



Universidade de Brasília - UnB  
Faculdade UnB Gama - FGA  
Engenharia Eletrônica

**Identificação de atributos e classificação de  
distúrbios da qualidade de energia elétrica  
baseada em métodos de análise de dados,  
processamento de sinais e rede neural.**

Autor: Antônio Aldísio de Sousa Alves Ferreira Filho  
Orientador: Prof. Jorge Andrés Cormane Angarita

Brasília, DF  
2020



Antônio Aldísio de Sousa Alves Ferreira Filho

**Identificação de atributos e classificação de distúrbios da  
qualidade de energia elétrica baseada em métodos de  
análise de dados, processamento de sinais e rede neural.**

Monografia submetida ao curso de graduação  
em Engenharia Eletrônica da Universidade de  
Brasília, como requisito parcial para obten-  
ção do Título de Bacharel em Engenharia  
Eletrônica.

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Prof. Jorge Andrés Cormane Angarita

Brasília, DF

2020

---

Antônio Aldísio de Sousa Alves Ferreira Filho

Identificação de atributos e classificação de distúrbios da qualidade de energia elétrica baseada em métodos de análise de dados, processamento de sinais e rede neural./ Antônio Aldísio de Sousa Alves Ferreira Filho. – Brasília, DF, 2020-58 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Jorge Andrés Cormane Angarita

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB  
Faculdade UnB Gama - FGA , 2020.

1. qualidade da energia elétrica. 2. Detecção e classificação. I. Prof. Jorge Andrés Cormane Angarita. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Identificação de atributos e classificação de distúrbios da qualidade de energia elétrica baseada em métodos de análise de dados, processamento de sinais e rede neural.

CDU 02:141:005.6

---

Antônio Aldísio de Sousa Alves Ferreira Filho

# **Identificação de atributos e classificação de distúrbios da qualidade de energia elétrica baseada em métodos de análise de dados, processamento de sinais e rede neural.**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Trabalho aprovado. Brasília, DF, 15 de Dezembro de 2020:

---

**Prof. Jorge Andrés Cormane Angarita**  
Orientador

---

**Prof. Dr. Marcus Vinícius Chaffim  
Costa**  
Convidado 1

---

**Prof. Dr. Diogo Caetano Garcia**  
Convidado 2

Brasília, DF  
2020

*Este trabalho é dedicado ao meu falecido pai, a minha maravilhosa mãe, a minha amável namorada e a todos que contribuíram para desenvolvimento desse trabalho.*

# Agradecimentos

Primeiramente agradeço a Deus pela oportunidade da vida, em segundo aos meus pais que sempre me aconselharam e apoiaram as minhas escolhas e a minha namorada que acompanhou o desenvolvimento desse trabalho ao meu lado. Também agradeço a oportunidade dada pelo meu orientador, das reuniões realizadas semanalmente e algumas broncas recebidas. Além disso, agradeço a todos os funcionários da Universidade de Brasília que de alguma forma possibilitaram o caminhar desse trabalho, meus amigos de graduação que estavam sempre ao meu lado e claro, não poderia deixar de lembrar, de todos os professores que passaram na minha vida, que contribuíram para a construção do conhecimento ao longo dessa jornada.

**Não entre em pânico.**

*Guia Mochileiro da Galáxia - Douglas Adams*

# Resumo

Não é novidade que a energia elétrica se tornou, nas últimas décadas, um elemento indispensável para a sociedade e essencial para a industrialização. É notável que, com o avanço da tecnologia e com a demanda exigida pela sociedade e pela indústria, a exigência por qualidade de energia elétrica vem aumentando. Desse modo, faz-se necessário o desenvolvimento de ferramentas capazes de realizar a detecção e classificação de distúrbios de energia elétrica. Este trabalho desenvolve a identificação de atributos (histogramas, estimativa de densidade kernel, estimadores estatísticos de ordem superior e transformada *space phasor model*) e a classificação de anomalias de rede elétrica através de rede neurais *feedforward* de múltiplas camadas. A detecção dar-se-á, primeiramente, com a segmentação do sinal em meio ciclo (126 amostras) para aplicação das técnicas de histograma e estimativa de densidade kernel, e um ciclo (256 amostras) para utilização das técnicas estimadores estatísticos de ordem superior e transformada *space phasor model*. A classificação ocorre com os atributos- número de classe, largura de banda, variância, assimetria, curtose e valor máximo e mínimo do eixo real - retirados das técnicas supracitadas. Os resultados obtidos demonstram a capacidade do algoritmo em classificar a operação normal do sinal e os distúrbios - *sag*, *swell*, harmônico e oscilação transiente- com eficiência global de 96% rede neural. Observando cada distúrbio individualmente nas etapas de treinamento e teste tivemos a eficiência, respectivamente, de 60.7 % e 64.9 % para *sag*, 98.1% e 98.2% para *swell*, 98.1% e 98.2% para harmônico, 88.1% e 83.3% para oscilação transiente e 98.7% e 98.2% para operação normal. Por fim, baseado em estudo comparativo com outros trabalhos semelhantes, nota-se resultados similares ao deste trabalho, no que tange a classificação de distúrbios de energia elétrica, com ressalva para os resultados obtidos com os distúrbios *sag* e harmônico, visto que o *sag* apresentou um resultado inferior.

**Palavras-chaves:** Qualidade de energia elétrica. Detecção. Classificação. Histograma. Estimativa de densidade kernel. Estatísticos de ordem superior. Transformada *space phasor model*. Rede neurais artificiais.

# Abstract

It is not new that electric energy has become, in recent decades, an indispensable element for society and essential for industrialization. It is noteworthy that, with the advancement of technology and the demand demanded by society and industry, the demand for quality of electric power has increased. Thus, it is necessary to develop tools capable of detecting and classifying electrical energy disorders. This competent work is the identification of attributes (histograms, kernel density estimation, higher and transformed statistical estimators *spatial phasor model*) and the classification of electrical network anomalies through multilayer neural networks *feedforward* . The detection will take place, with priority, with the application of the signal in half cycle (126) to apply the histogram and kernel density estimation techniques, and one cycle (256) to use the higher and transformed statistical estimation techniques. *spatial phasor model*. The classification occurs with the attributes - class number, bandwidth, variance, asymmetry, kurtosis and maximum and minimum value of the real axis - taken from the aforementioned techniques. The results obtained demonstrate an ability of the algorithm to classify a normal operation of the signal and the disturbances - *sag*, *swell*, harmonic and transient oscillation- with a global efficiency of 96% neural network. Observing each individual disturbance in the training and efficiency testing steps, respectively, from 60.7% and 64.9% for *sag*, 98.1% and 98.2% for *swell* , 98.1% and 98.2% for harmonic, 88.1% and 83.3% for transient oscillation and 98.7% and 98.2 % for normal operation. Finally, based on a comparative study with other similar works, we note results similar to this work, regarding the classification of electrical energy disorders, with the exception of the results obtained with the disturbances *sag* eonic damage, seen that *sag* had an inferior result.

**Key-words:** Electric power quality. Detection. Classification. Histogram. Kernel density estimation. Higher order statistics. Transform space phasor model. Artificial neural networks.

# Lista de ilustrações

Figura 1 – Distúrbio oscilação transiente . . . . .	20
Figura 2 – Distúrbio afundamento de tensão . . . . .	21
Figura 3 – Distúrbio elevação de tensão . . . . .	21
Figura 4 – Distúrbio harmônico . . . . .	23
Figura 5 – Divisão dos métodos de estimação de densidade de probabilidade . . . . .	24
Figura 6 – Histograma de um distúrbio harmônico com largura $L = 0.1$ . . . . .	25
Figura 7 – Histograma de um distúrbio harmônico com largura $L = 0.01$ . . . . .	26
Figura 8 – Histograma de um distúrbio harmônico com largura $L = 1$ . . . . .	26
Figura 9 – Comportamento das diferentes larguras de banda. . . . .	28
Figura 10 – Distribuição assimétrica negativa. . . . .	29
Figura 11 – Distribuição assimétrica positiva. . . . .	30
Figura 12 – Distribuição Platicúrticas, Mesocúrticas e Leptocúrticas . . . . .	31
Figura 13 – Transformada SPM aplicada em uma senoide ideal . . . . .	32
Figura 14 – Modelo não-linear de um neurônio. Fonte: (HAYKIN, 2011). . . . .	33
Figura 15 – Rede PMC. Fonte: (SILVA; FLAUZINO; SPATTI, 2019) . . . . .	35
Figura 16 – Duas fases de treinamento da rede PMC . . . . .	36
Figura 17 – Fluxograma da pesquisa . . . . .	38
Figura 18 – Formas de onda do distúrbio de tensão (Evento 4554). . . . .	41
Figura 19 – Formas de onda do distúrbio de tensão da fase c (Evento 4554). . . . .	42
Figura 20 – Extração de características por histogramas e estimativa de densidade kernel de diferentes distúrbios . . . . .	43
Figura 21 – Extração de características por estimadores estatísticos de ordem su- perior e a transformada SPM de diferentes distúrbios . . . . .	45
Figura 22 – Performance da melhor rede neural . . . . .	48
Figura 23 – Relação entre amplitude e variância para os distúrbios <i>sag</i> e <i>swell</i> . . . . .	51
Figura 24 – Relação entre amplitude e largura de banda para os distúrbios <i>sag</i> e <i>swell</i> . . . . .	51

# Lista de tabelas

Tabela 1 – Padrões de distúrbios. Fonte: (IEEE, 1993) . . . . .	19
Tabela 2 – Modelo teórico dos distúrbios elétricos. Adaptado de (ABDEL-GALIL et al., 2004) e (LIMA, 2015) . . . . .	40
Tabela 3 – Descrição dos registros oscilográficos de tensão utilizados. . . . .	41
Tabela 4 – Conjunto de treinamento, validação e teste . . . . .	46
Tabela 5 – Parâmetros dos distúrbios . . . . .	47
Tabela 6 – Resultado do treinamento da rede . . . . .	49
Tabela 7 – Resultado do validação da rede . . . . .	49
Tabela 8 – Resultado do teste da rede . . . . .	49
Tabela 9 – Resultados de classificação correta para cada distúrbio nas etapas treinamento, validação e teste (%) . . . . .	49
Tabela 10 – Comparação de desempenho em termos de porcentagem de resultados de classificação correta (%) . . . . .	49

# Lista de abreviaturas e siglas

EOS - Estimadores estatístico de ordem superior;

FDP - Função de densidade de probabilidade;

IEEE - Instituto de Engenheiros Eletricistas e Eletrônicos

PCM - *perceptron* multicamadas;

P.U - por unidade;

SPM - modelo fasorial espacial *space fasor model*;

QEE - Qualidade de energia elétrica;

RNA - Rede neurais artificiais;

# Lista de símbolos

$A$	Amplitude
$n$	Ordem
$a_L$	Acumulador associado à classe $C_L$
$C_L$	Classe associada à largura
$L$	Largura
$k$	Número total de classe
$S_{Real}$	Matriz de atributos de um sinal real;
$S_{Sintético}$	Matriz de atributos de um sinal sintético;
$K$	Coefficiente de curtose
$h$	largura de banda
$E$	Esperança
$\mu_2$	Segundo momento
$\mu_3$	Terceiro momento
$\mu_4$	Quarto momento
$S$	Coefficiente da assimetria
$M$	Matriz de base da transformada de Clack.
$y_k$	Saída da rede neural
$S_t$	Resultado da transformada SPM
$T$	Matriz dos valores reais e valores imaginários do resultado da transformada SPM
$h_{normal}$	Largura de banda do kernel normal
$w_k$	Peso simpático
$b_k$	Bias
$\nabla$	derivada parcial em relação ao peso simpático

$\ddot{y}$	Resultado esperado da saída da rede neural
$X_c$	Vetor de segmentação do sinal em um ciclo
$X_m$	Vetor de segmentação do sinal em meio ciclo
$V_a$	Tensão a
$V_b$	Tensão b
$V_c$	Tensão c

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Motivação	16
1.2	Justificativa	17
1.3	Objetivo Geral	17
1.3.1	Objetivo específico	17
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>18</b>
<b>2.1</b>	<b>Qualidade de Energia Elétrica</b>	<b>18</b>
2.1.1	Classificações distúrbios da qualidade de energia elétrica	19
2.1.1.1	Transitórios	20
2.1.1.2	Variações de curta duração	20
2.1.1.3	Variação de longa duração	22
2.1.1.4	Desequilíbrio	22
2.1.1.5	Distorções da Onda	22
2.1.1.6	Flutuação de tensão	23
2.1.1.7	Variação da frequência	23
<b>2.2</b>	<b>Função de Densidade de Probabilidade (FDP)</b>	<b>23</b>
2.2.1	Histograma	24
2.2.2	Estimativa de densidade por kernel	26
<b>2.3</b>	<b>Estimadores estatísticos de ordem superior (EOS)</b>	<b>27</b>
2.3.1	Segundo momento - Variância	28
2.3.2	Terceiro momento - Assimetria	29
2.3.3	Quarto momento - Curtose	30
<b>2.4</b>	<b>Transformada <i>Space phasor model</i></b>	<b>31</b>
<b>2.5</b>	<b>Redes neurais artificiais</b>	<b>32</b>
2.5.1	Redes <i>perceptron</i> multicamadas	35
2.5.1.1	Processo de treinamento de PMC	35
<b>3</b>	<b>METODOLOGIA</b>	<b>38</b>
3.1	Fluxograma Geral da Pesquisa	38
3.2	Base de dados sintéticos	39
3.3	Base de dados de sinais de distúrbios reais	40
3.4	Identificação dos atributos	41
3.5	Treinamento, Validação e Teste	44
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>47</b>

4.1	Resultados . . . . .	47
4.2	Discussões . . . . .	50
5	CONCLUSÃO . . . . .	52
5.1	Proposta de melhorias e trabalhos futuros . . . . .	52
	REFERÊNCIAS . . . . .	54
	ANEXOS	57
	ANEXO A – PSEUDOCÓDIGO . . . . .	58

# 1 Introdução

Não é novidade que a energia elétrica se tornou, nas últimas décadas, um elemento indispensável para a sociedade e essencial para a industrialização. É notável que, com o desenvolvimento da tecnologia e com a demanda exigida pela sociedade e pela indústria, a exigência por qualidade de energia elétrica (QEE) vem aumentando. Desse modo, os problemas de qualidade de energia e suas consequências tornaram uma importante área de pesquisa.

É importante ressaltar que, conforme (FERNANDES, 2017), a complexidade e a grande proporção do sistema elétrico contribuem para o aumento de possíveis ocorrência de distúrbios, tais como: afundamentos e elevações de tensão (*sag* e *swell*, respectivamente) elevações de tensão-, interrupções, flutuações, harmônicos e entre outros. Somado a isso, observamos que as consequências de tais ocorrências, geram problemas econômicos às concessionárias e aos consumidores, podendo até danificar os equipamentos dos usuários (DUGAN et al., 2012).

A detecção e classificação antecipada de possíveis distúrbios, enquanto o sistema opera em condições normais, é uma ferramenta importante no objetivo de proteger equipamentos de mau funcionamento e amenizar prejuízos financeiros, por possibilitar, assim, uma análise que propõe soluções no melhoramento da QEE.

Diante do apresentado, o presente estudo empregou as técnicas de função de densidade de probabilidade (FDP) não-paramétricas, estimadores estatísticos de ordem superior (EOS) e a transformada de *space phasor model* (modelo fasorial espacial) (SPM) na tarefa de identificação dos atributos dos distúrbios de QEE.

A partir da identificação dos atributos temos diversas técnicas que podem executar a classificação dos distúrbios tais como: máquina de vetores de suporte, árvore de decisão, regressão linear e redes neurais. O presente estudo empregou a técnica de rede neural como o mecanismo de classificação, visto que nos últimos anos essa ferramenta tem ganhado espaço na área de classificação de padrões.

