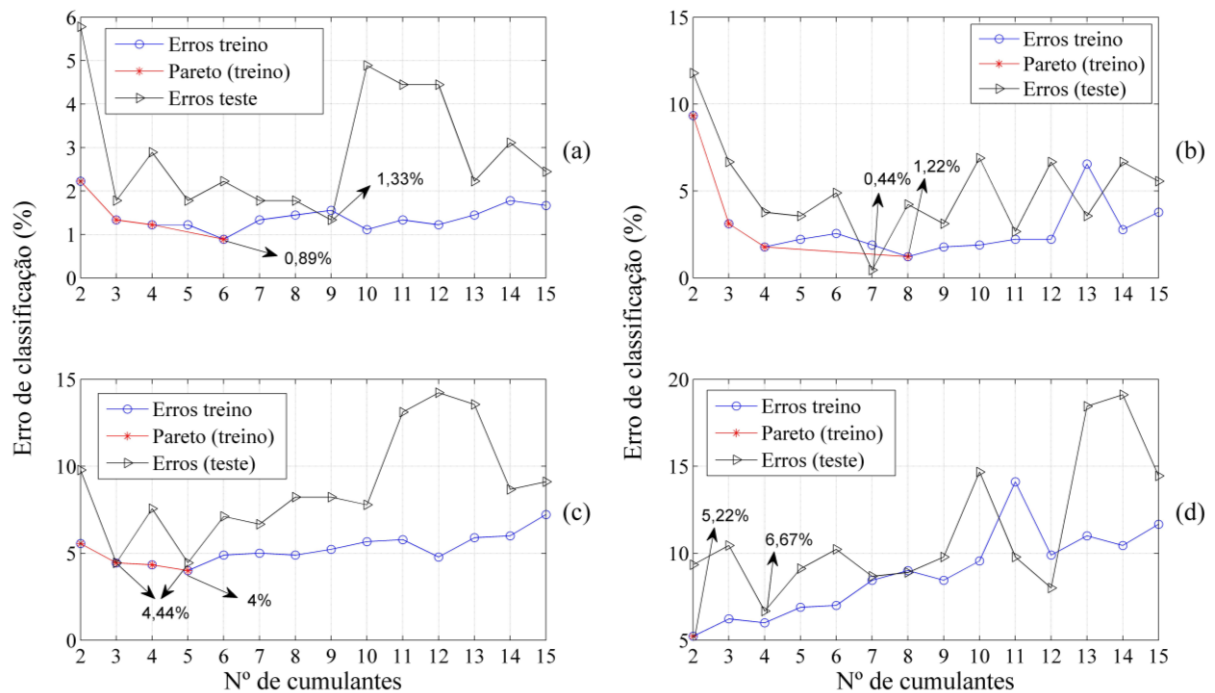
Dados em porcentagem		Classe estimada			Falsos negativos
		C1	C2	C3	
Classe real	C1	<b>90</b>	9,33	0,67	10
	C2	4,67	<b>95,33</b>	0	4,67
	C3	0	6,67	<b>93,33</b>	6,67
	Falsos positivos	4,67	16	0,67	<b>92,89</b>

#### 4.2.2 Resultados com classificador Perceptron de Multicamadas (MLP)

Na fase de projeto foram otimizados os cumulantes utilizados de entrada para a MLP considerando  $N$  variando entre 2 e 15 cumulantes. Também foram consideradas janelas de 1, 1/2, 1/4 e 1/8 de ciclo do sinal de tensão. A Figura 4.8 mostra os erros de classificação dos dados de treinamento e de teste para cada comprimento de janela. É possível notar um melhor desempenho para o classificador MLP em relação ao SVM, uma vez que o menor erro de treinamento foi de 0,89% com janela de 1 ciclo e menor erro de teste foi de 0,44% com janela de 1/2 ciclo. Mesmo com comprimento de janela reduzido (1/8 de ciclo) foi possível classificar os afundamentos de tensão com níveis relativamente baixos de erro.

Para janela de 1/2 ciclo, o TLBO selecionou 3 cumulantes de 2ª ordem e 4 de 4ª ordem no melhor caso. Para janela de 1/8 de ciclo, foram selecionados 3 cumulantes de 2ª ordem e 1 de 4ª. Para os outros tamanhos de janela também foram selecionados apenas cumulantes dessas duas ordens, o que mostra que os cumulantes de 3ª ordem não são boas características para serem usadas com esse tipo de classificador e para esse problema.

Figura 4.8 – Erros de classificação de treinamento (seleção dos melhores cumulantes) e de teste para classificador MLP. (a) Janela de 1 ciclo. (b) Janela de 1/2 ciclo. (c) Janela de 1/4 de ciclo. (d) Janela de 1/8 de ciclo.



Para analisar o desempenho de classificação para cada classe, foi feita a matriz de confusão para os melhores casos com dados de teste para janelas de 1/2 ciclo e 1/8 de ciclo, apresentada na Tabela 4.6.

Tabela 4.6 - Matriz de confusão da classificação com dados de teste (MLP com 7 cumulantes e janela de 1/2 ciclo e MLP com 4 cumulantes e janela de 1/8 de ciclo).

1/2 ciclo		Classe estimada			Falsos negativos	1/8 ciclo	Classe estimada			Falsos negativos
		C1	C2	C3			C1	C2	C3	
Classe real	C1	<b>99,33</b>	0	0,67	0,67	C1	<b>86,67</b>	3,33	10	13,33
	C2	0	<b>100</b>	0	0	C2	0	<b>100</b>	0	0
	C3	0	0,67	<b>99,33</b>	0,67	C3	3,33	3,33	<b>93,33</b>	6,67
	Falsos positivos	0	0,67	0,67	<b>99,56</b>	Falsos positivos	3,33	6,67	10	<b>93,33</b>

Analisando a Tabela 4.6, com janela de 1/2 ciclo conseguiu-se a melhor taxa de acerto, havendo o erro de apenas 1 evento de afundamento causado por falta e 1 evento de saturação de transformador dentre os 450 eventos classificados. Dependendo do desempenho, rapidez e complexidade necessários para a aplicação é possível optar por diferentes tamanhos de janela analisadas.

#### 4.2.3 Resultados de classificação na presença de outros distúrbios

Para testar a robustez do método de classificação na presença de outros distúrbios, foram gerados os seguintes casos simulados de afundamentos de tensão:

##### Caso c1: AT + ruído

- Ruído gerado considerando SNR = 40 dB;

##### Caso c2: AT + flicker + ruído (SNR = 40 dB)

- Flicker com amplitude de modulação variando entre 0.01 e 0.1 pu, e frequência da envoltória variando entre 5 e 25 Hz.

##### Caso c3: AT + harmônicos (até o limite da norma) + ruído (SNR = 40 dB)

- 3° componente harmônico com amplitude de 0.03 pu + 5° componente harmônico com amplitude de 0.02 pu.

**Caso c4:** AT + harmônicos (acima do limite da norma) + ruído (SNR = 40 dB)

- 3° componente harmônico variando entre 0.05 e 0.07 pu + 5° componente variando entre 0.04 e 0.06 pu + 7° componente variando entre 0.03 e 0.05 pu + 11° componente variando entre 0.02 e 0.04 pu + 13° componente variando entre 0.01 e 0.03 pu.

Para o Caso c3 foi considerada a presença de harmônicos até o limite indicado pela norma IEC STD 61000-3-6, com THD de até 5%. Para classificação foi utilizado somente o classificador MLP, que possui desempenho superior ao SVM e, inclusive necessita de menos entradas para o classificador. Foi escolhido o número de entradas (cumulantes) de acordo com o melhor desempenho para dados de teste e de acordo com o tamanho de janela analisada. Os resultados de classificação são mostrados na Tabela 4.7. Nota-se que a presença de ruído (Caso c1) só afetou negativamente janelas de 1/4 de ciclo, sendo que com 1/8 de ciclo houve uma redução do erro de classificação. Para os outros casos, a presença de *flicker* ou harmônicos gerou queda no desempenho. O pior caso foi para harmônicos com THD maior que 5%, que embora tenha afetado menos a classificação com 1 ciclo, fez aumentar o erro para os outros tamanhos de janela. A presença de harmônicos leva o método a confundir casos de falta e partida de motor com saturação de transformador, pois essa é uma característica do afundamento causado por saturação de transformador. Janelas com 1/2 ciclo continuaram apresentando o menor nível de erro para a maioria dos casos.