## 1.1 Motivação

A motivação desse trabalho é a verificação e o aprimoramento de técnicas encontradas na literatura científica, que visam a detecção e a classificação dos distúrbios de energia elétrica. Possibilitando, desse modo, a construção de um algoritmo capaz de realizar detecção e classificação automaticamente de forma confiável e eficaz.

## 1.2 Justificativa

A detecção e classificação de distúrbios da rede elétrica, em sistemas *offline*, é uma importante ferramenta no objetivo de entender o comportamento antes, durante e após os distúrbios. Portanto, a necessidade de técnicas viáveis capazes de realizar a detecção e classificação de distúrbios de energia elétrica, viabilizou a elaboração dessa pesquisa.

## 1.3 Objetivo Geral

O objetivo geral deste trabalho é identificar e classificar sinais de distúrbio da rede elétrica utilizando função de densidade de probabilidade, estimadores estatísticos de ordem superior, transformada *space phasor model* e redes neurais.

### 1.3.1 Objetivo específico

- Definir atributos de sinais de distúrbios da rede elétrica que permitam a identificação e classificação dos mesmos.
- Avaliar comparativamente o comportamento dos atributos a partir de métricas objetivas.
- Desenvolver um algoritmo para classificação dos distúrbios da rede elétrica.
- Avaliar comparativamente o desempenho do algoritmo de classificação a partir de métricas objetivas.

## 2 Revisão Bibliográfica

Este capítulo apresenta uma revisão bibliográfica, utilizada como embasamento teórico para o presente estudo, dos principais livros, artigos, dissertações e teses utilizadas na apresentação dos aspectos referentes aos distúrbios relacionados à QEE.

### 2.1 Qualidade de Energia Elétrica

O termo “qualidade de energia elétrica” começou ser empregado em trabalhos no final da década de 80, tendo como base os quatro contextos: equipamentos mais sensíveis a variações de energia, tais como microprocessadores, equipamentos mais sensíveis a variações de frequência em que estão atrelados a uma alta eficiência, tal qual drive de ajuste de velocidade de motores, qualidade de energia entregue ao consumidor final, e interconexões na distribuição de energia (DUGAN et al., 2012).

É possível notar, desse modo, que o conceito de QEE vincula-se a diversas questões, apresentando assim, uma definição não-consolidada do termo. Podemos observar tal afirmação nas seguintes definições:

"O conceito de fornecer e sustentar energia aos equipamentos eletrônicos de maneira que seja adequada para a operação do equipamento e compatível com o sistema de cabeamento e outros equipamentos conectados"(IEEE; INC, 2005).

"Qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulte em falha ou má operação dos equipamentos dos consumidores"(DUGAN et al., 2012).

"Desempenho do sistema em termos de continuidade do serviço, frequência em regime permanente e sob distúrbio, tensão de atendimento em regime permanente, flutuação, desequilíbrio e distorção harmônica de tensão e variação de tensão de curta duração"(ONS, 2019).

Tendo como base as definições apresentadas, condensamos todas as elucidações na seguinte afirmação: qualidade de energia elétrica é fornecer tensão e corrente ao sistema de maneira satisfatória sem que haja interferência e interrupções, não resultando assim, em falhas ou má operação de equipamentos.

### 2.1.1 Classificações distúrbios da qualidade de energia elétrica

Os problemas que agem sobre a QEE tem uma grande abrangência de fenômenos, que incluem variações de tensões de curta ou longa duração, distorções de ondas e distúrbios eletromagnéticos da corrente (DUGAN et al., 2012) (BOLLEN, 2012). A tabela 2.1.1 apresenta a classificação definida pelo *Instituto de Engenheiros Eletricistas e Eletrônicos* (IEEE).

Tabela 1 – Padrões de distúrbios. Fonte: (IEEE, 1993)

Categorias	Duração típica	Magnitude de tensão típica
<b>Transitório</b>		
Impulsivo	< 50ns - 1ms	
Oscilatório	20 $\mu$ s - 50 ms	0 - 8 p.u
<b>Variações de curta duração</b>		
Instantânea		
<i>Sag</i>	0.5 - 30 ciclos	0.1 - 0.9 p.u
<i>Swell</i>	0.5 - 30 ciclos	1.1 - 1.8 p.u
Momentânea		
<i>Outgate</i>	0.5 ciclos - 3s	<0.1 p.u
<i>Sag</i>	0.5 ciclos - 3s	0.1-0.9 p.u
<i>Swell</i>	0.5 ciclos - 3s	1.1-1.4 p.u
Temporária		
<i>Outgate</i>	>3s - 1min	<0.1 p.u
<i>Sag</i>	>3s - 1min	0.1-0.9 p.u
<i>Swell</i>	>3s - 1min	1.1-1.4 p.u
<b>Variações de longa duração</b>		
Interrupções sustentadas	> 1 min	0.0 p.u
Subtensão	> 1 min	0.8 - 0.9 p.u
Sobretensão	> 1 min	1.1 - 1.2 p.u
Sobrecarga de corrente	> 1 min	
<b>Desequilíbrio</b>		
tensão	Regime permanente	0.5 - 2 %
Corrente	Regime permanente	1.0 - 30 %
<b>Distorções de forma de onda</b>		
Deslocamento de DC	Regime permanente	0 - 0.1 %
Harmônicos	Regime permanente	0.0 - 20 %
Inter harmônicos	Regime permanente	0.0 - 2.0 %
<i>Notching</i>	Regime permanente	
Ruído	Regime permanente	0.0 - 1.0 %
<b>Flutuação de tensão</b>		
	Intermitente	0.1 - 7 % 0.2 - 2 $P_{st}$
<b>Variação de frequência</b>		
	< 10s	$\pm 0.10Hz$

nota:  $\mu$ s = microssegundo; s = segundos; ns = nanosegundos ; ms = milissegundos;  
p.u = por unidade; DC = corrente contínua;

### 2.1.1.1 Transitórios

Os transitórios são divididos em duas categorias: os impulsivos e os oscilatórios. Estes distúrbios podem ser gerados por inúmeras circunstâncias, causando, assim, a mudança repentina (DUGAN et al., 2012).

#### Impulsivos

Observamos que a ocorrência, nos transientes impulsivos, acontece de maneira repentina e ocasiona a mudança na normalidade do sistema, influenciando, desse modo, na condição da tensão, da corrente e na unidirecional na polaridade (DUGAN et al., 2012).

#### Oscilatórios

Os transientes oscilatórios são alterações instantâneas que mudam a polaridade da tensão ou da corrente afetando, assim, predominantemente a frequência do sinal (DUGAN et al., 2012).

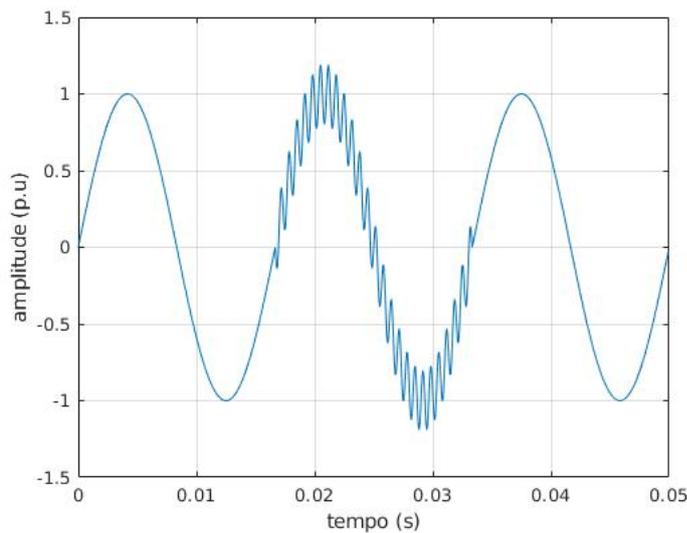


Figura 1 – Distúrbio oscilação transiente

### 2.1.1.2 Variações de curta duração

São variações que podem ser designadas como instantâneas, momentâneas ou temporárias. Os distúrbios dessa categoria são divididos em interrupção, *sag*, *swell*. A determinação de cada distúrbio está atrelada ao local da falha e as condições do sistema (DUGAN et al., 2012).

#### Interrupções

As Interrupções ocorrem quando o fornecimento de tensão e/ou carga de corrente caem significativamente atingindo valores menores que 0.1 por unidade (p.u) no período de até um minuto (DUGAN et al., 2012).

### Afundamento de tensão (*sag*)

O afundamento da tensão, ou também denominado *sag*, é o decréscimo da tensão e/ou da corrente dentro de meio ciclo até 30 ciclos de duração. Conjuntamente, este também, pode ser caracterizado pela queda da amplitude, atingindo patamares de 0.1 a 0.9 p.u (DUGAN et al., 2012). Conforme a figura 2.

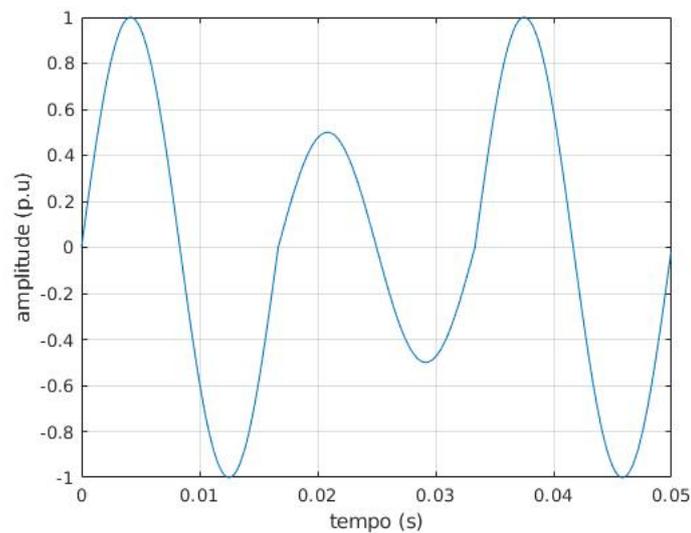


Figura 2 – Distúrbio afundamento de tensão

### Elevação de tensão (*swell*)

A elevação da tensão, ou também denominado *swell*, é o aumento da tensão e/ou da corrente dentro de meio ciclo até 30 ciclos de duração. Em que, o aumento da amplitude é entre 1.1 a 1.8 p.u (DUGAN et al., 2012). Conforme a figura 3.

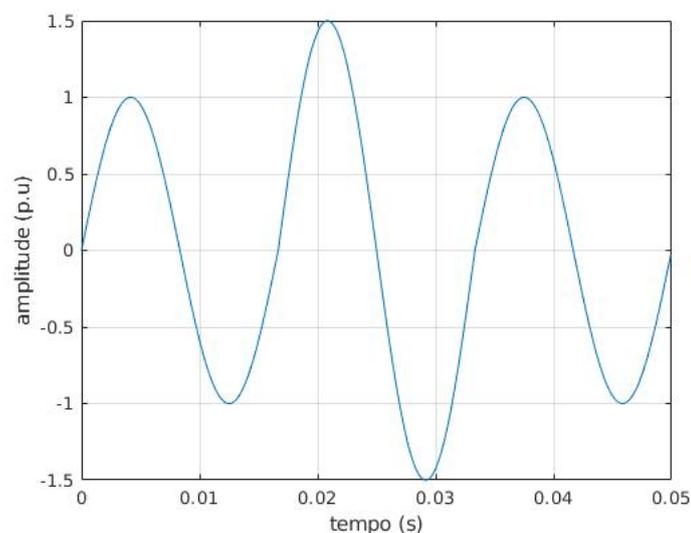


Figura 3 – Distúrbio elevação de tensão

### 2.1.1.3 Variação de longa duração

A classificação de longa duração é vista na norma **ANSI C84.1**, na qual especifica o distúrbio que tem duração superior a um minuto ([ANSI, 2011](#)). Os distúrbios classificados nessa descrição são: subtensão, sobretensão e interrupções sustentadas ([DUGAN et al., 2012](#)).

#### **Interrupções sustentadas**

As interrupções sustentadas são situações em que a tensão encontra-se em valores próximo de zero por períodos de tempo superior a 1 minuto. Essas interrupções são permanentes e necessitam da intervenção humana para reparo da rede ([DUGAN et al., 2012](#)).

### 2.1.1.4 Desequilíbrio

Esta é uma das formas de cálculo do desvio máximo dado pela média das três fases do sinal, sendo esse dividido pela média das três fases com o resultado expresso em porcentagem ([DUGAN et al., 2012](#)).

### 2.1.1.5 Distorções da Onda

As distorções da onda são divididas em: deslocamento de corrente contínua (*DC offset*), harmônicas, inter harmônicas, *notching* (corte de tensão) e ruído.

#### **Deslocamento de DC**

A presença de uma tensão ou corrente contínua em um sistema de energia de corrente alternada é denominado deslocamento DC. O distúrbio possui como característica a variação da amplitude entre 0 a 0.1 % do valor nominal ([DUGAN et al., 2012](#)).

#### **Harmônico**

Os harmônicos são distúrbios que têm como característica a presença de frequências acopladas na frequência fundamental da onda. O distúrbio tem a propriedade de variação da amplitude entre 0 a 20% do valor nominal ([DUGAN et al., 2012](#)), conforme apresentada na figura 4.

#### **Inter Harmônico**

São frequências que não são múltiplas da frequência fundamental, estas podem ser frequências discretas ou espectro de banda larga ([DUGAN et al., 2012](#)).

#### ***Notching***

O *Notching* é um distúrbio que acontece na comutação da corrente de uma fase para outra ([DUGAN et al., 2012](#)).

#### **Ruído**

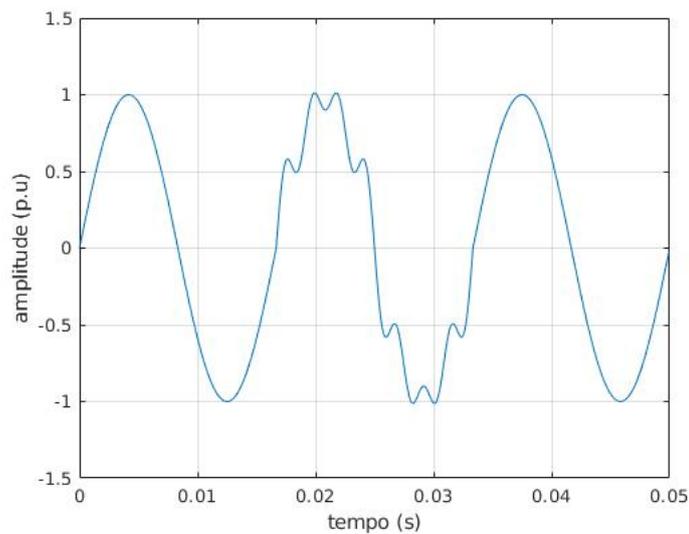


Figura 4 – Distúrbio harmônico

Ruídos são distorções indesejadas no sinal que não podem ser classificadas como distorções harmônicas (DUGAN et al., 2012).

#### 2.1.1.6 Flutuação de tensão

A flutuação de tensão ocorre de forma sistemática devido a variações da tensão ou de forma aleatória devido a mudanças na magnitude da amplitude (DUGAN et al., 2012).

#### 2.1.1.7 Variação da frequência

A variação da frequência ocorre quando a frequência ultrapassa os limites pré definidos para uma boa operação do sistema (DUGAN et al., 2012).

## 2.2 Função de Densidade de Probabilidade (FDP)

O comportamento de uma variável aleatória contínua  $X$  pode ser caracterizado com a sua função de densidade de probabilidade  $f_X(X)$ . A probabilidade de uma variável aleatória contínua pode ser definida pela integral da sua função de densidade de probabilidade, dado a um intervalo, definido como (HINES, 2006):

$$P(a < X < b) = \int_a^b f_X(x)dx, \quad (2.1)$$

para qualquer  $a < b$ , onde a função  $f$  detém as seguintes propriedades:

- Só valores positivos;

- É integrável;
- A integral de  $f(x)$  desde  $-\infty$  a  $+\infty$  é igual a 1;

Quando a FDP de uma variável aleatória não é conhecida, uma estimativa desta densidade pode ser obtida. Existem vários métodos para estimação da probabilidade, que podem ser divididos em paramétricos e não-paramétricos. Para os paramétricos supõe que a FDP conhecida. Por outro lado, métodos não-paramétricos não realizam suposições sobre a FDP. A figura 5 apresenta a divisão dos métodos de estimação de funções de densidade de probabilidade (HINES, 2006).

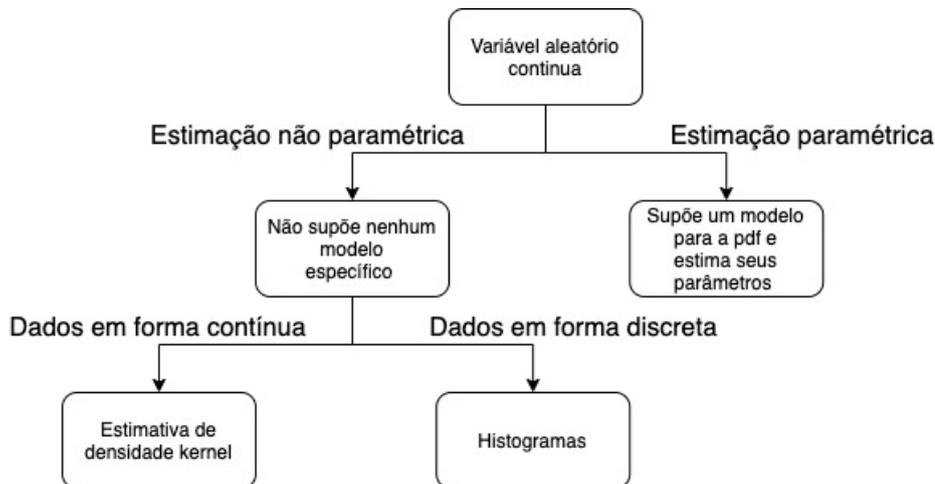


Figura 5 – Divisão dos métodos de estimação de densidade de probabilidade

### 2.2.1 Histograma

O histograma é considerado o estimador não paramétrico mais simples e mais antigo conhecido (RODRIGO; FERREIRA, 2009). Este possui como definição a distribuição de frequências dos dados analisados de forma visual, ou seja, é um resumo dos dados em uma representação de um gráfico de barras (MONTGOMERY et al., 2006).

A construção de um histograma consiste em dividir um intervalo de referência  $\omega = [A_{min}, A_{max}]$  em  $k$  classes (ou compartimentos)  $C_L$  e contar o número  $a_L$  de observações pertencentes a cada classe  $C_L$ . O número  $a_L$  é o acumulador associado à classe  $C_L$ . Seja  $X$  a função característica de  $C_L$ :

$$a_L = \sum_{i=1}^n X_{C_L}(x_i), \quad (2.2)$$

onde  $k$  é definida por:

$$k = \frac{A_{max} - A_{min}}{L}, \quad (2.3)$$

onde  $L$  é a largura e  $A$  é a amplitude.

A figura 6 apresenta o histograma da amplitude de uma função de distúrbio harmônico com a largura definida como 0.1. Em contrapartida, a figura 7 apresenta o histograma da mesma função com a largura definida como 0.01, observamos, desse modo que, a escolha de uma largura pequena pode ocasionar espaços vazios no histograma, ou seja, não apontando amostras dentro daquele intervalo assim, causando uma interpretação errada do sinal estudado. Por outro lado, se a largura for grande tem-se um histograma uniforme, não expressando, assim, nenhuma informação útil, conforme apresentado na figura 8 (MONTGOMERY et al., 2006).

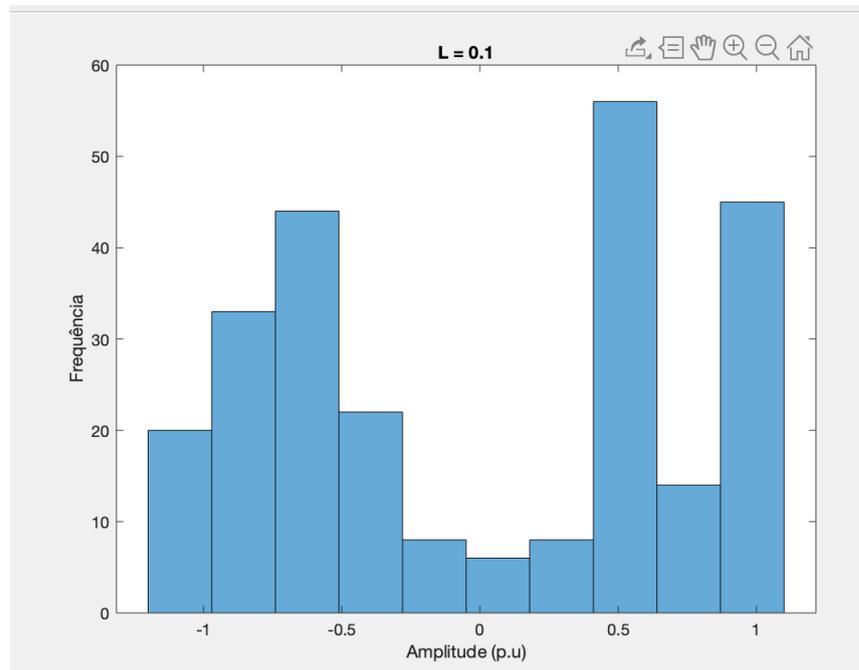


Figura 6 – Histograma de um distúrbio harmônico com largura  $L = 0.1$ .

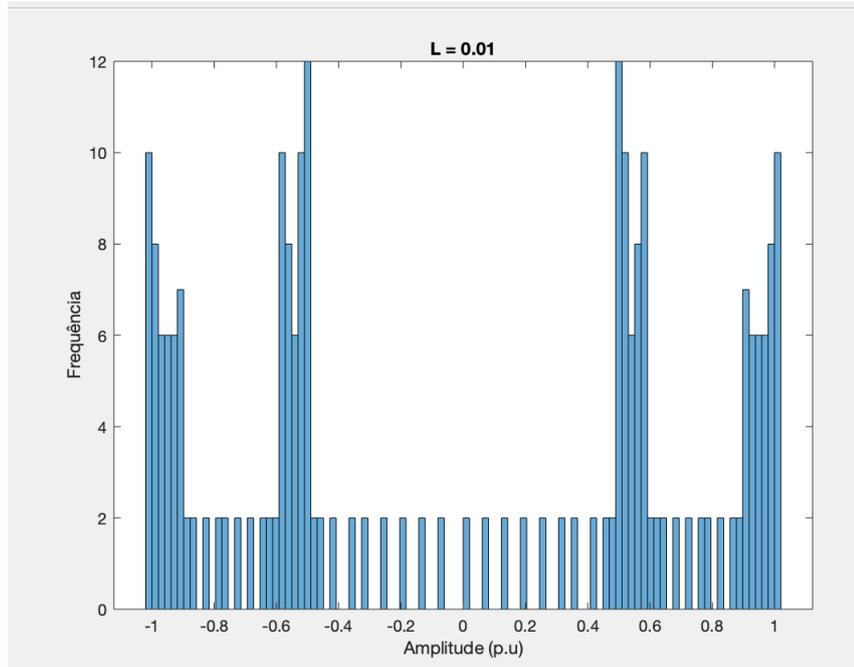


Figura 7 – Histograma de um distúrbio harmônico com largura  $L = 0.01$ .

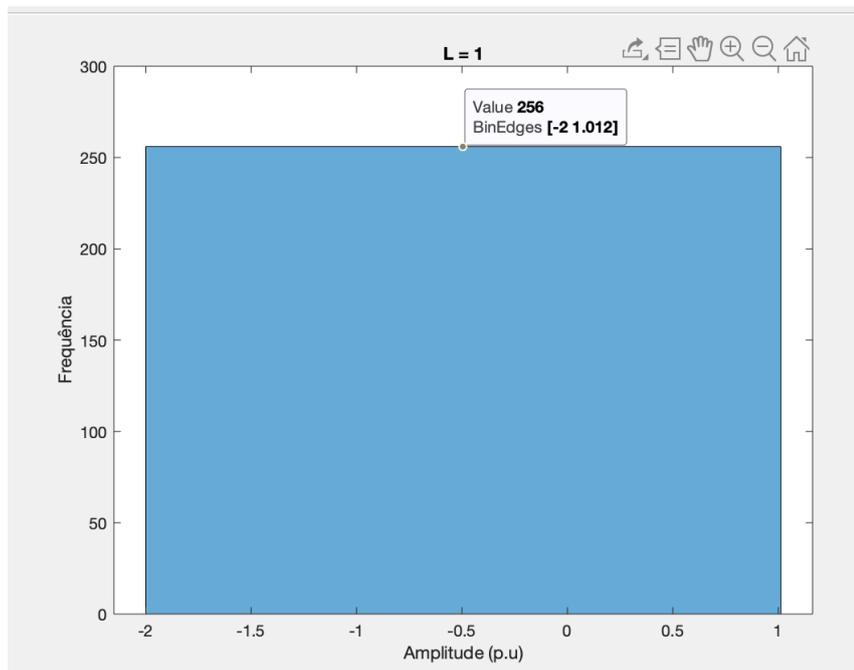


Figura 8 – Histograma de um distúrbio harmônico com largura  $L = 1$ .

### 2.2.2 Estimativa de densidade por kernel

Segundo o (RUPPERT; MATTESON, 2015), o histograma é um estimador de densidade bastante bruto, pois o método utiliza um resultado na forma discreta. Entretanto, uma forma mais eficiente de lidar com esse problema suavizar o histograma no sentido de que cada observação possa contribuir para diferentes classes com diferentes pesos, re-

presentando, desse modo, uma função contínua e não uma função discreta. Portanto, a definição da estimativa de densidade de kernel (HEUMANN; SHALABH; SCHOMAKER, 2016):

$$f(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right), h > 0, \quad (2.4)$$

onde  $n$  é o número de amostras,  $h$  é a resolução da estimativa (ou largura de banda) e o  $K$  é a função de kernel podendo ter diferentes tipos, o mais conhecido é o kernel de gaussiano (ou normal) sendo definido como:

$$k(x) = \left(\frac{1}{\sqrt{2\pi}}\right)^{-\frac{x^2}{2}}, \quad (2.5)$$

É importante observar que, se  $h$  for muito grande a estimativa será super-suavizada, ou seja, terá uma informação uniforme da estimativa de densidade de probabilidade. Por outro lado, se  $h$  for muito pequeno haverá uma sub-suavização, isto é, a função portará diversos picos, resultando assim, em uma densidade de probabilidade ruidosa (HEUMANN; SHALABH; SCHOMAKER, 2016).

A figura 9 mostra 3 estimativas, com kernel normal e diferentes larguras de banda, a partir de 100 amostras geradas de uma função aleatória. A curva pontilhada em preto é sub-suavizada, devido ao valor da largura ser muito pequeno ( $h = 0.2$ ), apresentando diversos picos e tornando a informação ruidosa. Por outro lado, a curva pontilhada em vermelho apresenta a largura de banda igual a 4, na qual tem a super-suavização, que leva a perda de informação por uniformizar a amostra. Por fim, a curva na cor azul mostra a melhor estimativa para o valor da largura de banda, isso é devido pela utilização da equação 2.6, apresentada a seguir.

Desta forma, quando utiliza-se o kernel normal existe uma equação determinada, que é o cálculo de  $h$  otimizado para o uso do kernel gaussiano. Portanto, o valor  $h$  ideal é dado por (KAFADAR; BOWMAN; AZZALINI, 1999):

$$h_{normal} = \left(\frac{4\sigma^5}{3n}\right)^{\frac{1}{5}}, \quad (2.6)$$

no qual  $\sigma$  é o desvio padrão da distribuição.

## 2.3 Estimadores estatísticos de ordem superior (EOS)

Os momentos são medidas descritivas, podendo ser determinados pela equação 2.7, em que o momento de ordem  $n$  é definido como a esperança, ou chamado também de

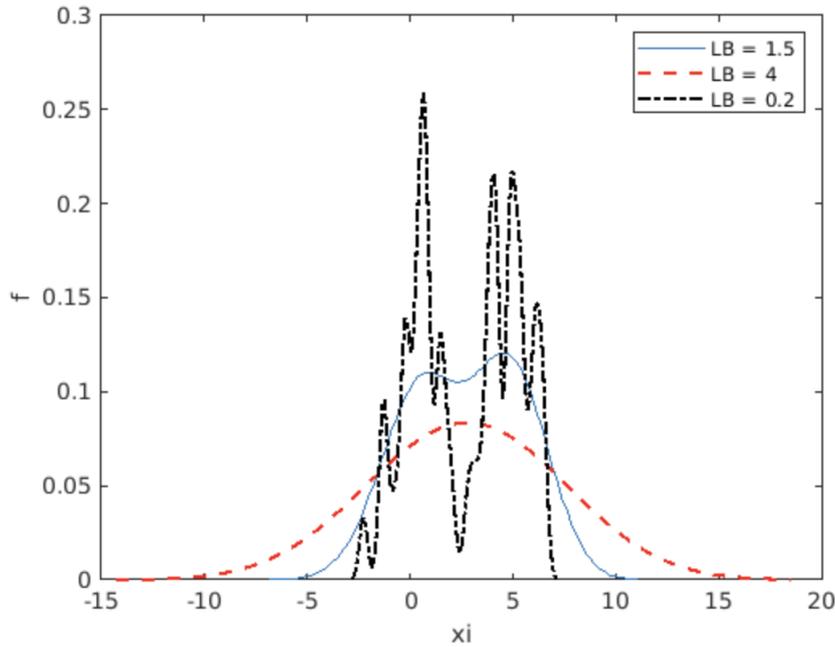


Figura 9 – Comportamento das diferentes larguras de banda.

valor esperado, de  $x^n$  (CASELLA; BERGER, 2014),

$$E(x^n), \quad (2.7)$$

em que  $n$  é a ordem de uma variável aleatória  $X$ .

Para o caso contínuo do momento tem-se a seguinte definição:

$$\mu_n = E(x^n) = \int_{-\infty}^{+\infty} x^n f(x) dx, \quad (2.8)$$

em que  $f(x)$  é função densidade. Assim, os momentos da seguinte ordem  $n$ , serão:

$$\mu_n = E(x^n) \quad (2.9)$$

A partir dos momento de ordem 2, como visto na equação 2.10, utilizam-se os momentos baseados nos desvios à media (MOREIRA, 2018). Qualquer momento a partir do segundo momento é chamado de estimadores estatísticos de ordem superior.

$$\mu_2 = E(x^2) = E[(x - \mu)^2] \quad (2.10)$$

### 2.3.1 Segundo momento - Variância

O segundo momento, ou segundo momento central, é denominado de variância. A variância de uma variável aleatória é a medida da sua dispersão estatística, ou seja, o que

indica a distância dos resultados do valor esperado, sendo definida como (HINES, 2006):

$$\mu_2 = E(x^2) = E[(x - \mu)^2] = \int_{-\infty}^{+\infty} x^2 f(x) dx = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{x})^2 \quad (2.11)$$

### 2.3.2 Terceiro momento - Assimetria

O terceiro momento é a assimetria, que pode ser definida como o grau de desvio ou afastamento da simetria. A definição do terceiro momento é apresentada pela seguinte equação (HINES, 2006):

$$\mu_3 = E(x - \bar{x})^3 = E(x^3) = \int_{-\infty}^{+\infty} (x - \bar{x})^3 f(x) dx, \quad (2.12)$$

o coeficiente da assimetria é representado como:

$$S = \frac{\mu^3}{\sigma^3}, \quad (2.13)$$

em que  $\mu^3$  é o terceiro momento e  $\sigma$  é o desvio padrão. O coeficiente de assimetria ( $S$ ) pode ser: igual a zero, por resultar em uma distribuição simétrica; ou maior que zero, por determinar uma distribuição assimétrica positiva; ou, por fim, menor que zero, por apresentar uma distribuição assimétrica negativa (LOPES, 2003).