Tabela 4.7 - Erros de classificação com MLP para sinais simulados com outros distúrbios.

Caso	Tamanho da janela			
	1 ciclo (9 cum)	1/2 ciclo (7 cum)	1/4 ciclo (3 cum)	1/8 ciclo (4 cum)
<b>c1</b>	1,33%	0,44%	5,11%	5,33%
<b>c2</b>	4,00%	0,89%	13,56%	10,44%
<b>c3</b>	19,11%	3,11%	22,67%	17,33%
<b>c4</b>	4,00%	10,44%	14,44%	38,00%

### 4.3 Resultados com dados reais

Para avaliar o desempenho do método com dados reais, foi utilizado um banco de dados coletado do sistema de distribuição da rede elétrica escocesa. Por esse motivo, os sinais possuem frequência fundamental de 50 Hz, sendo que foi utilizada uma frequência de

amostragem de 4800 Hz na aquisição. Essa diferença na frequência fundamental e de amostragem impossibilita a aplicação do método de classificação projetado, que deve ser reprojetoado considerando essas características dos dados. Entretanto, o método de detecção pode ser aplicado, uma vez que o comportamento de filtro do método não é afetado por frequências menores que 60 Hz e, como já mostrado em análise anterior, a frequência de amostragem não impede a aplicação do método.

O banco de dados possui 129 sinais trifásicos, sendo 116 de afundamentos causados por falta e 13 de afundamentos causados por saturação de transformador. As Figuras 4.9 a 4.11 ilustram o processamento desses sinais pelo método de detecção. A Figura 4.9 corresponde a um afundamento bifásico, a Figura 4.10 mostra um afundamento trifásico de dois estágios e a Figura 4.11 mostra um afundamento causado por saturação de transformador. É possível notar a semelhança da resposta do método em relação aos dados simulados. A Tabela 4.8 mostra o resultado quantitativo para os dados reais, evidenciando o alto desempenho para a tarefa de detecção, com baixa taxa de falso alarme. A taxa de erro de 20,7% para segmentação pode ser justificada pelo nível de ruído, presença de harmônicos e/ou ausência de *phase-jump* nos eventos analisados.

Figura 4.9 – Sinal real de afundamento bifásico e a resposta do método para cada fase.

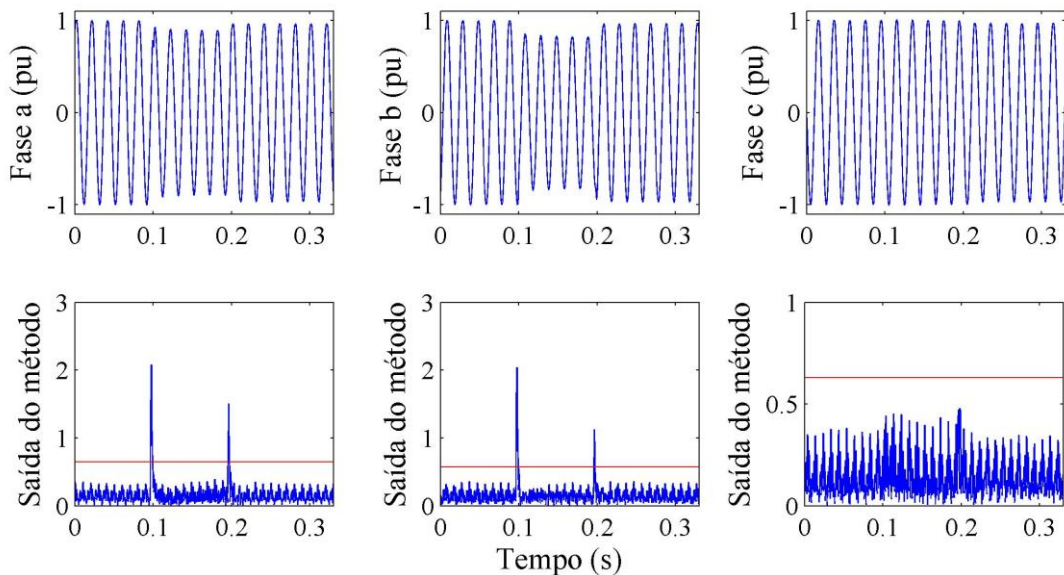


Figura 4.10 – Sinal real de afundamento trifásico de dois estágios e a resposta do método para cada fase.

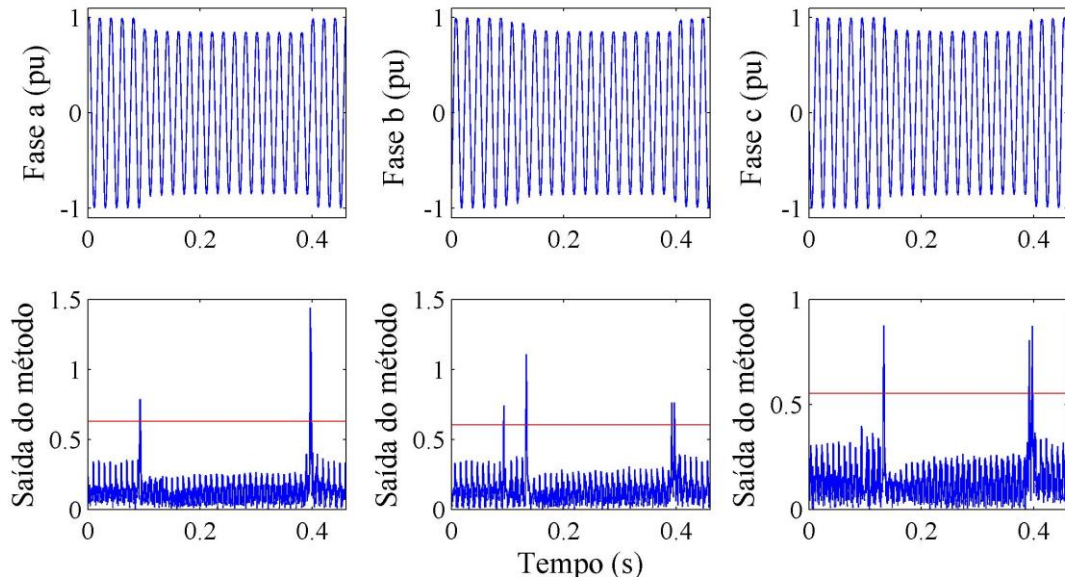


Figura 4.11 – Sinal real de afundamento causado por saturação de transformador e a resposta do método para cada fase.

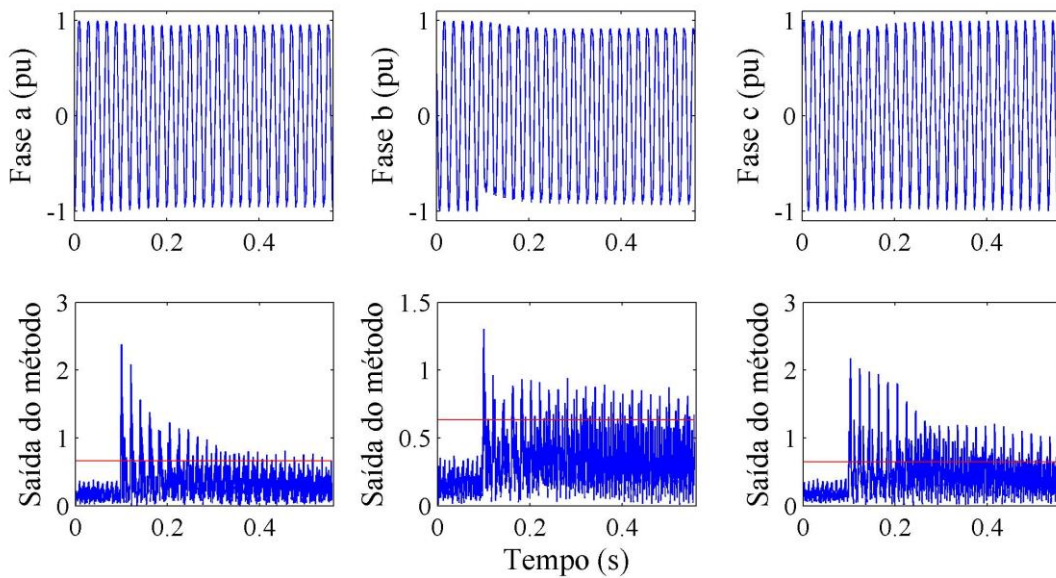


Tabela 4.8 - Desempenho de detecção e segmentação para dados reais.