Cada tipo de distribuição apresenta uma característica específica. A figura 10 tem a distribuição assimétrica negativa, que ocorre quando a distribuição ou a curva de frequência tem uma “cauda” mais longa à esquerda. Por outro lado, a figura 11 tem a distribuição assimétrica positiva, visto na figura 11, esta acontece quando a distribuição ou a curva de frequência tem uma “cauda” mais longa à direita. Por último, a distribuição simétrica apresenta-se quando há uma exata repartição de valores em torno do ponto (LOPES, 2003).

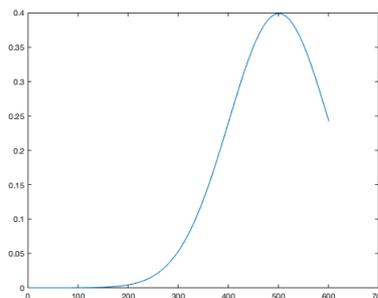


Figura 10 – Distribuição assimétrica negativa.

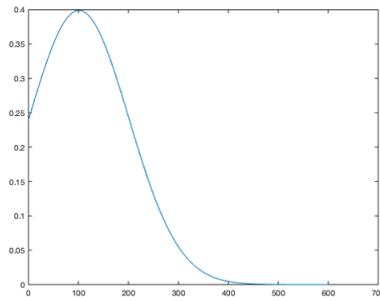


Figura 11 – Distribuição assimétrica positiva.

### 2.3.3 Quarto momento - Curtose

O quarto momento, ou também denominado curtose, é a medida que caracteriza o achatamento da curva, ou seja, é possível observar que a distribuição é mais aguda ou achatada do que curva normal, podendo ser definida como (LOPES, 2003):

$$\mu_4 = E(x - \bar{x})^4 = E(x^4) = \int_{-\infty}^{+\infty} (x - \bar{x})^4 f(x) dx, \quad (2.14)$$

para realizar o cálculo do coeficiente de achatamento utiliza-se a seguinte equação:

$$K = \frac{1}{n} \sum \left( \frac{(x_i - \bar{x})^4}{\sigma^4} \right) - 3 = \frac{\mu_4}{\sigma^4} - 3, \quad (2.15)$$

no qual  $\mu^4$  é o quarto momento e  $\sigma$  é o desvio padrão.

O valor da curtose poderá ser tanto positivo quanto negativo. Assim sendo, a curtose pode ser classificada em três tipos, conforme apresentado na figura 12 : se  $K < 0$  obtém-se a curva platicúrtica, em que tem-se o valor abaixo da dispersão normal, ou seja, apresenta-se uma curva com achatamento no seu topo; se  $K = 0$  apresenta-se uma curva mesocúrtica, na qual é considerada uma curva padrão; por fim, se  $K > 0$  tem-se uma curva leptocúrtica, em que o valor mostra-se acima da dispersão normal, ou seja, a curva exibe um grau de achatamento menor, tendo assim, uma curva mais aguda e com extremidades mais espaçadas (LOPES, 2003).

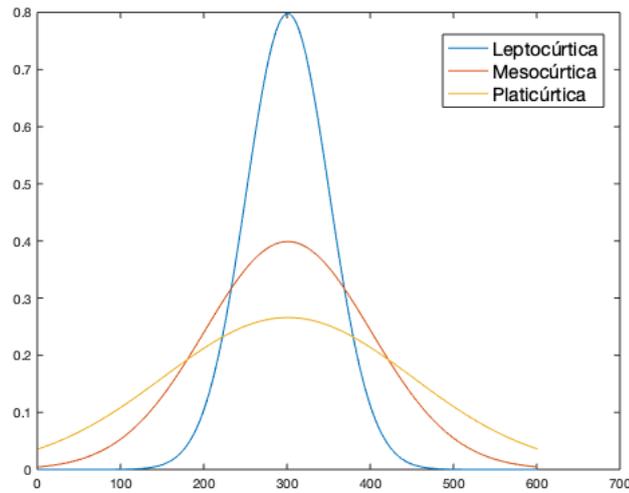


Figura 12 – Distribuição Platicúrticas, Mesocúrticas e Leptocúrticas

## 2.4 Transformada *Space phasor model*

A transformada *space phasor model* (SPM) é baseada na transformada de Clarke, que realiza a conversão algébrica de grandezas trifásicas equilibradas para em uma referência bifásica equilibrada, sendo definida como (BAGHERI, 2018):

$$V_{\alpha\beta} = MV_{abc}, \quad (2.16)$$

onde  $M$  é,

$$M = \frac{2}{3} \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \\ 1 & \frac{-1}{2} & \frac{-1}{2} \\ 0 & \frac{\sqrt{3}}{2} & \frac{-\sqrt{3}}{2} \end{bmatrix}, \quad (2.17)$$

sendo essa a base da transformada de SPM, porém, com a diferença da escolha do  $M$ , que veremos para frente.

A transformada de SPM é composta das três tensões-neutro,  $V_a(t), V_b(t), V_c(t)$  (BAGHERI, 2018), sendo definida da seguinte forma:

$$s_t = \frac{2}{3}[V_a(t) + \alpha V_b(t) + \alpha^2 V_c(t)], t = 1, 2, \dots, n, \quad (2.18)$$

em que  $\alpha = e^{\frac{j2\pi}{3}}$  e  $s_t$  é uma matriz temporal de números complexos, sendo definida como:

$$s_t = [s_1, s_2, \dots, s_n]^T, \quad (2.19)$$

separando a matriz  $s_t$  em real e imaginário temos uma nova matriz  $S$ ,

$$T = \begin{bmatrix} s_{t,R} & s_{t,I} \end{bmatrix}_{n \times 2}, \quad (2.20)$$

em que  $s_{t,R} = [s_{1,R}, s_{2,R}, \dots, s_{n,R}]^T$  é a componente reais e  $s_{t,I} = [s_{1,I}, s_{2,I}, \dots, s_{n,I}]^T$  é a componente imaginária.

A figura 13 apresenta a transformada SPM, que é formada por número complexo que tem magnitude entre  $[-1, 1]$  p.u para uma senoide ideal.

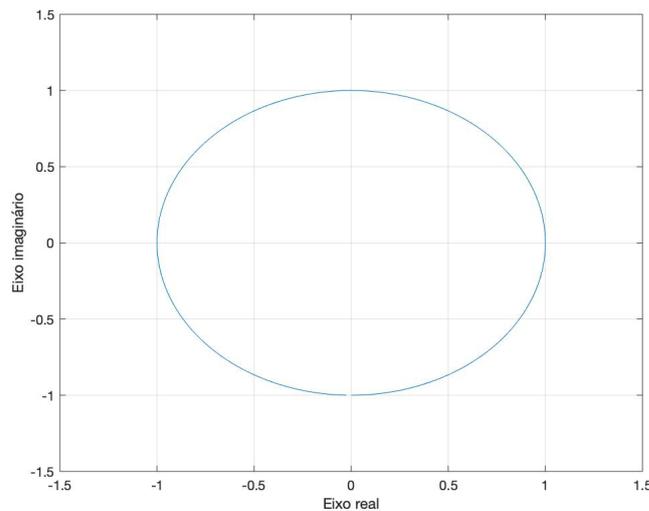


Figura 13 – Transformada SPM aplicada em uma senoide ideal

## 2.5 Redes neurais artificiais

As redes neurais artificiais (RNAs), ou apenas redes neurais, são algoritmos inspirados no funcionamento do cérebro humano. As redes têm dois aspectos semelhantes ao cérebro humano: o conhecimento adquirido a partir de um processo de aprendizagem; forças de conexão entre neurônios (pesos sinápticos) (HAYKIN, 2011) (SILVA; FLAUZINO; SPATTI, 2019).

O processo de aprendizagem é chamado de algoritmo de aprendizagem, que tem a função de modificar os pesos sinápticos de uma rede com objetivo de obter o resultado esperado. O processo de alteração dos pesos sinápticos é o método tradicional para o projeto de redes neurais (HAYKIN, 2011).

A principal função da rede neural é solucionar problemas de complexidade elevada. Entretanto, a RNA simplifica a resolução destes problemas, ao passo que os decompõem em um número de tarefas relativamente simples, e estas são distribuídas a neurônios que coincidem com as suas capacidades inerentes. Dentre os problemas tradicionalmente abor-

dados com RNA, temos associação de padrões; reconhecimento de padrões; aproximação de funções; controle e filtragem. (HAYKIN, 2011).

A figura 14 apresentada o neurônio artificial, possuindo este três elementos básicos. O primeiro são as sinapses, ou elos de conexão, caracterizadas por um peso. Especificamente um sinal  $x_j$  que se conectado ao neurônio  $k$  é multiplicado pelo peso sináptico  $w_{kj}$ . Cabe ressaltar que um peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos a positivos, ao contrario da sinapse do cérebro. O segundo é o combinador linear, que é responsável por agregar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos. Por último, há a função de ativação, ou função restritiva, que tem como principal foco restringir a amplitude da saída de um neurônio. Tipicamente, o intervalo da saída de um neurônio é escrito como o intervalo unitário fechado  $[0 \ 1]$ , ou alternativamente  $[-1 \ 1]$  (HAYKIN, 2011) (SILVA; FLAUZINO; SPATTI, 2019).

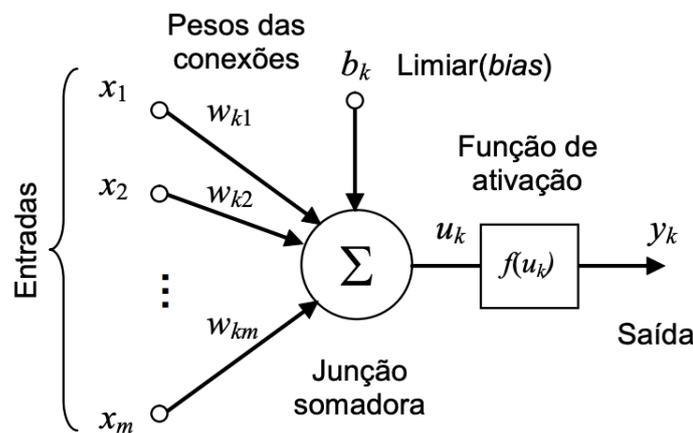


Figura 14 – Modelo não-linear de um neurônio. Fonte: (HAYKIN, 2011).

A partir da figura 14 podemos descrever a saída  $y_k$  sendo:

$$y_k = f(u_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right), \quad (2.21)$$

assumindo  $x_0 = 1$  e  $w_{k0} = b_k$  e rescrevendo a equação 2.21 encontramos a equação 2.22

$$y_k = f\left(\sum_{j=0}^m w_{kj}x_j\right). \quad (2.22)$$

A funções de ativação podem ser decomposta em dois grupos. O primeiro abrange as funções parcialmente diferenciáveis, e o segundo, funções totalmente diferenciáveis, considerando todo o seu domínio de definição. Por exemplo: o primeiro grupo inclui as funções de degrau e rampa, e o segundo, as funções logística e tangente hiperbólica (SILVA; FLAUZINO; SPATTI, 2019).

A arquitetura da RNA é a definição de como serão ligados os neurônios, ou seja, como os neurônios estão arrançados. Esta formação esta estruturada através do direcionamento das conexões sinápticas dos neurônios (SILVA; FLAUZINO; SPATTI, 2019).

A forma como se arranja dentro de uma rede neural é chamado de topologia. A rede neural pode apresentar a mesma arquitetura, porém pode ter diferentes números de neurônios e funções de ativações distintas. Portanto, uma RNA pode ter a mesma arquitetura mas com topologias distintas (SILVA; FLAUZINO; SPATTI, 2019).

As principais arquiteturas de redes neurais são redes neurais *feedforward* (alimentação à frente) de camada simples, *feedforward* de camadas múltiplas, recorrentes e reticuladas. A arquitetura *feedforward* de camada simples é composta unicamente das camadas de entrada e saída. Por outro lado, a arquitetura *feedforward* de múltiplas camadas é formada pelas mesmas características da anterior somada à camada intermediária. Uma característica interessante das redes *feedforward* é que, em geral, a quantidade de sinais de saída sempre coincidirá com o número de neurônios daquela respectiva camada (SILVA; FLAUZINO; SPATTI, 2019).

Entre as principais arquiteturas *feedforward* de camadas múltiplas se encontra o *perceptron* multicamadas (*multilayer perceptron*) (MLP), em que o seu processo de treinamento é baseado na regra delta generalizada (SILVA; FLAUZINO; SPATTI, 2019).

Segundo (HAYKIN, 2011), a habilidade de aprender é a propriedade de importância primordial para uma rede neural. O aprendizado de uma rede pode se desenvolver de inúmeros modos. Com isso, há a existência de diversos modelos de algoritmos, que possuem como principal diferença o modo como é formulado o ajuste de um peso sináptico de um neurônio. O aprendizado, conforme (SILVA; FLAUZINO; SPATTI, 2019), é composto de duas fases: a busca por informações e o ajuste de pesos em um processo iterativo.

O processo de treinamento se divide em dois grupos: treinamento e validação. O grupo de treinamento é utilizado para definir os pesos, já o grupo de validação é utilizado para verificar o despenho da rede, determinando, assim, o grau de precisão obtido pelo treinamento. O grupo de treinamento é composto aleatoriamente com cerca de 60% a 90% das amostras da rede. Por outro lado, o grupo de validação é utilizado para verificar se os aspectos, referentes à generalização de soluções por parte da rede, estão em patamares aceitáveis, possibilitando, desse modo, a validação da topologia. O grupo de validação é composto entre 10% a 40% do conjunto total de amostras (SILVA; FLAUZINO; SPATTI, 2019).

Somado a isso, há uma divisão entre os tipos de treinamentos, os de aprendizagem supervisionada e os de aprendizagem não supervisionada. O treinamento supervisionado tem como ideia que o algoritmo tem um "professor" responsável por direcionar o aprendizado da rede. Neste tipo de aprendizagem é necessário ter o conhecimento das entradas

e das saídas desejadas, ou seja, há a necessidade de se disponibilizar uma tabela de dados(entrada/saída). Por outro lado, o treinamento não-supervisionada tem a ausência das saídas desejadas, deste modo, a rede deve se auto-organizar em relação às particularidades existentes entre os elementos componentes do conjunto total de amostras (SILVA; FLAUZINO; SPATTI, 2019).

### 2.5.1 Redes *perceptron* multicamadas

As redes *Perceptron* multicamadas (PMC) é uma topologia da arquitetura *feed-forward* com o treinamento supervisionado. Elas são caracterizadas pela presença de pelo menos uma camada intermediária (SILVA; FLAUZINO; SPATTI, 2019).

Na figura 15, temos uma ilustração da rede *perceptron* multicamadas. Note que, as entradas só tem um caminho até a saída, ou seja, a propagação dos sinais de entrada da rede independe da quantidade de camadas intermediárias. Também é possível observar, que a saída pode ser composta por diversos neurônios, sendo que, cada um representa uma saída desejada pelo processo a ser mapeado (SILVA; FLAUZINO; SPATTI, 2019).

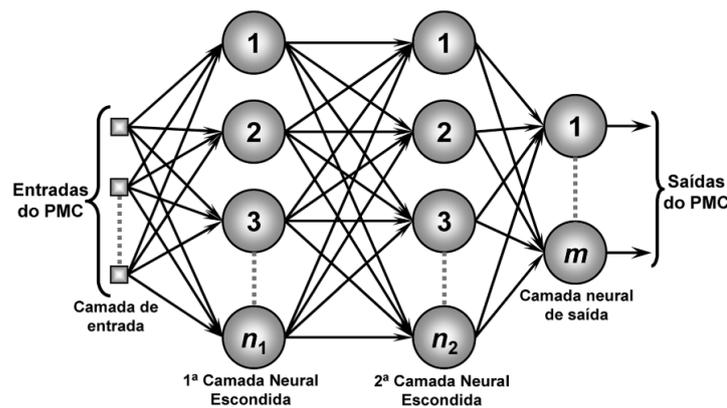


Figura 15 – Rede PMC. Fonte: (SILVA; FLAUZINO; SPATTI, 2019)

#### 2.5.1.1 Processo de treinamento de PMC

O treinamento de uma PMC é definido pelo o algoritmo *backpropagation* (retro propagação), ou chamada de regra delta generalizada. O algoritmo detém duas fases bem definidas que segue a seguinte ordem: propagação adiante (*forward*) e propagação reversa (*backward*).

A propagação adiante consiste em inserir o grupo de treinamento na camada de entrada e propaga-lo até a camada de saída. Vale ressaltar que os pesos sinápticos e limiares dos neurônios permanecem inalterados durante essa fase. Após essa etapa, a rede terá os desvios, ou seja, os erros entre as entradas e saídas produzidos por cada neurônio. Esses erros serão utilizados no próximo passo. A propagação reversa consiste

em inserir os desvios calculados de cada neurônio nas saídas e propaga-los até as entradas dos neurônios seguintes. Realizando, deste modo, os ajustes nos pesos sinápticos e limiares de cada neurônio. Esse processo se repete até que o erro tenha alcançado valores aceitáveis (SILVA; FLAUZINO; SPATTI, 2019).

A figura 16, apresenta como é o funcionamento do algoritmo *backpropagation* para dois neurônios de entrada e um de saída.

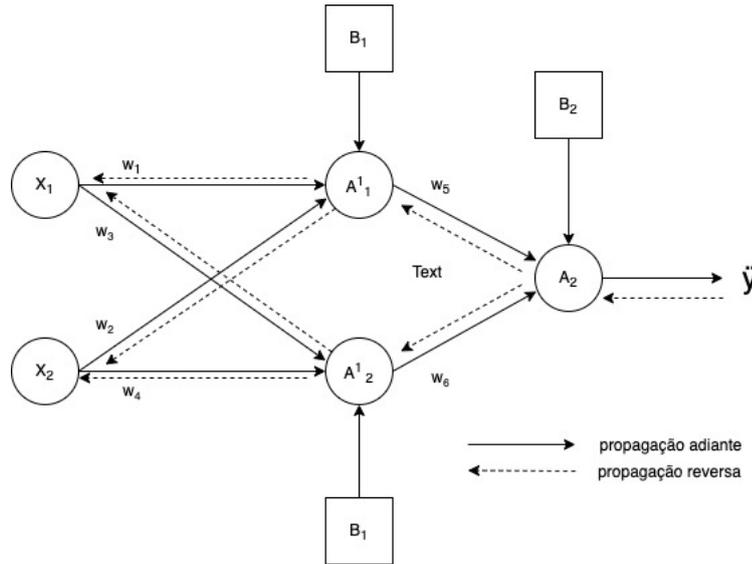


Figura 16 – Duas fases de treinamento da rede PMC

Realizando matematicamente o processo do algoritmo temos o seguinte:

$$\ddot{y} = g(w_5 a_1^1 + w_6 a_2^1 + b_2), \quad (2.23)$$

onde  $g$  é a função de ativação e  $\ddot{y}$  é a função de hipótese, ou seja, a saída da rede neural. Realizando a expansão dos neurônio  $a_1^1$  e  $a_2^1$

$$\ddot{y} = g(w_5 g(w_1 x_1 + w_2 x_2 + b_1) + w_6 g(w_3 x_1 + w_4 x_2 + b_2)), \quad (2.24)$$

sabendo que  $\frac{1}{2}(\ddot{y} - y)^2$  é o erro da saída em relação a entrada. Substituindo  $\ddot{y}$  por (2.23) temos,

$$\frac{1}{2}(g(w_5 a_1^1 + w_6 a_2^1 + b_2) - y)^2, \quad (2.25)$$

realizando a derivada parcial da equação (2.25) em relação a  $w_5$  ( $\nabla_5$ ) e assumindo que  $g$  a função logística temos a seguinte derivada parcial,

$$\nabla_5 = (a_1^2 - y) a_1^2 (1 - a_1^2) a_1^1, \quad (2.26)$$

realizando o mesmo processo para cada  $w$  temos:

$$\nabla_6 = (a_1^2 - y)a_1^2(1 - a_1^2)a_1^2, \quad (2.27)$$

$$\nabla_1 = (a_1^2 - y)a_1^2(1 - a_1^2)w_5a_1^1(1 - a_1^1)x_1, \quad (2.28)$$

$$\nabla_2 = (a_2^1 - y)a_1^2(1 - a_1^2)w_5a_1^1(1 - a_1^1)x_2, \quad (2.29)$$

$$\nabla_3 = (a_1^2 - y)a_1^2(1 - a_1^2)w_6a_2^1(1 - a_2^1)x_1, \quad (2.30)$$

$$\nabla_4 = (a_2^1 - y)a_1^2(1 - a_1^2)w_6a_2^1(1 - a_2^1)x_2. \quad (2.31)$$

Os pesos sinápticos são representados nas expressões anteriores podendo ser generalizados em quaisquer topologia e independentemente da quantidade de camadas intermediárias.

# 3 Metodologia

O presente capítulo tem por objetivo apresentar os métodos de desenvolvimento dos processos aplicados neste trabalho.

## 3.1 Fluxograma Geral da Pesquisa

A figura 17 apresenta a sequência das etapas desenvolvidas nesta pesquisa.

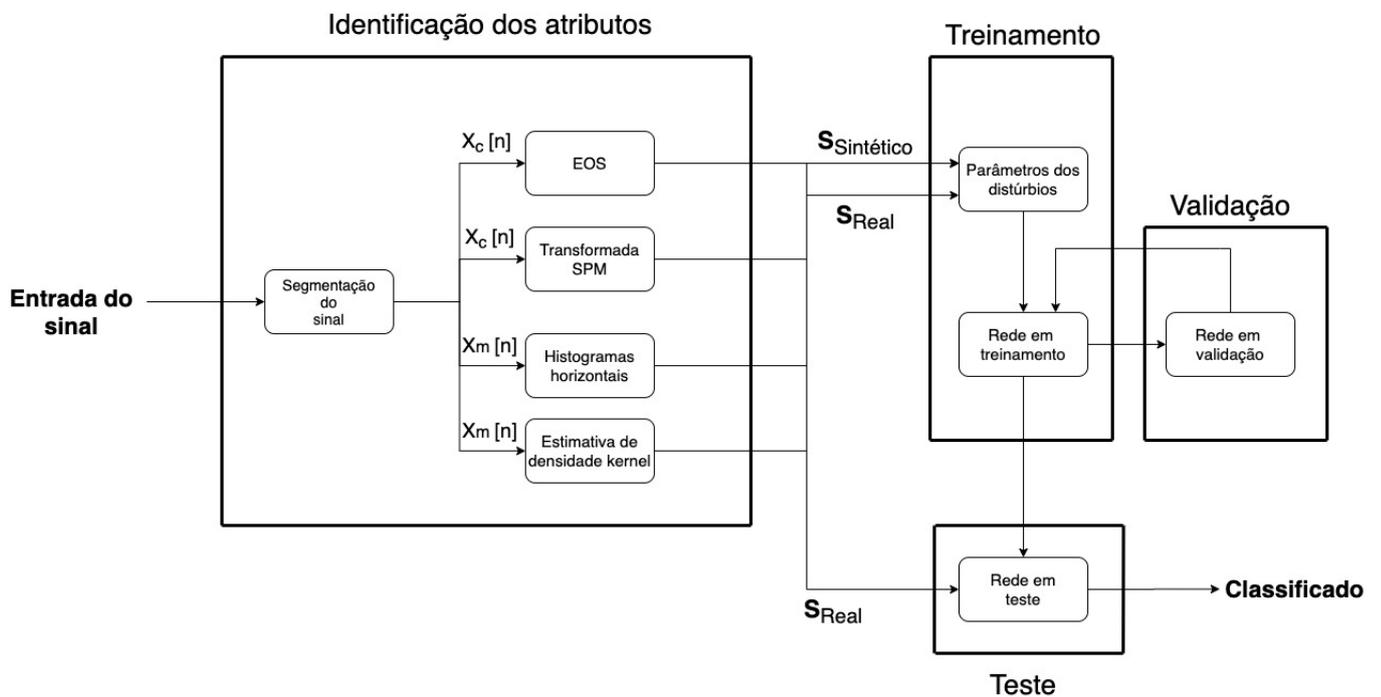


Figura 17 – Fluxograma da pesquisa

É observável que, com o intuito de contribuir para o estudo de detecção e classificação de distúrbios de energia elétrica, propõe-se um algoritmo para realização disso. Somado a isso, têm-se os métodos de função de densidade de probabilidade não paramétricos (histogramas e estimativa de densidade kernel), estimadores estatísticos de ordem superior e a transformada *space phasor model*, para identificação dos atributos. Por fim, utiliza-se a rede *perceptron* multicamadas para a classificação de distúrbios de energia elétrica.

A metodologia proposta dar-se-a pela utilização dos sinais sintéticos fornecido por (ABDEL-GALIL et al., 2004) e os dados reais oferecido por (EPRI, 2011). A identificação de atributos se divide em segmentação do sinal e aplicação dos métodos supracitados. O

signal é segmentado em 128 e 256 amostras, ou seja, meio ciclo e um ciclo da frequência fundamental do sinal de tensão, respectivamente, representado pelo vetor  $X_m[n]$  e  $X_c[n]$  na figura 17. O vetor segmentado em meio ciclo utiliza os métodos histogramas horizontais - em parte da proposta (VALTIERRA-RODRIGUEZ et al., 2014) - e estimativa de densidade kernel. Por outro lado, o vetor segmentado em um ciclo segue para os métodos estimadores estatísticos de ordem superior (proposto por (AGÜERA-PÉREZ et al., 2011)) e para a transformada SPM proposta por (BAGHERI, 2018). Em seguida, observa-se que, para a realização do treinamento é necessário possuir um sinal sintético capaz de desenvolver uma matriz de atributos ( $S_{Sintético}$ ), que tem como objetivo obter *labels* aptos a realizar a determinação dos distúrbios da base de dados de sinais de distúrbios reais. Tal procedimento foi realizado manualmente com 70% da base de dados de sinais reais, essa etapa fez-se necessário visto que esse banco de dados não possuía a determinação dos eventos. Diante disso, a matriz de atributos de sinal ( $S_{Real}$ ) será utilizada para o treinamento da rede neural. Esse treinamento será executado com o algoritmo de aprendizagem baseado em retro propagação (*backpropagation*). Dessa forma, o treinamento poderá ser finalizado de dois modos: quando ocorrer o erro médio quadrático igual  $10^{-2}$ , ou quando se atingir 1000 épocas de treinamento. Por fim, com a rede neural treinada e validada é possível realizar o teste da rede e obter a classificação do distúrbio a partir do  $S_{Real}$ .

Todas as etapas apresentadas na figura 17 são realizadas pelo *software Mathworks Matlab*®. A escolha do software é devido a uma experiência prévia, a sua comunidade ativa e a excelência na documentação das funções.

## 3.2 Base de dados sintéticos

A modelagem de perturbações é necessária para auxiliar no projeto e nos testes de novos métodos para detectar e classificar anomalias de energia elétrica (DECANINI et al., 2011). (ABDEL-GALIL et al., 2004) propôs modelos teóricos de alguns distúrbios, conforme apresentado na tabela 2, em que encontram-se as equações e parâmetros para as simulações.

A partir das equações, apresentadas na tabela 2, foi criada uma base de dados com 256 amostras por ciclo, com a frequência de amostragem de 15,36 kHz – recomendada pelo padrão **IEEE 1159-2009**. Os distúrbios abordados nesse trabalho são *sag* – afundamento, *swell* - elevação, harmônico e oscilação transiente.

Tabela 2 – Modelo teórico dos distúrbios elétricos. Adaptado de (ABDEL-GALIL et al., 2004) e (LIMA, 2015)

Distúrbio	Equações	Parâmetros
Operação Normal (s1)	$v(t) = A(\text{sen}(\omega t))$	$\omega = 2\pi 60$
<i>Sag</i> (s2)	$v(t) = A(1 - \alpha(u(t - t_1) - u(t - t_2))\text{sen}(\omega t)),$	$0.9 \leq \alpha \leq 1$ $t_1 < t_2$ $T \leq t_1 - t_2 \leq 12T$
<i>Swell</i> (s3)	$v(t) = A(1 - \alpha(u(t - t_1) - u(t - t_2))\text{sen}(\omega t),$	$0.1 \leq \alpha \leq 0.8$ $t_1 < t_2$ $T \leq t_1 - t_2 \leq 12T$
Harmônico (s4)	$v(t) = A(\text{sen}(\omega t) + \alpha_3\text{sen}(3\omega t) + \alpha_5\text{sen}(5\omega t) + \alpha_7\text{sen}(7\omega t))$	$0.05 \leq \alpha_3 \leq 0.015$ $0.05 \leq \alpha_5 \leq 0.015$ $0.05 \leq \alpha_7 \leq 0.015$
Oscilação Transiente (s5)	$v(t) = A\text{sen}(\omega t) + \alpha_{osc}\exp(-\frac{t-t_1}{T_{osc}})\text{sen}(\omega_{osc}(t - t_1))$	$T_{osc} = [0.008 \ 0.04] \text{ s}$ $\omega_{osc} = [100 \ 400] \text{ Hz}$

nota: T = Tempo total do sinal; s = segundos; Hz = Hertz

### 3.3 Base de dados de sinais de distúrbios reais

A base de dados utilizada neste trabalho é a (EPRI, 2011). Esta tem os registros oscilógrafos disponibilizados em formato **IEEE COMTRADE (IEEE STD C337.111, 1999)**. Cada um deles contém as formas de ondas dos três sinais de tensão e da corrente, como também, possui a corrente do neutro, totalizando 7 sinais armazenados.

A tabela 3 apresenta um apanhado dos sinais selecionados para a execução dessa pesquisa. É observável que esta mostra as formas de ondas correspondentes aos registros dos locais identificados como **site0002, site0003, site0011 e site0012**. Esses registros foram coletados com uma frequência fundamental de 60 Hz com uma taxa de amostragem de 256 amostras por ciclo.

Tabela 3 – Descrição dos registros oscilográficos de tensão utilizados.

Local	Formas de Onda
Site0002	47
Site0003	4
Site0011	8
Site0012	26
Total	85

A figura 18 representa o registro do evento 4554 do site0002, em que podemos observar que o sinal tem amostras antes (A), durante (B) e depois (C) do distúrbio.