Tarefa	% de erro	Falso Alarme
Detecção	0,86 %	0,86 %
Segmentação	20,7 %	0,86 %

## 4.4 Comparação com outros métodos

O método proposto foi comparado com outros métodos de detecção, segmentação e classificação de afundamentos de tensão. Essa comparação foi dividida entre as três tarefas, uma vez que a maior parte dos métodos só realiza a detecção e/ou segmentação.

### 4.4.1 Comparação com método de detecção e segmentação baseado em transformada Wavelet

O trabalho de Latran e Teke (2015) propõe um método de detecção de afundamentos e elevações de tensão baseado na transformada Wavelet. Os autores utilizaram seis casos simulados para avaliar o desempenho do método. Em todos os casos os ATs e as ETs ocorrem entre 0,2 e 0,3 segundos. Os casos são os seguintes:

- Caso 1: AT de 13% sem *phase-jump*
- Caso 2: ET de 13% sem *phase-jump*
- Caso 3: AT de 13% com  $-10^\circ$  de *phase-jump*
- Caso 4: ET de 13% com  $-10^\circ$  de *phase-jump*
- Caso 5: AT de 13% com  $-20^\circ$  de *phase-jump* em um sinal distorcido com harmônicos
- Caso 6: AT de 13% com  $-20^\circ$  de *phase-jump* em um sinal distorcido com harmônicos e *flicker*

Esses casos foram simulados e processados com o método proposto. Os tempos de detecção alcançados pelo método proposto e pelo método desenvolvido por Latran e Teke (2015) são mostrados na Tabela 4.9.

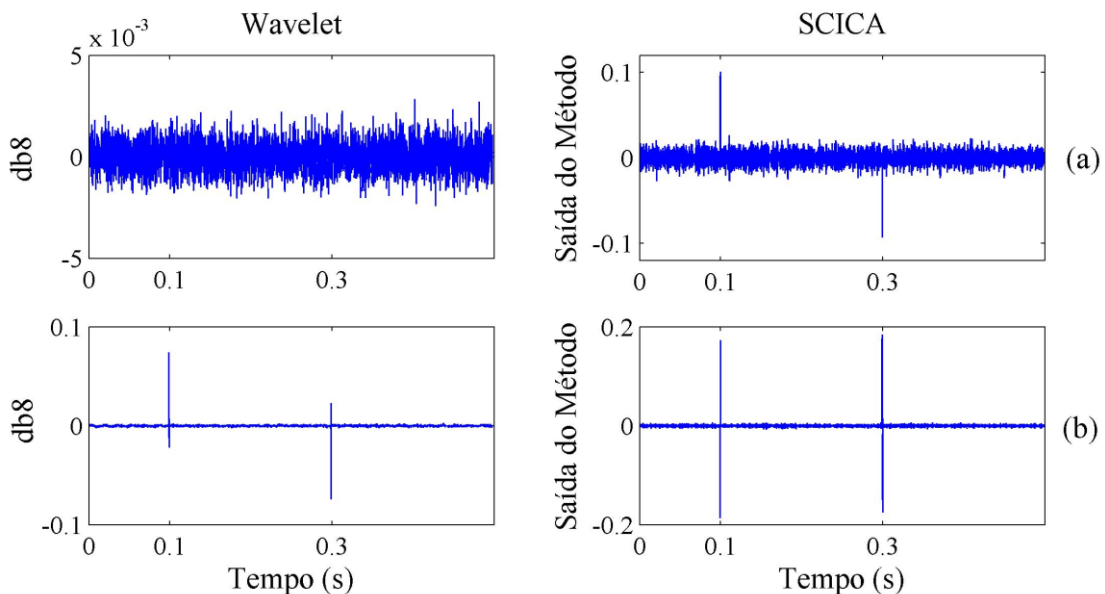
Pode-se observar que os métodos tiveram precisão de segmentação semelhantes. No entanto, o método proposto possui a vantagem de ser robusto a ruído e variação da frequência fundamental. Observe que o método de Latran e Teke (2015) não incluiu ruído em suas análises. Além disso, no trabalho de Latran e Teke (2015), o tempo necessário para detectar o início e fim do evento é de 0,5 ms para afundamentos sem *phase-jump* e 1,15 ms para afundamentos com *phase-jump*. O método proposto pode ser aplicado em tempo real, produzindo resultados a cada amostra, necessitando de apenas o intervalo de 1 amostra (0,065 ms) para detectar o afundamento, sendo mais rápido que o trabalho com Wavelet.

Tabela 4.9 - Comparação entre um método baseado em transformada Wavelet e o método proposto (SCICA) para segmentação de afundamentos e elevações de tensão.

Casos	Wavelet		SCICA	
	Início (s)	Fim (s)	Início (s)	Fim (s)
1	0,2005	0,3010	0,1997	0,2994
2	0,2005	0,3010	0,1994	0,2997
3	0,2003	0,3001	0,1996	0,2996
4	0,2003	0,3001	0,1996	0,2996
5	0,2003	0,3001	0,1996	0,2996
6	0,2003	0,3001	0,1995	0,2995

A Figura 4.12 mostra a respostas dos dois métodos para sinais com ruído (SNR = 60 dB). Na Figura 4.12 (a) há um afundamento de 13% sem *phase-jump*, enquanto na (b) o afundamento de 13% possui *phase-jump* de  $-10^\circ$ . Pode-se observar que o método baseado em Wavelet não foi capaz de detectar o afundamento sem *phase-jump*, pois não há picos no sinal de saída que representem a presença de distúrbios. Por outro lado, o método proposto detectou o afundamento em ambas as situações.

Figura 4.12 – Comparação entre Wavelet e SCICA para segmentação de AT na presença de ruído. (a) AT de 13% sem *phase-jump*. (b) AT de 13% com  $-10^\circ$  de *phase-jump*.



#### 4.4.2 Comparação com outros métodos de detecção/segmentação e classificação

No trabalho de Gu et al. (2004), foi proposto um detector e classificador de ATs causados por falta, saturação de transformadores e chaveamento de capacitores. O método consiste em detectar os eventos utilizando o valor RMS de meio ciclo do sinal de tensão e classifica-los através de informações obtidas do valor RMS juntamente com o critério estatístico de Neyma-Pearson, de tal forma a garantir uma taxa de falso alarme menor do que 5%. O método analisa tamanhos diferentes de janela do sinal de tal forma a garantir a detecção e classificação com o menor tempo possível. Primeiro utiliza-se janela de 1/8 de ciclo e, se não for detectado um evento causado por falta, então utiliza-se uma janela de 1/4 de ciclo, sendo repetido o processo com janelas de 1/2 e 3/4 de ciclos até constatar a presença de AT por falta, caso contrário o evento é classificado como não causado por falta. Foram utilizados sinais reais obtidos da medição realizada por 2 meses em uma rede de média tensão.

Os resultados mostraram que o método é capaz de detectar mais de 98% dos eventos considerando uma taxa de falso alarme de 5%. Para dados de treinamento, cerca de 70% dos ATs causados por falta foram classificados corretamente utilizando uma janela de 1/4 de ciclo, com menos de 10% dos eventos de saturação de transformador incorretamente classificados como falta. Aumentando-se o tamanho da janela para 3/4 de ciclo todos os eventos causados por falta são detectados e 20% do total de ATs causados por saturação de transformador são classificados como faltas. Para dados de teste, com janelas de 1/4 de ciclo cerca de 70% dos eventos causados por faltas são corretamente classificados e 20% dos eventos causados por saturação de transformadores são detectados como falta. Para janelas de 3/4 ciclo todas as faltas são detectadas corretamente e 30% das saturações de transformador são classificadas como faltas.

Considerando os resultados alcançados pelo método proposto nessa dissertação de mestrado, atingiu-se uma taxa de detecção acima de 99% para a maioria dos casos simulados, considerando janelas de 1/8 de ciclo e resposta em tempo real (a cada nova amostra). A taxa de falso alarme ficou em cerca de 1% para a maioria dos casos. Para sinais reais, a taxa de detecção foi de 99,14%. Em relação à classificação, considerando os resultados com ruído para o método proposto (Caso c1), o método proposto obteve média de 99,56% e 94,89% de acerto para janelas de 1/2 e 1/4 de ciclo respectivamente. Para janela de 1/4 ciclo 97,33% das faltas são classificadas corretamente e houve acerto de 91,33% para eventos de ST (6% das ST são classificados como falta). Para janela de 1/2 ciclo, 99,33% das faltas e das ST são

classificadas corretamente, havendo somente 1 evento de falta classificado como ST e 1 evento de ST classificado como PMI.

Comparando os métodos, o desempenho do método proposto é superior para as tarefas de detecção e classificação de ATs, embora não tenha sido possível utilizar o mesmo banco de dados do trabalho de Gu et al. (2004). Ademais, o método Gu et al. (2004) possui a desvantagem de precisar de medições de um ano inteiro para incluir as variações sazonais no treinamento do método caso deseje-se obter resultados ótimos.

No trabalho de Manjula, Mishra e Sarma (2013), como já explicado na Seção 2.7, foi utilizada a transformada Hilbert para detectar ATs e para extrair as características do sinal de tensão. Para classificá-los entre ATs causados por falta, partida de motor de indução e saturação de transformador é utilizada uma Rede Neural Probabilística (PNN). O método é comparado com um sistema baseado em Transformada Wavelet e Rede Neural Multicamadas (MLP). Os autores utilizaram dados simulados no MATLAB/Simulink para projetar e testar o método. O melhor desempenho de classificação foi obtido com Transformada Hilbert como extratora de características e PNN como classificador, obtendo uma média de acertos de 98,63%.

O método proposto na presente dissertação de mestrado (EOS para extrair características e MLP como classificador) mostrou desempenho superior, uma vez 99,56% dos dados foram classificados corretamente utilizando-se janelas de 1/2 ciclo do sinal de tensão. É importante ressaltar que o trabalho de Manjula, Mishra e Sarma (2013) não informou sobre o tamanho da janela analisada e nem sobre a presença de ruído ou outros distúrbios. Dessa forma, pode-se inferir também a vantagem do método proposto em relação ao tempo de resposta e robustez a outros distúrbios.

#### **4.5 Aplicações dos sistemas de detecção, segmentação e classificação de ATs**

O processo de detecção de distúrbios é o primeiro passo para mitigar distúrbios e avaliar a QEE do sistema. A detecção, classificação e localização dos afundamentos de tensão de forma rápida e *online* é muito importante para os sistemas de proteção para linhas de transmissão e distribuição, permitindo isolar somente a região afetada pelo evento o mais rápido possível e, evitando assim o efeito cascata e a propagação do distúrbio através do sistema. O método de detecção e classificação proposto neste trabalho se mostra muito promissor nesse sentido, uma vez que foi possível atingir resultados bons de detecção com janelas de 1/8 de ciclo e em tempo real, assim como a classificação das causas do evento

considerando janelas menores ou iguais a  $1/2$  ciclo. Tais características confirmam a rápida resposta do método e, considerando também a baixa complexidade computacional na fase de operação, faz com que o método seja promissor também para relés digitais.

Também em relação ao sistema de proteção, o método proposto pode ser usado para avaliar o sistema analisando bancos de dados já existentes e determinando se os casos de atuação dos relés de proteção são realmente necessários e condizentes com os eventos ocorridos.

A segmentação dos ATs permite separar trechos dos sinais elétricos com e sem a presença do distúrbio. Dessa forma, é possível gerar bancos de dados específicos e de menor tamanho para posteriores análises. Para determinados sistemas de classificação também é importante que se faça a segmentação precisa dos eventos. Para o método de classificação proposto, é importante que o início dos eventos seja corretamente detectado.

Outra aplicação importante do método proposto é em sistemas de compensação de ATs, uma vez que a detecção do evento é o primeiro passo para a compensação do afundamento, sendo que a velocidade de resposta do sistema de detecção é crítica para o desempenho dos métodos de compensação.

## 5 CONCLUSÃO E PERSPECTIVAS

Para projetar o sistema de detecção e segmentação de ATs, foram utilizadas as técnicas ICA e TLBO. O uso da ICA para este fim foi inovador e permitiu alcançar bons resultados de detecção e segmentação tanto para dados simulados quanto para dados reais. O método mostrou-se robusto à presença de outros distúrbios (harmônicos, *flicker* e variação da frequência fundamental). Outras duas vantagens importantes são a baixa complexidade computacional na fase de operação e a rápida resposta do método, permitindo a aplicação em tempo real, o que é muito interessante para sistemas de proteção.

Como desvantagem, o método mostrou ser afetado por ruído com SNR menor que 50 dB, porém, na prática, geralmente encontra-se ruído com SNR variando entre 50 db e 70 db. Além disso, o método é sensível a eventos de PMI e ST, justificando a necessidade de um sistema de classificação, se o objetivo for proteção.

Comparando o método proposto com outros métodos encontrados na literatura (baseados em transformada Wavelet e no valor RMS), confirmam-se as vantagens já mencionadas e superior desempenho alcançado pelo método proposto.

Os sistemas de classificação de ATs segundo suas três causas principais (falta, PMI e ST) foi feito através das técnicas EOS, discriminante linear de Fisher e TLBO para extrair e selecionar as características e SVM e MLP para classificar. As etapas de extração e seleção de características utilizaram técnicas inovadoras para o problema tratado, permitindo projetar classificadores com bom desempenho e com menos parâmetros de entrada, reduzindo a complexidade computacional. O custo computacional na fase operacional envolve somente o cálculo dos cumulantes selecionados e o processamento deles pelo classificador projetado.

O classificador SVM mostrou-se satisfatório apenas para janelas com 1 ciclo. Já o classificador MLP alcançou bons resultados para os quatro tamanhos de janelas testados (1, 1/2, 1/4 e 1/8 de ciclo). O classificador MLP foi testado também em casos com a presença de outros distúrbios (*flicker* e harmônicos), sendo que foi possível manter um bom desempenho para janelas com 1/2 ciclo. O pior caso foi a presença de harmônicos com THD acima do permitido pela norma.

Comparando o melhor classificador MLP projetado com outros métodos encontrados na literatura, verifica-se a superioridade do método proposto em relação às porcentagens de acerto e também em relação à velocidade de resposta, uma vez que bons resultados foram alcançados com janelas de 1/2 ciclo ou menores.

## 5.1 Perspectivas

Para realizar uma análise mais completa dos ATs, em trabalhos futuros pode-se estender o método para localizar onde a falta ocorreu dentro da rede e, principalmente, recuperar a amplitude do afundamento. Pode-se tentar recuperar a amplitude do AT utilizando a própria ICA ou utilizando outras técnicas. A localização da falta pode ser executada com técnicas de inteligência computacional.

Em relação à classificação, pode-se incluir outros eventos relacionados à variação de tensão, tais como chaveamento de capacitores, reaceleração de motores e energização. Investigações com outros tipos de classificadores também podem ser realizadas a fim de melhorar o desempenho e reduzir a complexidade.