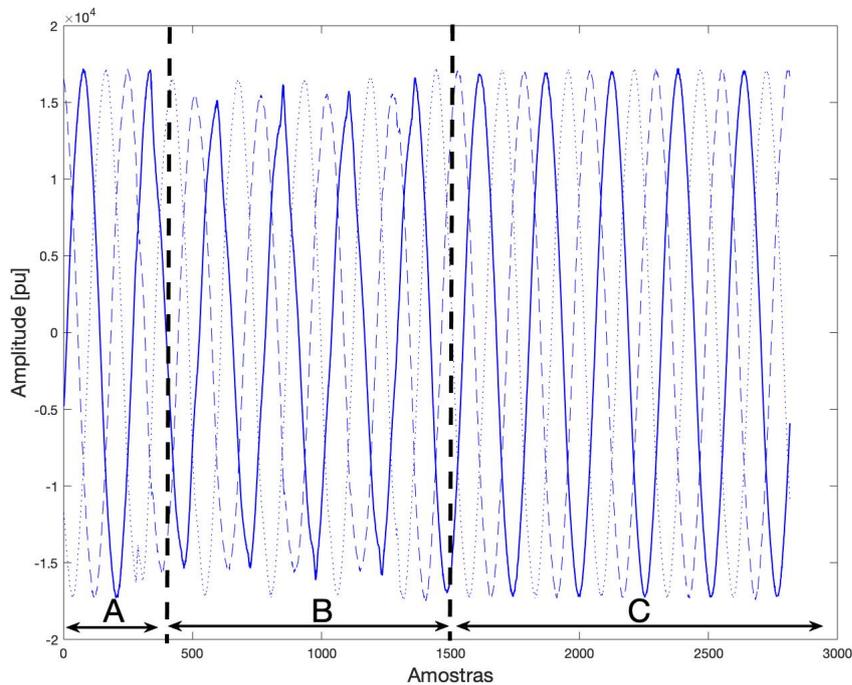


Figura 18 – Formas de onda do distúrbio de tensão (Evento 4554).

### 3.4 Identificação dos atributos

O bloco de identificação dos atributos é desenvolvido em duas partes, como apresentado na figura 17: segmentação e aplicação das técnicas para identificação dos atributos. O primeiro tem como objetivo dividir o sinal em meio ciclos e em um ciclo, e o segundo tem a meta de extrair os atributos de cada técnica aplicada.

Na primeira parte é realizada a divisão da entrada em meio ciclo e em um ciclo, ou seja, 128 amostras e 256 amostras, respectivamente. A figura 17 representa o vetor de 128 amostras como  $X_m[n]$  e o 256 como  $X_c[n]$ .

A figura 19 demonstra a segmentação da forma de onda do distúrbio de tensão do evento 4554 da fase c. No qual, a figura 19 (A) apresenta as 512 primeiras amostras do sinal, a figura 19 (B) mostra a primeira segmentação em meio ciclo do sinal e, por último, a figura 19 (C) demonstra a primeira segmentação em um ciclo do sinal.

O  $X_m[n]$  é utilizado pelas técnicas FDP não paramétricos (histogramas e estimativa de densidade kernel) e o  $X_c[n]$  é empregado pelas técnicas EOS e a transformada SPM.

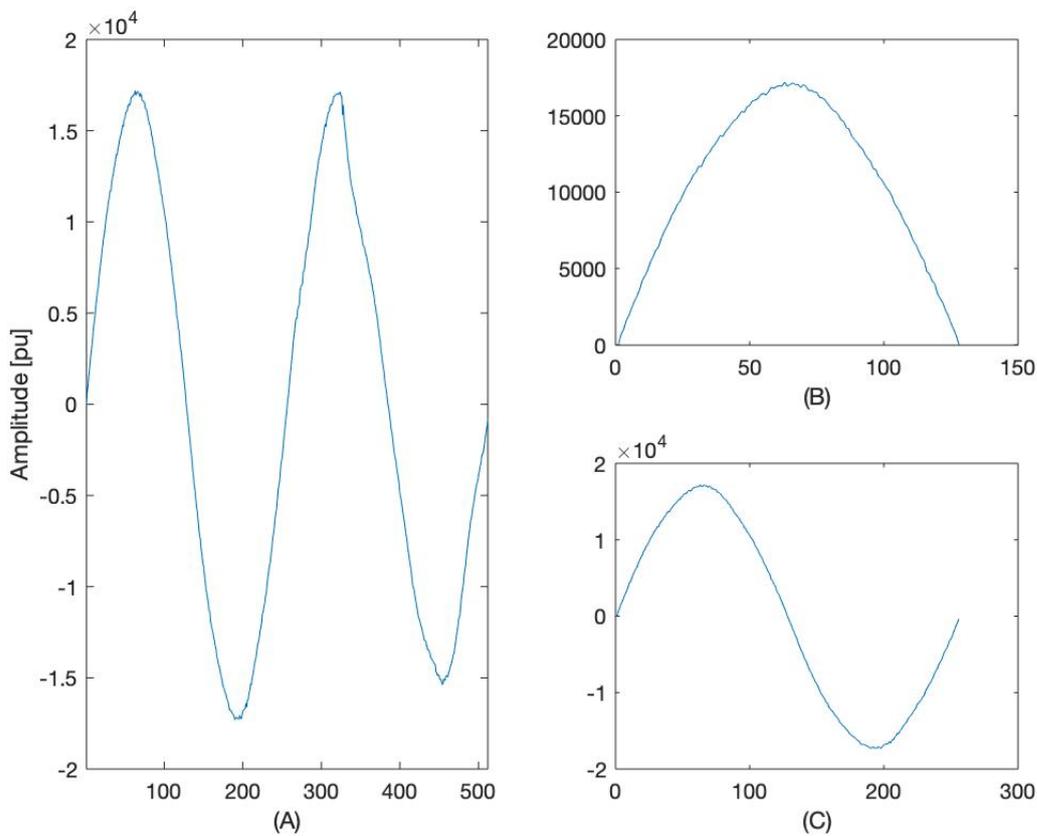


Figura 19 – Formas de onda do distúrbio de tensão da fase c (Evento 4554).

As figuras 20 (A), (B), (C) se referem, respectivamente, ao sinal de meio ciclo analisado, ao histograma horizontal e a estimativa de densidade kernel do distúrbio *sag*. As figuras 20 (D), (E), (F) correspondem, respectivamente, ao vetor  $X_m[n]$  analisado, ao histograma horizontal e a estimativa de densidade kernel do distúrbio *swell*. As figuras 20 (G), (H), (I) se referem, respectivamente, ao sinal de meio ciclo analisado, ao histograma horizontal e a estimativa de densidade kernel do distúrbio harmônico. As figuras 20 (J), (K), (L) correspondem, respectivamente, ao sinal de meio ciclo analisado, ao histograma horizontal e a estimativa de densidade kernel do distúrbio oscilação transiente.

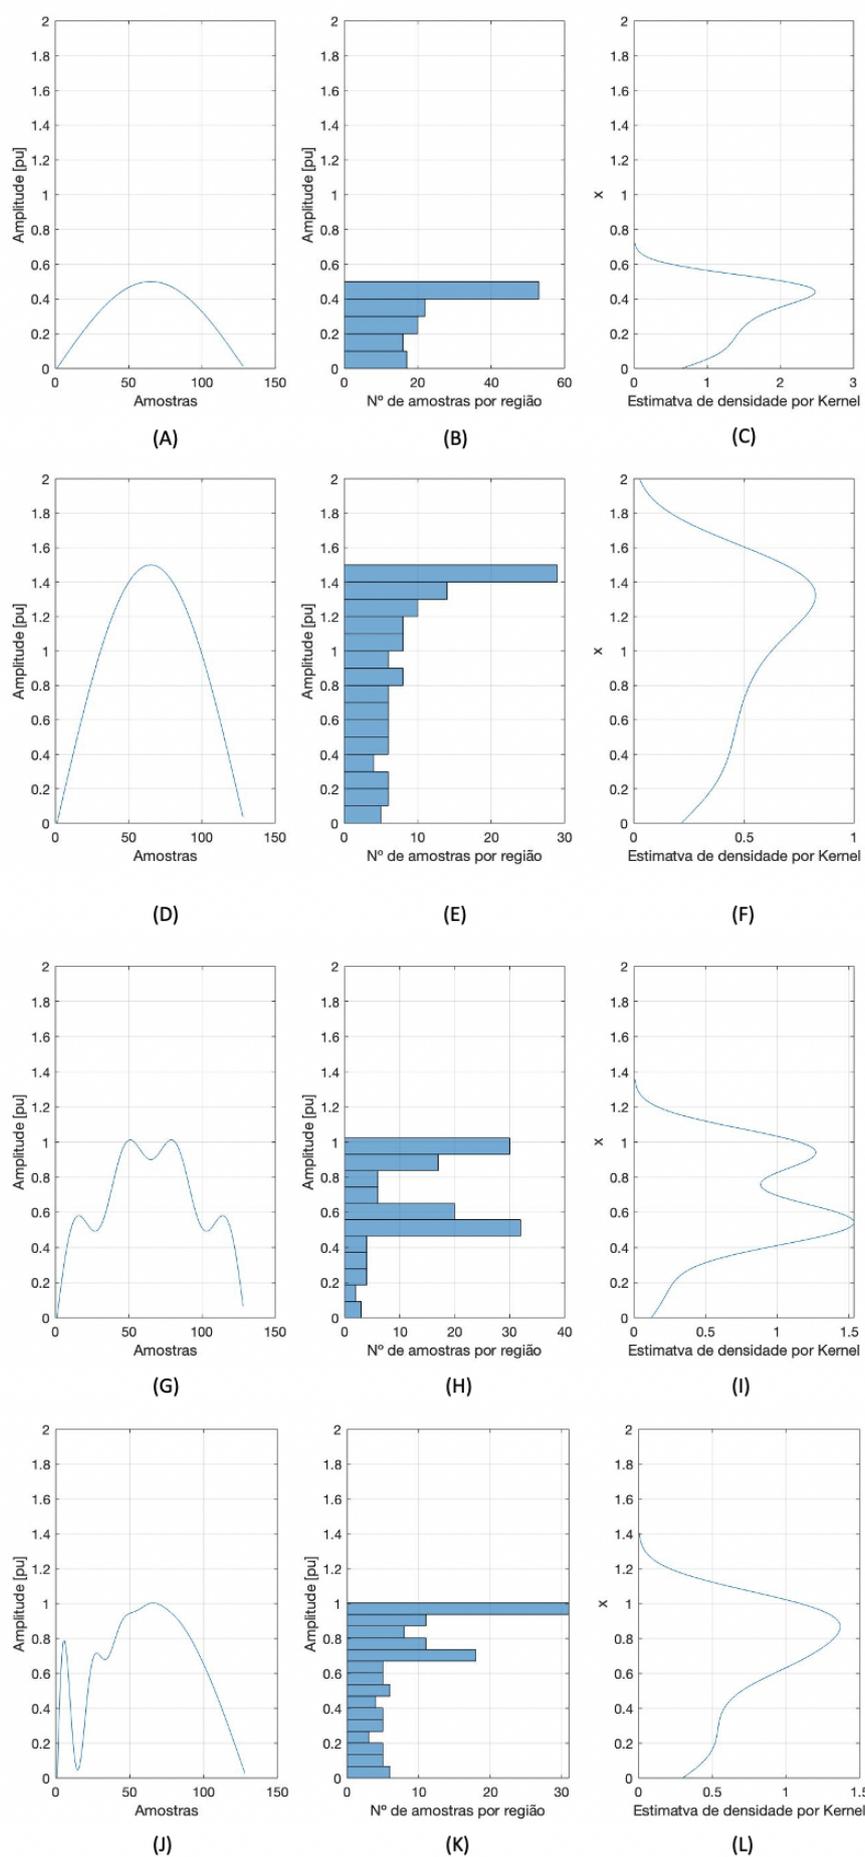


Figura 20 – Extração de características por histogramas e estimativa de densidade kernel de diferentes distúrbios

As figuras 20 (B), (E), (H) e (K) obedecem a equação 2.3 com o valor da largura da classe (L) sendo definida como 0.1 para encontrar o número de classe. As figuras 20 (C), (F), (I) e (L) utilizam a equação 2.4 para encontrar a estimativa de densidade utilizando o kernel normal (equação 2.5) e por fim, realizam a equação 2.6 para encontrar a melhor largura de banda ( $h$ ).

As figuras 21 (A) e (B) se referem, respectivamente, ao sinal de um ciclo analisado em que realizam os estimadores estatísticos de ordem superior e a transformada SPM do distúrbio *sag*. As figuras 21 (C) e (D) correspondem, respectivamente, ao sinal de um ciclo analisado em que realizam os estimadores estatísticos de ordem superior e a transformada SPM do distúrbio *swell*. As figuras 21 (E) e (F) correspondem, respectivamente, ao sinal de um ciclo analisado em que realizam os estimadores estatísticos de ordem superior e a transformada SPM do distúrbio harmônico. As figuras 21 (G) e (H) correspondem, respectivamente, ao sinal de um ciclo analisado em que realizam os estimadores estatísticos de ordem superior e a transformada SPM do distúrbio oscilação transiente.

As figura 21 (A), (C), (E) e (G) utilizam as equações 2.11, 2.13 e 2.15 para obter a variância, a assimetria e a curtose, respectivamente. As figura 21 (B), (D), (F) e (H) são resultados da metodologia da transformada SPM, que são desenvolvidas com a aplicação da equação 2.18, na qual realizam a transformada. Após isso, ocorre a aplicação da equação 2.20 com o objetivo de encontrar os valores do eixo real e imaginário.

### 3.5 Treinamento, Validação e Teste

O bloco de treinamento, validação e teste, como visto na figura 17, é responsável pela classificação do distúrbio de energia elétrica. A montagem da classificação se dá nas seguintes etapas: definição dos parâmetros dos distúrbios, treinamento da rede, validação da rede e teste da rede.

A definição dos parâmetros dos distúrbios, ou base de conhecimento, faz-se necessário devido à escolha do treinamento supervisionado. Como não foi encontrado uma determinação prévia dos distúrbios da base (EPRI, 2011) necessitou-se então criar a própria base de conhecimento dos sinais reais a partir dos atributos extraídos dos sinais sintéticos.

A arquitetura implementada é PMC, apresentada na Seção 2.5.1. A PMC é formada de uma camada intermediária composta por 10 neurônios e a com a função de ativação tangente hiperbólica. A camada de entrada apresenta 7 neurônios, ou seja, cada neurônio para um dos 7 atributos identificados, e a camada de saída tem 5 neurônios, que são os 4 distúrbios estudados e a operação normal do sinal.