O método de detecção e classificação mostrou-se bastante promissor, sendo que pode ser estendido para detectar outras variações transitórias no SEP, como é o caso da detecção de ilhamento em sistemas com geração distribuída abordada no trabalho de Mohanty et al. (2015). Nesse sentido, outra aplicação interessante é em sistemas de armazenamento de formas de onda para posterior reconstrução do sinal. Aplicando o método proposto para detectar novidades, é possível selecionar somente as partes mais importantes do sinal para posterior reconstrução, como discutido por Kapisch et al. (2016).

## REFERÊNCIAS

- ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: a definition. **Electric power systems research**, Elsevier, v. 57, n. 3, p. 195–204, 2001.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **PRODIST 641/2014**: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST. 6 ed. [S. l.], 2014. 75 p.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **SDR-0029/2011**: Revisão da Regulamentação sobre a Qualidade do Produto no Sistema de Distribuição de Energia Elétrica. Brasília, 2011. 41 p.
- ANDERSSON, T.; NILSSON, D. **Test and evaluation of voltage dip immunity**. Chalmers University of Technology, 2002.
- ARRILLAGA, J.; BOLLEN, M. H.; WATSON, N. R. Power quality following deregulation. **Proceedings of the IEEE**, IEEE, v. 88, n. 2, p. 246–261, 2000.
- ARRUDA, E. F. d. **Análise de distúrbios relacionados com a qualidade da energia elétrica utilizando a transformada Wavelet**. Tese (Doutorado) — Universidade de São Paulo, 2003.
- 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.
- BARKER, P. P.; MELLO, R. W. D. Determining the impact of distributed generation on power systems. i. radial distribution systems. In: IEEE. **Power Engineering Society Summer Meeting, 2000**. IEEE. [S.l.], 2000. v. 3, p. 1645–1656.
- BAYOD-RÚJULA, A. A. Future development of the electricity systems with distributed generation. **Energy**, Elsevier, v. 34, n. 3, p. 377–383, 2009.
- BELOUHRANI, A. et al. A blind source separation technique using second-order statistics. **IEEE Transactions on signal processing**, IEEE, v. 45, n. 2, p. 434–444, 1997.
- BOLLEN, M.; YANG, Y.; HASSAN, F. Integration of distributed generation in the power system—a power quality approach. In: IEEE. **Harmonics and Quality of Power, 2008. ICHQP 2008. 13th International Conference on**. [S.l.], 2008. p. 1–8.
- BOLLEN, M. H. Characterisation of voltage sags experienced by three-phase adjustable-speed drives. **IEEE Transactions on Power Delivery**, IEEE, v. 12, n. 4, p. 1666–1671, 1997.
- BOLLEN, M. H.; GU, I. **Signal processing of power quality disturbances**. [S.l.]: John Wiley & Sons, 2006. v. 30.
- BROWN, R. E. **Electric power distribution reliability**. [S.l.]: CRC press, 2008.
- CARDOSO, J.-F.; SOULOUMIAC, A. Blind beamforming for non-gaussian signals. In: IET.

**IEE proceedings F (radar and signal processing)**. [S.l.], 1993. v. 140, n. 6, p. 362–370.

CHICCO, G.; MANCARELLA, P. Distributed multi-generation: a comprehensive view. **Renewable and sustainable energy reviews**, Elsevier, v. 13, n. 3, p. 535–551, 2009.

DAVIES, M. E.; JAMES, C. J. Source separation using single channel ica. **Signal Processing**, Elsevier, v. 87, n. 8, p. 1819–1832, 2007.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. [S.l.]: John Wiley & Sons, 2012.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. Electromagnetic compatibility (EMC): Assessment of emission limits for the connection of distorting installations to MV, HV and EHV power systems. **IEC TR 61000-3-6: 2008**, 58 p. 2008.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. Electromagnetic compatibility (EMC): Testing and measurement techniques – Power quality measurement methods. **IEC 61000-4-30: 2015**, 146 p. 2015.

FARIED, S.; ABORESHAID, S. A monte carlo technique for the evaluation of voltage sags in series capacitor compensated radial distribution systems. In: IEEE. **Power Engineering 2002 Large Engineering Systems Conference on, LESCOPE 02**. [S.l.], 2002. p. 41–46.

FERREIRA, D. D. **Análise de Distúrbios Elétricos em Sistemas de Potência**. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2010.

FERREIRA, D. D. et al. Hos-based method for classification of power quality disturbances. **Electronics Letters, IET**, v. 45, n. 3, p. 183–185, 2009.

FERREIRA, D. D. et al. Ica-based method for quantifying EEG event-related desynchronization. In: SPRINGER. **International Conference on Independent Component Analysis and Signal Separation**. [S.l.], 2009. p. 403–410.

FERREIRA, D. D. et al. Independent component analysis-based method for electroencephalogram analysis during photic stimulation. **Journal of neuroscience methods**, Elsevier, v. 235, p. 252–261, 2014.

FERREIRA, D. D. et al. Method based on independent component analysis for harmonic extraction from power system signals. **Electric Power Systems Research**, Elsevier, v. 119, p. 19–24, 2015.

FERREIRA, D. D. et al. Extracting the transient events from power system signals by independent component analysis. **International Transactions on Electrical Energy Systems**, Wiley Online Library, v. 26, n. 4, p. 884–900, 2016.

FERREIRA, D. D.; SEIXAS, J. M. de; CERQUEIRA, A. S. Ica-based method for power quality disturbance analysis. In: IEEE. **Intelligent System Applications to Power Systems, 2009. ISAP'09. 15th International Conference on**. [S.l.], 2009. p. 1–6.

FOROUGH, A.; MOHAMMADI, E.; ESMAEILI, S. Application of hilbert–huang transform

and support vector machine for detection and classification of voltage sag sources. **Turkish Journal of Electrical Engineering & Computer Sciences**, The Scientific and Technological Research Council of Turkey, v. 22, n. 5, p. 1116–1129, 2014.

GARDNER, M. W.; DORLING, S. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric environment**, Elsevier, v. 32, n. 14, p. 2627–2636, 1998.

GARGOOM, A. M.; ERTUGRUL, N.; SOONG, W. L. Automatic classification and characterization of power quality events. **IEEE Transactions on Power Delivery**, IEEE, v. 23, n. 4, p. 2417–2425, 2008.

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

GU, I. Y.-H.; STYVAKTAKIS, E. Bridge the gap: signal processing for power quality applications. **Electric Power Systems Research**, Elsevier, v. 66, n. 1, p. 83–96, 2003.

GUEDES, J. D.; FERREIRA, D. D.; BARBOSA, B. H. A non-intrusive approach to classify electrical appliances based on higher-order statistics and genetic algorithm: a smart grid perspective. **Electric Power Systems Research**, Elsevier, v. 140, p. 65–69, 2016.

HAYKIN, S. S. et al. **Neural networks and learning machines**. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. v. 3.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural networks**, Elsevier, v. 2, n. 5, p. 359–366, 1989.

HYVÄRINEN, A.; INKI, M. Estimating overcomplete independent component bases for image windows. **Journal of Mathematical Imaging and Vision**, Springer, v. 17, n. 2, p. 139–152, 2002.

HYVÄRINEN, A.; KARHUNEN, J.; OJA, E. **Independent component analysis**. [S.l.]: John Wiley & Sons, 2004. v. 46.

IBRAHIM, W. A.; MORCOS, M. M. Artificial intelligence and advanced mathematical tools for power quality applications: a survey. **IEEE Transactions on Power Delivery**, IEEE, v. 17, n. 2, p. 668–673, 2002.

IEEE Recommended Practice for Monitoring Electric Power Quality. **IEEE Std 1159-2009 (Revision of IEEE Std 1159-1995)**, p. c1–81, June 2009.

ISMAIL, H.; ZAKARIA, Z.; HAMZAH, N. Classification of voltage sag using multi-resolution analysis and support vector machine. **Journal of Clean Energy Technologies**, v. 4, n. 3, 2016.

JAMES, C. J.; WANG, S. Blind source separation in single-channel eeg analysis: An application to bci. In: **Proc. 28th Annu. Int. Conf. IEEE Engineering in Medicine and Biology Society**. [S.l.: s.n.], 2006. p. 6544–6547.

KAPISCH, E. B. et al. A gapless waveform recorder for monitoring smart grids. In: IEEE.

**Harmonics and Quality of Power (ICHQP), 2016 17th International Conference on.** [S.l.], 2016. p. 130–136.

KEZUNOVIC, M.; LIAO, Y. A new method for classification and characterization of voltage sags. **Electric Power Systems Research**, Elsevier, v. 58, n. 1, p. 27–35, 2001.

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.

LIM, P. K.; DORR, D. S. Understanding and resolving voltage sag related problems for sensitive industrial customers. In: **IEEE. Power Engineering Society Winter Meeting, 2000. IEEE.** [S.l.], 2000. v. 4, p. 2886–2890.

LIZIERI, C.; SATCHELL, S.; ZHANG, Q. The underlying return-generating factors for reit returns: An application of independent component analysis. **Real Estate Economics**, Wiley Online Library, v. 35, n. 4, p. 569–598, 2007.

MAHELA, O. P.; SHAIK, A. G.; GUPTA, N. A critical review of detection and classification of power quality events. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 41, p. 495–505, 2015.

MANJULA, M.; MISHRA, S.; SARMA, A. Empirical mode decomposition with hilbert transform for classification of voltage sag causes using probabilistic neural network. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 44, n. 1, p. 597–603, 2013.

MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. **Proceedings of the IEEE**, Ieee, v. 79, n. 3, p. 278–305, 1991.

MOHANTY, S. R. et al. Comparative study of advanced signal processing techniques for islanding detection in a hybrid distributed generation system. **IEEE Transactions on sustainable Energy**, IEEE, v. 6, n. 1, p. 122–131, 2015.

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**, Elsevier, v. 6, n. 4, p. 525–533, 1993.

MORÉ, J. J. The levenberg-marquardt algorithm: implementation and theory. In: **Numerical analysis.** [S.l.]: Springer, 1978. p. 105–116.

MORENO, I. et al. Causal and anti-causal segmentation of voltage dips in power distribution networks. **IEEE Latin America Transactions**, IEEE, v. 14, n. 7, p. 3080–3086, 2016.

MORENO-MUNOZ, A. et al. Improvement of power quality using distributed generation. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 32, n. 10, p. 1069–1076, 2010.

MORSI, W. G.; EL-HAWARY, M. A new perspective for the iec standard 1459-2000 via stationary wavelet transform in the presence of nonstationary power quality disturbance.

**IEEE Transactions on Power Delivery**, IEEE, v. 23, n. 4, p. 2356–2365, 2008.

OJA, E.; YUAN, Z. The fastica algorithm revisited: Convergence analysis. **IEEE Transactions on Neural Networks**, IEEE, v. 17, n. 6, p. 1370–1381, 2006.

PEPERMANS, G. et al. Distributed generation: definition, benefits and issues. **Energy policy**, Elsevier, v. 33, n. 6, p. 787–798, 2005.

RAO, R. V.; SAVSANI, V.J.; VAKHARIA, D. Teaching–learning-based optimization: a novel method for constrained mechanical design optimization problems. **Computer-Aided Design**, Elsevier, v. 43, n. 3, p. 303–315, 2011.

RIBEIRO, M. et al. Power quality disturbances detection using hos. In: IEEE. **Power Engineering Society General Meeting, 2006. IEEE**. [S.l.], 2006. p. 6–pp.

RIBEIRO, M. V.; PEREIRA, J. L. R. Classification of single and multiple disturbances in electric signals. **EURASIP Journal on Advances in Signal Processing**, Hindawi Publishing Corp., v. 2007, n. 2, p. 15–15, 2007.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The rprop algorithm. In: IEEE. **Neural Networks, 1993, IEEE International Conference on**. [S.l.], 1993. p. 586–591.

ROSENBLATT, F. **Principles of neurodynamics**. [S. l.]: Spartan Book, New York, 1962.

SADIGH, A. K.; SMEDLEY, K. Fast and precise voltage sag detection method for dynamic voltage restorer (dvr) application. **Electric Power Systems Research**, Elsevier, v. 130, p. 192–207, 2016.

SAINI, M. K.; KAPOOR, R. Classification of power quality events—a review. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 43, n. 1, p. 11–19, 2012.

SEDIGHNEJAD, H.; JALILIAN, A. Effect of protection device coordination on voltage sag characteristics of distribution networks. **ISA transactions**, Elsevier, v. 49, n. 4, p. 407–414, 2010.

STYVAKTAKIS, E.; BOLLEN, M. H. Signatures of voltage dips: transformer saturation and multistage dips. **IEEE Transactions on power delivery**, IEEE, v. 18, n. 1, p. 265–270, 2003.

STYVAKTAKIS, E.; BOLLEN, M. H.; GU, I. Y. Expert system for classification and analysis of power system events. **IEEE Transactions on Power Delivery**, IEEE, v. 17, n. 2, p. 423–428, 2002.

TEKE, A.; BAYINDIR, K.; TÜMAY, M. Fast sag/swell detection method for fuzzy logic controlled dynamic voltage restorer. **IET generation, transmission & distribution**, IET, v. 4, n. 1, p. 1–12, 2010.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. Fourth edition. Boston: Academic Press, 2009.

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.

TONG, L. et al. Indeterminacy and identifiability of blind identification. **IEEE Transactions on circuits and systems**, IEEE, v. 38, n. 5, p. 499–509, 1991.

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

VENAYAGAMOORTHY, G. K. Potentials and promises of computational intelligence for smart grids. In: IEEE. **Power & Energy Society General Meeting, 2009. PES'09. IEEE**. [S.l.], 2009. p. 1–6.

WANG, Y.; BOLLEN, M. H.; XIAO, X.-Y. Calculation of the phase-angle-jump for voltage dips in three-phase systems. **IEEE Transactions on Power Delivery**, IEEE, v. 30, n. 1, p. 480–487, 2015.

## APÊNDICE A – REDES NEURAIS ARTIFICIAIS

Uma Rede Neural Artificial (RNA) pode ser definida como um processador paralelamente distribuído contendo várias unidades de processamento simples (neurônios) conectadas através de pesos, capaz de aprender e armazenar conhecimento. Tais características justificam sua semelhança ao cérebro humano (HAYKIN, 2009).

De acordo com Haykin (2009), as principais características das RNAs são: capacidade de lidar com comportamento não linear, aprendizagem através do mapeamento da relação entrada-saída, adaptabilidade a variações do sistema, capacidade de generalização com pouco conhecimento estatístico prévio do sistema e tolerância a falhas (computação robusta).


Dentre as várias arquiteturas de RNAs, as redes com alimentação direta e múltiplas camadas são as mais utilizadas em problemas de reconhecimento de padrões. Essas redes são geralmente conhecidas como perceptrons de múltiplas camadas (MLP – *Multilayer Perceptron*) (ROSEMBLAT, 1962). Segundo Gardner e Dorlin (1998), uma MLP consiste de um sistema interconectado de neurônios tal como ilustrado na Figura A.1, podendo ter uma ou mais camadas escondidas. Os neurônios são conectados por pesos e a saída de cada um é resultado da soma das entradas do neurônio modificadas por uma função de ativação não-linear. A saída do neurônio é então multiplicada pelo peso conectando ao próximo neurônio da próxima camada, tendo a característica de propagação sempre para frente, para a próxima camada, o que faz essa rede também ser conhecida como rede neural *feed-forward*.

Através da seleção adequada dos pesos, funções de ativação e número de neurônios, a MLP pode aproximar qualquer função mensurável (HORNIK; STINCHCOMBE; WHITE, 1989). A escolha desses parâmetros é feita através do treinamento da rede, que consiste em apresentar repetidas vezes o conjunto de dados de treinamento à rede para que os pesos possam ser ajustados até que o mapeamento desejado entre a entrada e saída seja atingido. Esse treinamento é supervisionado, ou seja, a resposta da rede é comparada com a resposta ideal conhecida, de tal forma a gerar um erro que é utilizado no processo de treinamento (GARDNER; DORLING, 1998).