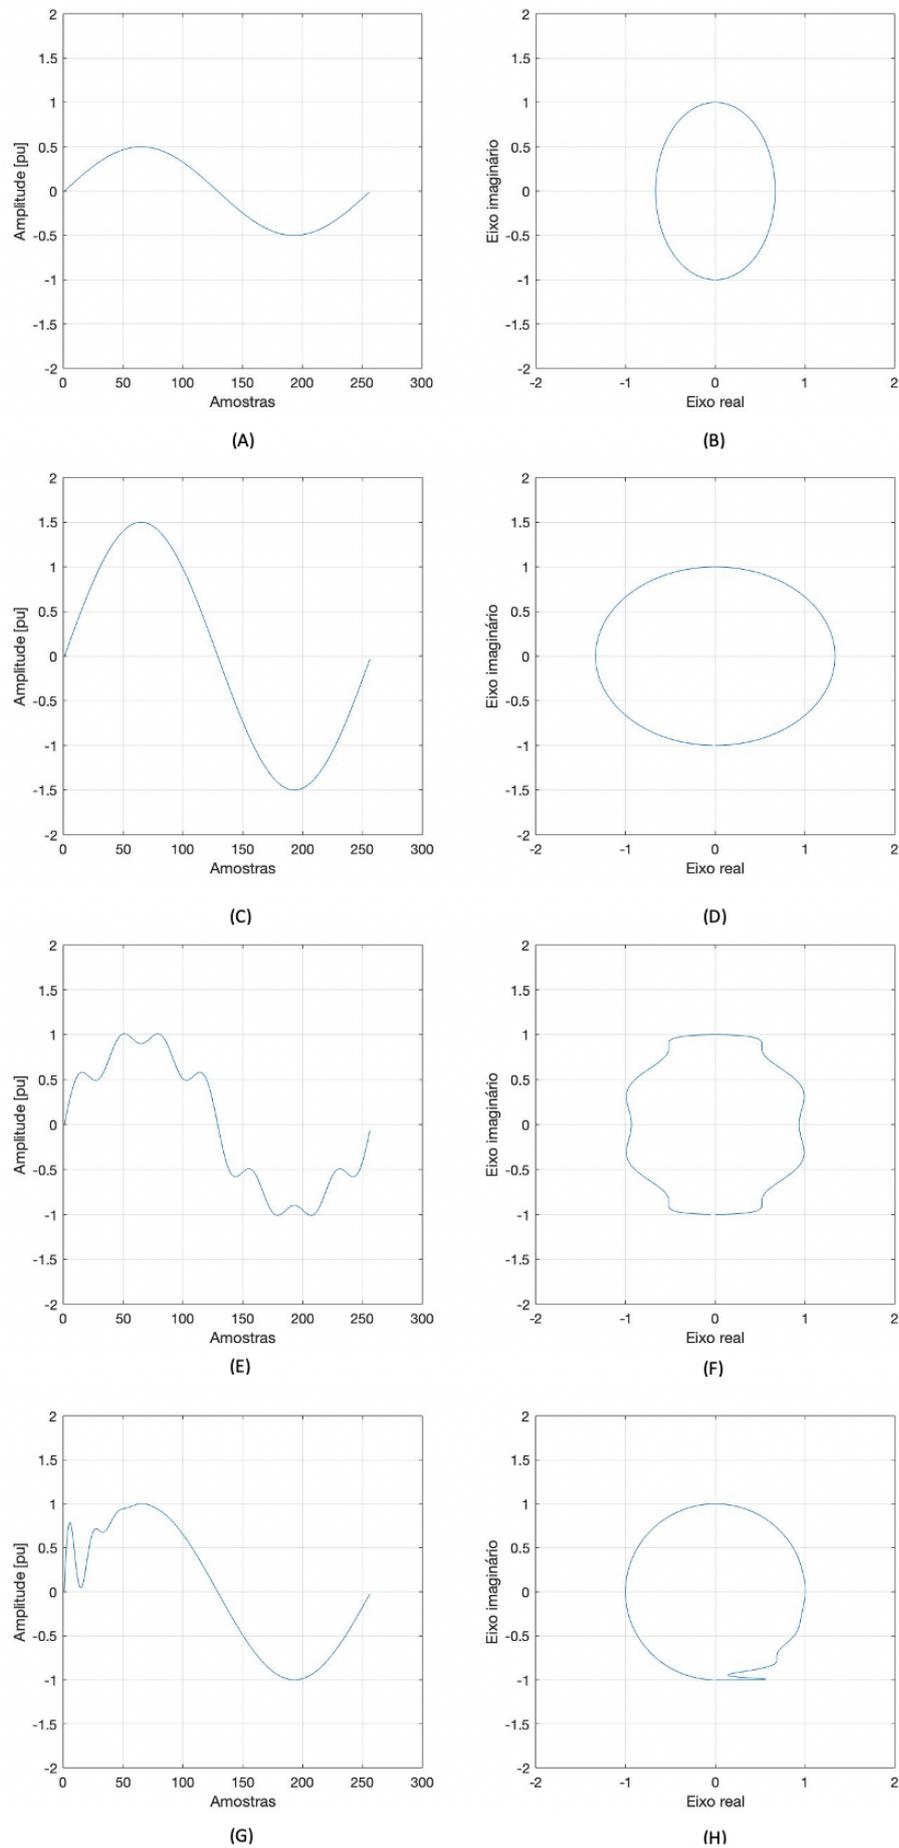


Figura 21 – Extração de características por estimadores estatísticos de ordem superior e a transformada SPM de diferentes distúrbios

A tabela 3.5 apresenta a divisão do banco de dados (EPRI, 2011) em três grupos de instâncias. Os números apresentados são referentes à quantidade de meio ciclos distribuídos para cada instancia. Elas são divididas em conjunto de treinamento, conjunto de validação, e conjunto de teste. O treinamento corresponde a 70% do total da base de dados, a validação e o teste correspondem a 15% cada um.

Tabela 4 – Conjunto de treinamento, validação e teste

	Número de Instâncias		
	Treinamento	Validação	Teste
Base de dados (EPRI, 2011)	30617	6562	6562

O processo de treinamento utilizou o algoritmo *backpropagation*. Este processo é o conjunto de treinamento e validação da etapa de aprendizagem da rede. Destaca-se que essa atividade pode ser finalizada quando o valor do erro médio quadrático for inferior a  $10^{-2}$ , ou quando atingir 1000 épocas de treinamento.

## 4 Resultados e Discussões

Este capítulo tem como objetivo verificar a eficiência do algoritmo desenvolvido para a solução do problema de detecção e classificação de distúrbios de energia elétrica, a partir da metodologia descrita na Seção 3.1. Para avaliar a eficiência dos resultados obtidos com esse método, foi realizada uma comparação com os trabalhos científicos semelhantes.

### 4.1 Resultados

Para a utilização da metodologia, foram considerados os atributos: número de classe, largura de banda, variância, assimetria, curtose e valores máximo e mínimo do eixo real a partir das técnicas FDP não paramétrica (histograma e estimativa de densidade kernel), EOS e transformada SPM. Esses atributos são agrupadas em uma matriz  $[S]$ . Neste estudo, foram utilizados dois conjuntos de banco de dados: um sintético e outro real. O sintético é utilizado para definir os parâmetros dos distúrbios e o real para treinamento, validação e teste da rede neural, conforme explicado na subsecção 3.1.

O procedimento para geração dos parâmetros sintéticos foi realizado duas vezes, com objetivo de determinar os eventos na base de dados reais, a primeira vez obteve-se as informações dos distúrbios com amplitude típica mínima e a segunda com o intuito de adquirir os parâmetros para os distúrbios com amplitude típica máxima (os valores de amplitude típica mínima e máxima podem ser vistos na tabela 2.1.1). Observa-se assim, que após o processamento da etapa de identificação dos atributos de sinais sintéticos, obteve-se os parâmetros para cada distúrbio, conforme apresentado na tabela 5.

Tabela 5 – Parâmetros dos distúrbios

	Número de classe		Largura de banda		Variância		Assimetria	Curtose	Valor Eixo Real	
	Max	Min	Max	Min	Max	Min			-	-
s1	10	9	0.1596	0.1333	0.5964	0.4152	0	-1.5	1.06	0.94
s2	9	1	0.1318	0.0146	0.4153	0.005	0	-1.5	0.93	0.4
s3	18	11	0.2636	0.1611	1.8	0.5965	0	-1.5	1.07	1.066
s4	199	9	2.9622	0.1149	200	0.5195	0	1.4016	13.6	0.93
s5	18	9	1.2487	0.2231	32	0.5107	0.0139	6.2523	1.5945	1.5945

nota: Max = Máximo; Min = Mínimo; - = Valor único;

Com a definição dos distúrbios do banco de dados reais tem-se a tabela de entrada e saída para o treinamento da PCM. Vale ressaltar que o procedimento de treinamento foi realizado 100 vezes para obter a melhor PCM. O melhor resultado de treinamento

foi obtido pela PCM que apresentou a eficiência de classificação global de 96%, ou seja, melhor valor relacionado entre o treinamento, validação e teste da rede. Essa rede obteve os resultados de performance da validação de  $9.18 * 10^{-3}$  para 209 épocas, conforme apresentado na figura 22.

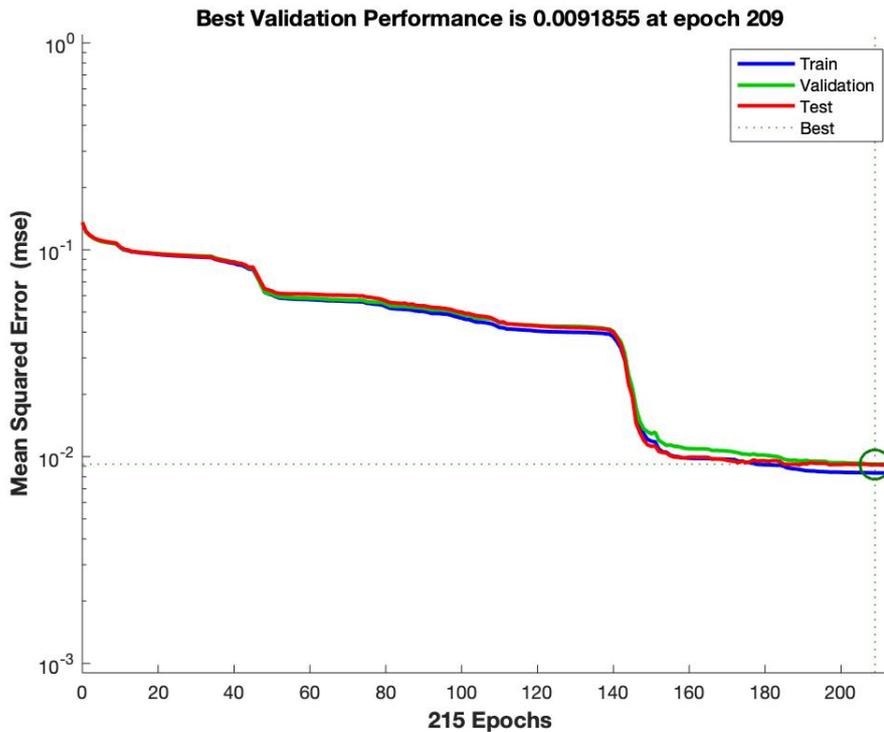


Figura 22 – Performance da melhor rede neural

A rede escolhida apresentou os seguintes resultados para treino, validação e teste, conforme apresentado nas tabelas 6, 7 e 8, nas quais mostram a eficiência geral de cada etapa. Por outro lado, a tabela 9 demonstra a eficiência individual de cada distúrbio nas etapas de treinamento, validação e teste.

Para avaliar a eficiência e a coerência dos resultados obtidos, estes foram comparados com os trabalhos de (VALTIERRA-RODRIGUEZ et al., 2014) (1), (Willian Souza Arruda, 2015), (2), que utilizam as técnicas de histograma para detecção e sistema imunológico artificial para classificação. Por outro lado, (BAGHERI et al., 2018) (3) conta com a transformada SPM para detectar e redes neurais para classificação. (ENSHAEE; ENSHAEE, 2018) (4) emprega, respectivamente, a transformada S e rede neural para detecção e classificação dos distúrbios de energia elétrica. Por fim, (FERREIRA et al., 2009) (5) utiliza a técnica EOS para identificação e máquina de vetores de suporte e rede neural para classificação. A tabela 10 mostra uma comparação entre o resultado obtido neste trabalho e os resultados apresentados pelos trabalhos supracitados.

Tabela 6 – Resultado do treinamento da rede

	s1	s2	s3	s4	s5
s1	8688	1	3	83	25
s2	471	812	0	16	38
s3	14	0	1761	17	4
s4	160	16	38	12924	54
s5	37	3	4	31	554
eficiência	96.1%				

Tabela 7 – Resultado do validação da rede

	s1	s2	s3	s4	s5
s1	1874	0	0	28	8
s2	98	181	0	3	12
s3	1	0	368	6	3
s4	34	7	8	2747	4
s5	11	0	3	5	118
eficiência	95.8%				

Tabela 8 – Resultado do teste da rede

	s1	s2	s3	s4	s5
s1	1832	1	0	28	5
s2	100	213	0	8	7
s3	1	0	387	3	3
s4	33	4	9	2743	4
s5	12	2	2	7	115
eficiência	95.9%				

Tabela 9 – Resultados de classificação correta para cada distúrbio nas etapas treinamento, validação e teste (%)

	Treinamento	Validação	Teste
s1	98.7	98.1	98.2
s2	60.7	61.6	64.9
s3	98.1	97.4	98.2
s4	98.1	98.1	98.2
s5	88.1	86.1	83.3
eficiência global	96%		

Tabela 10 – Comparação de desempenho em termos de porcentagem de resultados de classificação correta (%)

Distúrbios	(1)	(2)	(3)	(4)	(5)	<b>Este trabalho</b>
s1	100	100	97.72	–	–	<b>98.6</b>
s2	100	100	95.18	98.6	100	<b>61.6</b>
s3	100	100	93.59	99	100	<b>98</b>
s4	98	100	–	98.2	100	<b>98</b>
s5	98	100	–	97	100	<b>87.1</b>

nota : – = não definidos

## 4.2 Discussões

Mediante a tabela 10, é possível observar que a metodologia apresentada obteve um percentual de eficiência global semelhante, comparada aos trabalhos científicos apresentados. Por outro lado, ao observar individualmente cada distúrbio, obteve-se resultados similares, superiores e inferiores aos demais trabalhos.

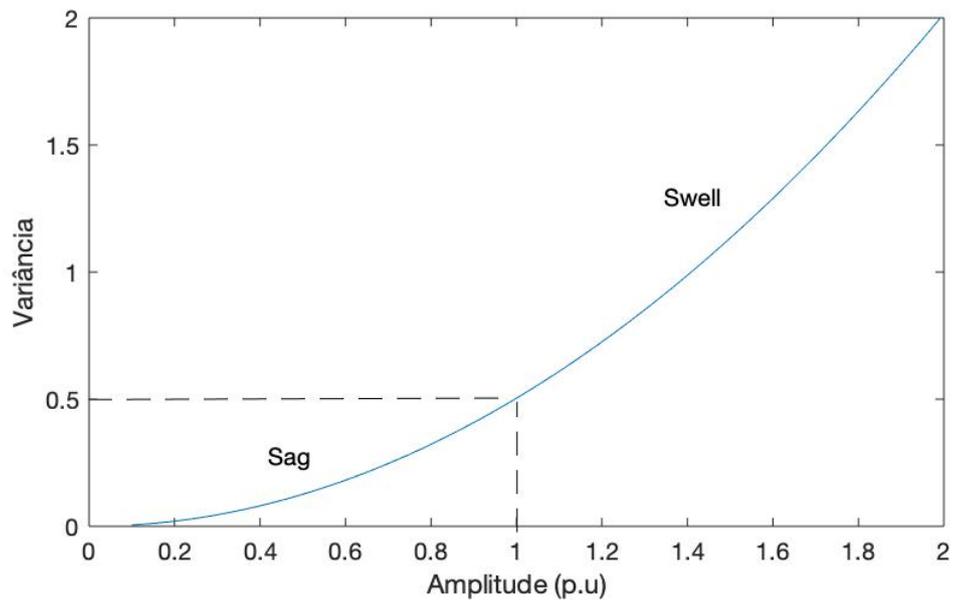
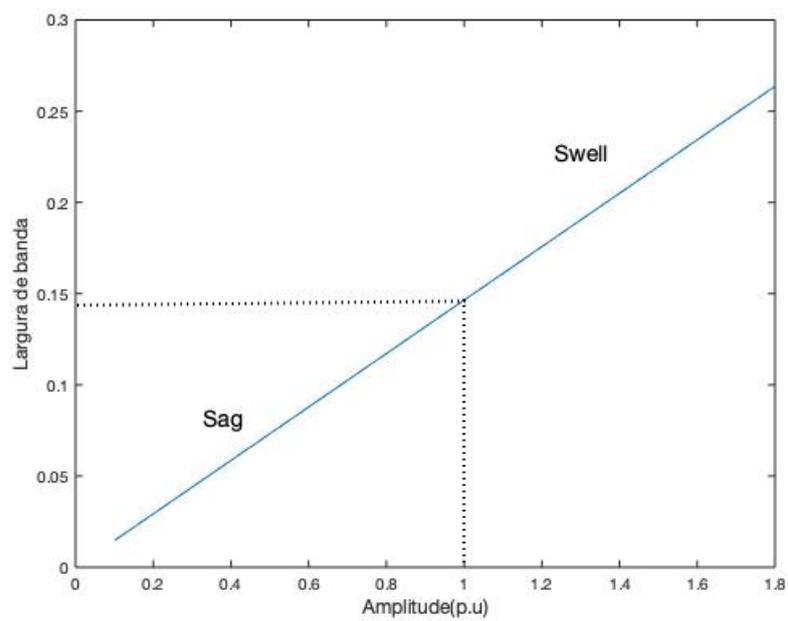
Os bancos de dados para treinamento utilizados pelos autores (VALTIERRA-RODRIGUEZ et al., 2014), (Willian Souza Arruda, 2015), (BAGHERI et al., 2018), (ENSHAE; ENSHAE, 2018) e (FERREIRA et al., 2009) foram criados sinteticamente. No entanto, esse trabalho desenvolveu o treinamento a partir de um banco de dados real.

Uma característica relevante é a relação entre amplitude da onda com os atributos número de classe, largura de banda, variância e valor do eixo real, sendo que estes não têm relação com o formato da onda. Isso pode ser observado na metodologia desenvolvida por (AGÜERA-PÉREZ et al., 2011), em que é demonstrado que a variância e amplitude tem relação não-linear. Essa observação pode ser vista com os valores da variância dos distúrbios *sag* (s2) e *swell* (s3) apresentados na tabela 5. A figura 23 demonstra o comportamento em forma gráfica dessa relação, dado que a linha pontilhada informa o ponto exato da operação normal. Por outro lado, a relação entre a largura de banda e amplitude é uma relação linear, conforme visto na figura 24.

Outro fato observado nessa metodologia proposta é a não-dependência da amplitude para os atributos de assimetria e curtose, visto que na tabela 5 esses dados apresentam valores únicos para qualquer valor da amplitude. Entretanto, é notável que, a curtose é relacionada ao formato da onda, ao passo que os distúrbios harmônico (s4) e oscilação transiente (s5) têm a sua forma modificada comparada os distúrbios *sag* e *swell*.

É perceptível na tabela 9 que os distúrbios s2 e s5 foram os que obtiveram pior desempenho, sendo que o s2 tem a pior taxa de acerto- menor que 70%. O resultado não esperado do distúrbio s2 não teve determinação do motivo, visto que os outros apresentaram taxas de acerto acima de 70%, com alguns distúrbios com eficiência próximo de 100%. Mesmo com esse baixo desempenho do distúrbio s2, a rede escolhida apresentou a maior eficiência global- igual a **96%**.

A partir dos resultados e das comparações realizadas com outros trabalhos, é observado que utilizar varias técnicas de identificação de atributos mostra-se eficiente para resolver o problema de detecção. Enquanto isso, a rede neural treinada para classificar apresentou bons resultados, tendo eficiência global de **96%**, sendo necessário uma otimização da rede e dos atributos utilizados para uma melhor classificação levando em conta o resultado obtido pelo distúrbio s2.

Figura 23 – Relação entre amplitude e variância para os distúrbios *sag* e *swell*Figura 24 – Relação entre amplitude e largura de banda para os distúrbios *sag* e *swell*

# 5 Conclusão

Este trabalho desenvolve um algoritmo que tem as técnicas de identificação de atributos (histogramas, estimativa de densidade por kernel, estimadores estatísticos de ordem superior e transformada *space phasor model*) e a classificação de anomalias de rede elétrica através de rede neurais *feedforward* de múltiplas camadas. Somado a esses conceitos, fez-se o levantamento de trabalhos científicos publicados em anais de conferencias e revistas, sendo proposto um método de identificação de atributos para a classificação dos distúrbios de energia elétrica.

Foram utilizados os métodos: função de densidade de probabilidade não-paramétricas-histogramas e estimador de densidade kernel- para extrair atributos de cada meio ciclo do sinal de tensão; e estimadores estatísticos de ordem superior, juntamente com a transformada SPM para extrair atributos de cada um ciclo do sinal de tensão. Esses atributos foram utilizados como entrada da rede neural para determinar a classificação do sinal entre a operação normal e os distúrbios de energia elétrica: *sag*, *swell*, harmônico e oscilação transiente.

Ao avaliar os resultados experimentais obtidos, conclui-se que a metodologia proposta atinge um nível global de **96%** na classificação dos distúrbios abordados. Observando cada distúrbio individualmente nas etapas de treinamento e teste tivemos a eficiência, respectivamente, de 60.7 % e 64.9 % para *sag*, 98.1% e 98.2% para *swell*, 98.1% e 98.2% para harmônico, 88.1% e 83.3% para oscilação transiente e 98.7% e 98.2% para operação normal.. Esse resultado apresenta-se satisfatório, comparado a outros trabalhos publicados no meio científico.

Destacam-se os atributos de assimetria e curtose, pois esses não estão relacionados com a amplitude da onda, relacionando-se, assim, com a distorção, ao contrário dos demais atributos, que apresentam relação direta com a amplitude da onda. Destaca-se também, o fato da metodologia classificar o sinal de energia elétrica a cada meio ciclo de sinal de tensão.

## 5.1 Proposta de melhorias e trabalhos futuros

Para melhoramento dessa pesquisa propõem-se trabalhar com mais distúrbios, ao passo que foram utilizados apenas 4 distúrbios simples, tornando assim, uma metodologia mais abrangente ao melhor identificar as interferências elétricas. É necessário também, realizar um estudo específico sobre qual é a melhor arquitetura e topologia da rede neural a serem adotadas pela etapa de classificação. Por fim, é preciso um estudo de uma possível

implementação em microcontroladores, com a finalidade de testar a metodologia proposta em um ambiente real.

# Referências

ABDEL-GALIL, T. K. et al. Power quality disturbance classification using the inductive inference approach. *IEEE Transactions on Power Delivery*, v. 19, n. 4, p. 1812–1818, 2004. ISSN 08858977. Citado 4 vezes nas páginas 10, 38, 39 e 40.

AGÜERA-PÉREZ, A. et al. Characterization of electrical sags and swells using higher-order statistical estimators. *Measurement: Journal of the International Measurement Confederation*, v. 44, n. 8, p. 1453–1460, 2011. ISSN 02632241. Citado 2 vezes nas páginas 39 e 50.

ANSI, A. N. S. – *For Electric Power Systems and Equipment – Voltage Ratings (60 Hertz) - C 84.1*. 2011. Citado na página 22.

BAGHERI, A. *Artificial Intelligence-Based Characterization and Classification Methods for Power Quality Data Analytics*. [s.n.], 2018. 116 p. ISBN 9789177902508. Disponível em: <<http://tu.diva-portal.org/smash/get/diva2:1260152/FULLTEXT01.pdf>>. Citado 2 vezes nas páginas 31 e 39.

BAGHERI, A. et al. A Robust Transform-Domain Deep Convolutional Network for Voltage Dip Classification. *IEEE Transactions on Power Delivery*, Institute of Electrical and Electronics Engineers Inc., v. 33, n. 6, p. 2794–2802, dec 2018. ISSN 08858977. Citado 2 vezes nas páginas 48 e 50.

BOLLEN, M. H. *Signal Processing of power quality disturbances*. [S.l.: s.n.], 2012. 882 p. ISBN 9780471731689. Citado na página 19.

CASELLA, G.; BERGER, R. L. *Inferência estatística / George Casella, Roger L. Berger ; tradução Solange A. Visconte ; revisão técnica Jorge Oishi*. [s.n.], 2014. ISBN 9788522108947. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true&db=cat07149a&AN=buin.1026711&site>>. Citado na página 28.

DECANINI, J. G. et al. Detection and classification of voltage disturbances using a Fuzzy-ARTMAP-wavelet network. *Electric Power Systems Research*, v. 81, n. 12, p. 2057–2065, 2011. ISSN 03787796. Citado na página 39.

DUGAN, R. C. et al. *Electrical Power Systems Quality*. 3. ed. New York: [s.n.], 2012. 558 p. ISBN 9780071761550. Citado 7 vezes nas páginas 16, 18, 19, 20, 21, 22 e 23.

ENSHAEI, A.; ENSHAEI, P. A New S-Transform-Based Method for Identification of Power Quality Disturbances. *Arabian Journal for Science and Engineering*, Springer Berlin Heidelberg, v. 43, n. 6, p. 2817–2832, 2018. ISSN 21914281. Citado 2 vezes nas páginas 48 e 50.

EPRI. *DOE/EPRI National Database Repository of Power System Events*. 2011. Disponível em: <<http://expertmonitoring.com/doelibrary/default.asp>> Acesso em: 10 setemebro. 2019. Citado 4 vezes nas páginas 38, 40, 44 e 46.

FERNANDES, R. M. Uma nova técnica para detecção e classificação de transitórios em sistema elétricos de potência. 2017. Citado na página 16.

- FERREIRA, D. D. et al. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica. *Controle y Automacao*, v. 20, n. 1, p. 53–62, 2009. ISSN 01031759. Citado 2 vezes nas páginas 48 e 50.
- HAYKIN, S. *Redes neurais : princípios e prática*. 2011. Disponível em: <<https://integrada.minhabiblioteca.com.br/books/9788577800865>>. Citado 4 vezes nas páginas 9, 32, 33 e 34.
- HEUMANN, C.; SHALABH; SCHOMAKER, M. *Introduction to Statistics and Data Analysis With Exercises, Solutions and Applications in R*. 2016. Disponível em: <<http://hdl.handle.net/2078/ebook:90415>>. Citado na página 27.
- HINES, W. W. *Probabilidade e estatística na engenharia / William W. Hines ... [et al.] ; tradução Vera Regina Lima de Farias e Flores*. [s.n.], 2006. ISBN 9788521614746. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true&db=cat07149a&AN=buin.934737&site>>. Citado 3 vezes nas páginas 23, 24 e 29.
- IEEE, I. o. E.; INC, E. E. *Ieee emerald 1100 Powering and Grounding electronic equipment*. New York: IEEE, 2005. ISBN 0738149799. Disponível em: <[http://www2.elo.utfsm.cl/~ipd411/archivos/apuntes/Std1100-2005{\\\_}0163820](http://www2.elo.utfsm.cl/~ipd411/archivos/apuntes/Std1100-2005{\_}0163820)>. Citado na página 18.
- IEEE, S. -. *The New IEEE Standards Dictionary of Electrical and Electronics Terms*. 1993. Citado 2 vezes nas páginas 10 e 19.
- KAFADAR, K.; BOWMAN, A. W.; AZZALINI, A. Applied Smoothing Techniques for Data Analysis: The Kernel Approach with S-PLUS Illustrations. *Journal of the American Statistical Association*, v. 94, n. 447, p. 982, 1999. ISSN 01621459. Citado na página 27.
- LIMA, A. P. D. A. *ALGORITMO HÍBRIDO NEURAL-IMUNO APLICADO AO DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA*. [S.l.], 2015. Citado 2 vezes nas páginas 10 e 40.
- LOPES, L. F. D. Apostila Estatística. p. 1–139, 2003. Citado 2 vezes nas páginas 29 e 30.
- MONTGOMERY, D. et al. *Probabilidade e estatística na engenharia*. Livros Técnicos e Científicos, 2006. ISBN 9788521614746. Disponível em: <<https://books.google.com.br/books?id=9AVgPgAACAAJ>>. Citado 2 vezes nas páginas 24 e 25.
- MOREIRA, L. D. E. S. A relação parabólica entre assimetria e curtose em um experimento de gaseificador fluidizado. 2018. Citado na página 28.
- ONS, O. n. d. S. *Glossário - Qualidade de energia elétrica(QEE)*. 2019. Disponível em: <<http://ons.org.br/paginas/conhecimento/glossario>>. Citado na página 18.
- RODRIGO, M.; FERREIRA, P. Método Kernel : Estimacão de Densidades e Classificacão de Padrões Estrutura da Apresentacão Motivacão Estimacão de Densidades pelo Método Kernel ( i ) Caso Univariado Análise Discriminante Kernel Experimentos. 2009. Citado na página 24.

RUPPERT, D.; MATTESON, D. S. *Statistics and Data Analysis for Financial Engineering : with R examples*. 2015. Disponível em: <<http://hdl.handle.net/2078/ebook:63178>>. Citado na página 26.

SILVA, I. N. da; FLAUZINO, R. A.; SPATTI, D. H. *Redes neurais artificiais para engenharia e ciências aplicadas / Ivan Nunes da Silva, Danilo Hernane Spatti, Rogério Andrade Flauzino*. [s.n.], 2019. ISBN 9788588098879. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true{&}db=cat07149a{&}AN=buin.1044631{&}site>>. Citado 6 vezes nas páginas 9, 32, 33, 34, 35 e 36.

VALTIERRA-RODRIGUEZ, M. et al. Detection and classification of single and combined power quality disturbances using neural networks. *IEEE Transactions on Industrial Electronics*, IEEE, v. 61, n. 5, p. 2473–2482, 2014. ISSN 02780046. Citado 3 vezes nas páginas 39, 48 e 50.

Willian Souza Arruda, B. D. *CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA BASEADA EM SISTEMAS IMUNOLÓGICOS ARTIFICIAIS JOÃO PESSOA 2015*. [S.l.], 2015. Citado 2 vezes nas páginas 48 e 50.

# Anexos

# ANEXO A – Pseudocódigo

Para facilitar a leitura do código, considere o fluxograma da figura 14 na página 47. Considera-se que a rede neural já tenha sido treinada e que a entrada é composto de 3 ondas de tensão. O pseudocódigo tem as seguintes funções:

- **SEG128**: Função de segmentação do sinal em 128 amostras, ou seja, meio ciclo;
- **SEG256**: Função de segmentação do sinal em 256 amostras, ou seja, um ciclo;
- **FDP**: Função que realiza o histograma e estimativa de densidade de kernel e retorna os atributos número de classe e largura de banda;
- **EOS**: Função que realiza a estimadores estatísticos de ordem superior e retorna os atributos variância, assimetria e curtose;
- **SPM**: Função que realiza a transformada SPM e retorno os atributos valor máximo e mínimo do eixo real;

```
1 input = entrada(3,:);
2 %% segmenta o
3 [A_128,B_128, C_128 ] = SEG128(input); % segmenta o em meio ciclo
4 [A_256,B_256, C_256 ] = SEG256(input); % segmenta o em um ciclo
5
6 %% identifica o dos atributos
7 for i = 1:legnth(A_256)
8     [A_FDP(i,:), B_FDP(i,:), C_FDP(i,:)] = ...
9         FDP(A_128(i,:),B_128(i,:), C_128(i,:));
10    [A_EOS(i,:), B_EOS(i,:), C_EOS(i,:)] = ...
11        EOS(A_256(i,:),B_256(i,:), C_256(i,:));
12    [A_SPM(i,:), B_SPM(i,:), C_SPM(i,:)] = ...
13        SPM(A_256(i,:),B_256(i,:), C_256(i,:));
14 end
15 %% Concatena o dos atributos das mesmas fases
16 entrada_A = [A_FDP;A_EOS;A_SPM];
17 entrada_B = [B_FDP;B_EOS;B_SPM];
18 entrada_C = [C_FDP;C_EOS;C_SPM];
19
20 %% Aplicando rede neural em cada fase
21 Resultado_A = rede([entrada_A]);
22 Resultado_B = rede([entrada_B]);
23 Resultado_C = rede([entrada_C]);
```