Dentre os algoritmos de treinamento de redes neurais, um dos mais populares é o algoritmo de retropropagação do erro, conhecido como *back-propagation* (HAYKIN, 2009). Alguns exemplos de outros algoritmos de treinamento são: *Levenberg-Marquardt* (MORÉ, 1978), *Resilient Backpropagation* (RIEDMILLER; BRAUN, 1993), *Scaled Conjugate Gradient* (MØLLER, 1993). A escolha do melhor algoritmo de treinamento vai depender do tipo de problema, uma vez que uma MLP pode ser aplicada para tarefas de predição,

aproximação de funções ou classificação de padrões. Além disso, é importante considerar também as características de cada problema.

Figura A.1 – Estrutura de uma rede do tipo perceptron de múltiplas camadas (MLP).



## APÊNDICE B – MÁQUINA DE VETOR DE SUPORTE (SVM)

Máquina de vetor de suporte (SVM – *Support Vector Machine*) é um método supervisionado de aprendizado utilizado em problemas de reconhecimento de padrões e análise de regressão (VAPNIK; VAPNIK, 1998). O SVM padrão é utilizado em problemas de duas classes, de tal forma a encontrar a fronteira de decisão entre elas que minimiza o erro de classificação (ISMAIL; ZAKARIA; HAMZAH, 2016).

Considerando um conjunto de dados de treinamento  $(x_1, y_1), \dots, (x_n, y_n), x \in R^M$ , em que  $x_i$  é a  $i$ -ésima característica apresentada ao método e  $y_i \in \{-1, 1\}$  é o  $i$ -ésimo rótulo de classe para o respectivo dado (para um problema de duas classes), o SVM constrói a fronteira de decisão  $g(x)$ . Essa fronteira pode ser encontrada por funções de ativação linear, sigmoideal, radial ou polinomial. Considerando o caso linear, o hiperplano de separação pode ser dado por:

$$g(x) = w^T x + b, \quad (\text{B1})$$

em que  $w^T$  é o vetor de pesos ótimo e  $b$  é o bias.

A fronteira de decisão  $g(x)$  é ótima quando a margem de separação entre as duas classes é maximizada. Para atingir esse objetivo, considera-se o seguinte problema de minimização:

$$\min \frac{1}{2} w^T w, \quad (\text{B2})$$

sujeito a:

$$d_i(w^T x_i + b) \geq 1. \quad (\text{B3})$$

Esse problema é equivalente a minimizar a seguinte função de Lagrange:

$$J\{w, b, \alpha\} = \frac{1}{2} (w^T w) - \sum_{i=1}^p \alpha_i [d_i(w^T x_i + b) - 1], \quad (\text{B4})$$

em que  $\alpha_i$  são multiplicadores de Lagrange diferentes de zero.

Tal função objetivo é válida se duas classes são linearmente distribuídas. Caso elas tenham distribuição não linear, a seguinte função objetivo deve ser considerada:

$$\min \frac{1}{2} w^T w + C \sum_{i=1}^p \xi_i, \quad (\text{B5})$$

sujeito a:

$$\begin{aligned} \xi_i &> 0 \\ d_i(w^T \phi(x_i) + b) &\geq 1 - \xi_i, \end{aligned}$$

em que  $\xi_i$  são as variáveis de folga utilizadas para permitir que alguns dados fiquem dentro da margem e  $C$  é a fronteira superior de  $\alpha$ , utilizada para ajustar os erros de treinamento.

O vetor  $x_i$  é mapeado em um espaço de alta dimensão dados pela função  $\phi$ . A função *kernel* é definida como:

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j). \quad (\text{B6})$$

Podem ser utilizadas três tipos de funções kernel:

a) *Kernel* Linear:

$$K(x_i, y_i) = x_i^T x_j \quad (\text{B7})$$

b) *Kernel* polinomial:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0 \quad (\text{B8})$$

c) *Kernel* de função de base radial:

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right), \gamma > 0, \quad (\text{B9})$$

em que  $r$ ,  $d$  e  $\gamma$  são parâmetros do kernel.

Assim, pela função *kernel* é possível transformar o espaço de entradas em um espaço de parâmetros de alta dimensão (FOROUGHI; MOHAMMADI; ESMAEILI, 2014).

Para aplicar o SVM em problemas com mais de uma classe existem algumas abordagens, sendo as duas principais: um contra todos e um contra um. Na abordagem um contra todos, são projetados classificadores para cada classe considerando as outras classes como uma só. Já na um contra um, são projetados classificadores para pares de classes, de tal forma que a classificação é feita de acordo com a maior quantidade de votos para uma classe (THEODORIDIS; KOUTROUMBAS, 2009).

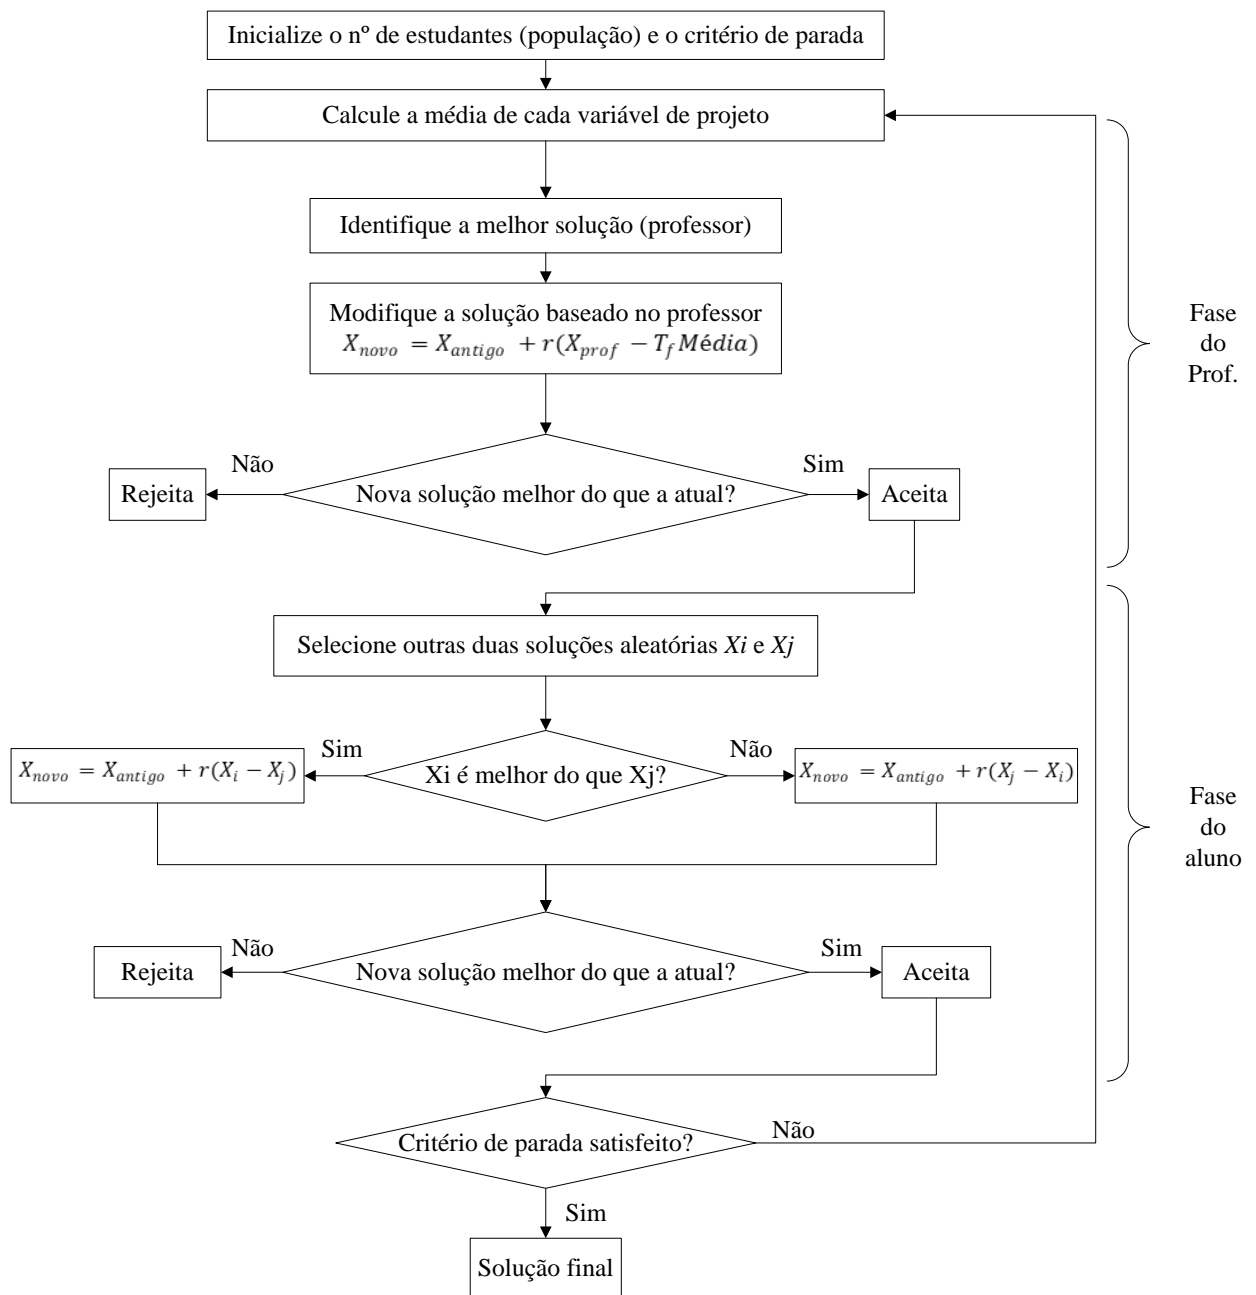
## APÊNDICE C – TEACHING-LEARNING-BASED OPTIMIZATION (TLBO)

O algoritmo de otimização *Teaching-learning-based optimization* (TLBO) (RAO; SAVSANI; VAKHARIA, 2011) é uma metaheurística baseada em população. Para procurar pela solução ótima, o método utiliza uma população composta de alunos e um professor, inspirando-se no sistema de aprendizado dentro de uma sala de aula. Sua execução é dividida em duas fases: a fase de professor, em que ele passa seus conhecimentos para os alunos e a fase do aluno, em que os alunos aumentam seus conhecimentos pela interação entre eles. A melhor solução em cada iteração é representada pelo professor, sendo que se algum aluno tiver avaliação melhor do que o professor, então esse aluno passa a ser o novo professor.

O fluxograma da execução do algoritmo é mostrado na Figura C.1. O cálculo das constantes presentes no fluxograma, assim como os detalhes de cada passo podem ser encontrados em Rao, Savsani e Vakharia (2011).

As vantagens do TLBO em relação a outras metaheurísticas são a menor quantidade de avaliações da função custo e os poucos parâmetros necessários de inicialização (somente o tamanho da população e quantidade de iterações) (RAO; SAVSANI; VAKHARIA, 2011).

Figura C.1 – Fluxograma de execução do TLBO.



## APÊNDICE D – ESTATÍSTICAS DE ORDEM SUPERIOR (EOS)

As EOS são definidas em termo de momentos ou cumulantes, sendo utilizadas nas mais diversas áreas, tais como biomedicina, processamento de dados sísmicos, reconstrução de imagens, estimação de atraso temporal, filtros adaptativos, entre outras. O termo momento é mais recomendado para sinais determinísticos, enquanto que cumulantes se adequam mais a sinais aleatórios. Considerando as características não lineares dos distúrbios elétricos, os cumulantes são mais indicados para serem usados como extratores de características. As expressões dos cumulantes de segunda, terceira e quarta ordem de um sinal aleatório  $x[n]$ , quando  $E\{x\} = 0$ , são, respectivamente (MENDEL, 1991):

$$c_{2,x}[i] = E\{x[n]x[n+i]\}, \quad (D1)$$

$$c_{3,x}[i] = E\{x[n]x^2[n+i]\}, \quad (D2)$$

$$c_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3c_{2,x}[i]c_{2,x}[0], \quad (D3)$$

em que  $i$  é o  $i$ -ésimo atraso e  $x[n]$  é o  $n$ -ésimo elemento do vetor  $x$ .

Considerando um vetor com comprimento finito ( $N$ ), as devidas aproximações estocásticas e utilizando uma abordagem alternativa apresentada por Ribeiro et al. (2006), é possível calcular os cumulantes utilizando todas as  $N$  amostras de sinal disponível. Nessa abordagem é como se houvesse continuidade entre a última e a primeira amostra, formando um *buffer* circular nos sinais, transformando-os em virtualmente circular. Matematicamente, isso pode ser feito substituindo  $n+i$  nas equações pelo resto inteiro da divisão entre  $n+i$  e  $N$ , representado pela expressão  $\text{mod}(n+i, N)$ . Assim, as expressões para o cálculo dos cumulantes ficam definidas por:

$$\hat{c}_{2,x}[i] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n+i, N]], \quad (D4)$$

$$\hat{c}_{3,x}[i] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}[n+i, N]], \quad (D5)$$

$$\hat{c}_{4,x}[i] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}[n+i, N]] - \frac{1}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n+i, N]] \sum_{n=0}^{N-1} x^2[n] \quad (D6)$$

## APÊNDICE E – DISCRIMINANTE LINEAR DE FISHER

O discriminante linear de Fisher é uma técnica simples para discriminação de dados multidimensionais que pode ser utilizado como classificador ou como ferramenta de seleção de parâmetros (DUDA; HART; STORK, 2012). Se utilizado como seletor de parâmetros, o discriminante linear de Fisher é capaz de reduzir o número de parâmetros do problema, reduzindo a complexidade computacional e levando a projetos de classificadores mais simples e com melhor desempenho. Neste trabalho, essa técnica é utilizada para selecionar os parâmetros que melhor caracterizam os sinais elétricos analisados, servindo de inicialização do algoritmo TLBO.

A função custo para aplicar o discriminante linear de Fisher como seletor de parâmetros é dada por (THEODORIDIS; KOUTROUMBAS, 2009):

$$J_c = \sum_i^M \sum_{j \neq i}^M \frac{(\mu_i - \mu_j)^2}{\sigma_i^2 + \sigma_j^2}, \quad (E1)$$

em que  $J_c = [J_1 \dots J_l]^T$ ,  $l$  é o número total de parâmetros; os termos  $i$  e  $j$  são referentes às médias ( $\mu$ ) e variâncias ( $\sigma$ ) correspondentes às características sob investigação das classes  $w_i$  e  $w_j$  respectivamente. Os  $i$ -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de  $J_c$ , representam os parâmetros com melhor separabilidade entre classes.

Assim como as Estatísticas de Ordem Superior, vários trabalhos já aplicaram o discriminante linear de Fisher na área de reconhecimento de padrões em QEE e obtiveram sucesso em suas análises (FERREIRA, 2010; FERREIRA et al, 2009a; FERREIRA; SEIXAS; CERQUEIRA, 2015).

## APÊNDICE F – LISTA DE PUBLICAÇÕES

Através desse projeto de mestrado, foi possível publicar os seguintes artigos completos em periódico, conferência internacional e conferências nacionais:

- NAGATA, E. A. et al. Voltage sag and swell detection and segmentation based on Independent Component Analysis. **Electric Power Systems Research**, v. 155, p. 274-280, 2018.
- NAGATA, E. A.; FERREIRA, D. D.; DUQUE, C. A. ICA-based method for power quality disturbance detection. In: **Harmonics and Quality of Power (ICHQP), 2016 17th International Conference on**. IEEE, 2016. p. 412-417.
- NAGATA, E. A. et al. Método de Classificação de Afundamentos de Tensão em Rede com Geração Distribuída. **XII Conferência Brasileira sobre Qualidade de Energia Elétrica (CBQEE 2017)**. Curitiba, PR, 2017.
- NAGATA, E. A. et al. Método de Detecção de Sag e Swell Baseado em Análise de Componentes Independentes. **XXI Congresso Brasileiro de Automática (CBA 2016)**. Vitória, ES, 2016.